

基于优化靶向诱捕器的 YOLO v8 活体稻纵卷叶螟智能识别方法

刘双喜^{1,2} 王刘西航¹ 王金星^{1,3} 胡宪亮⁴ 杨圣杰¹ 马盼⁵

(1. 山东农业大学机械与电子工程学院, 泰安 271018; 2. 农业装备智能化山东省工程研究中心, 泰安 271018;
3. 山东省设施园艺智慧生产技术装备重点实验室(筹), 泰安 271018;
4. 山东祥辰科技集团有限公司, 济南 251400; 5. 济南市农业科学研究院, 济南 251400)

摘要: 针对水稻活体害虫智能识别过程中容易出现目标小、姿态各异以及诱捕时诱捕装置效率不高等问题, 导致害虫识别精度不足, 本文提出一种基于一拖三活体靶向诱捕器改进 YOLO v8n 模型的水稻害虫智能识别方法。通过改进传统靶向识别装置结构, 设计一拖三活体靶向诱捕装置提高工作效率; 针对智能识别所需数据集制作, 提出图像逐帧清晰度对比排序法进行数据集提取, 通过改进 CBAM 注意力机制引入自适应模块, 提升模型对目标区域关注度, 改进 AFPN 结构, 在 AFPN 中增加高分辨率 P2 层, 以增强对小目标的识别能力。模型试验结果表明, 改进后的 YOLO v8n 模型在稻纵卷叶螟数据集上的平均精度均值 (mAP@0.5) 达到 95.65%。消融试验结果表明, 改进后的 CBAM 模块、引入 P2 层 AFPN 结构均显著提升模型性能, 使模型综合识别能力达到最优。田间试验进一步验证改进后的 YOLO v8n 模型实际应用效果, 结合靶向识别装备在稻田中稻纵卷叶螟识别率达 90% 以上, 表现出较好鲁棒性和稳定性。综上, 本文提出基于 YOLO v8n 改进的模型水稻活体害虫识别方法能够有效提高识别精度与效率, 为水稻害虫精准识别和防控提供科学依据, 具有较强实际应用价值与推广潜力。

关键词: 水稻害虫; 一拖三活体靶向诱捕器; CBAM; AFPN

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2025)12-0499-11 OSID: 

YOLO v8-based Intelligent Recognition of Live *Cnaphalocrocis medinalis* Using Optimized Targeted Trapping Device

LIU Shuangxi^{1,2} WANG Liuxihang¹ WANG Jinxing^{1,3} HU Xianliang⁴ YANG Shengjie¹ MA Pan⁵

(1. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Taian 271018, China
2. Shandong Engineering Research Center of Agricultural Equipment Intelligentization, Taian 271018, China
3. Shandong Key Laboratory of Intelligent Production Technology and Equipment for Facility Horticulture, Taian 271018, China
4. Shandong Xiangchen Technology Group Co., Ltd. Co., Ltd., Ji'nan 251400, China
5. Ji'nan Academy of Agricultural Sciences, Ji'nan 251400, China)

Abstract: Aiming to address the issues of small target size, varying pest postures, and low detection efficiency, and suboptimal performance of trapping devices during live rice pest identification, an intelligent recognition method was proposed based on an improved YOLO v8n model integrated with a one-to-three live targeted trapping device. By optimizing the structural design of the traditional targeted recognition equipment, a one-to-three live targeted trapping device was developed to enhance operational efficiency. For the construction of the dataset required for intelligent recognition, a frame-by-frame image clarity comparison and sorting method was proposed to improve data quality. Additionally, an adaptive module was introduced into the improved CBAM attention mechanism to enhance the model's focus on target regions, and a high-resolution P2 layer was added to the AFPN structure to improve small target recognition capability. Comparative experiments demonstrated that the improved YOLO v8n model achieved a mean average precision (mAP@0.5) of 95.65% on the rice leaf folder dataset. Ablation experiments further verified that the enhanced CBAM module and the introduction of the P2 layer in the

AFPN structure significantly improved model performance, resulting in optimal overall recognition capability. Field trials confirmed the practical effectiveness of the improved YOLO v8n model, achieving a recognition rate of over 90% for rice leaf folder pests across 60 mu (approximately 4 hectares) of rice fields when combined with the targeted identification device, demonstrating good robustness and stability. In summary, the intelligent recognition method for live rice pests based on YOLO v8n the improved model proposed effectively enhanced recognition accuracy and efficiency, providing a scientific basis for precise pest identification and control in rice fields, with strong practical application value and promotion potential.

Key words: rice pest; one-to-three live targeted trapping device; CBAM; AFPN

0 引言

根据全国农业技术推广服务中心数据,虫害所造成的经济损失占有所有农作物虫害经济损失的 55%^[1-2]。但传统水稻害虫诱捕往往伴随着益虫误捕情况,在水稻田误捕的益虫,像食蚜蝇、蜘蛛、寄生蜂在生态系统中扮演着重要角色^[3],它们能捕食危害水稻的害虫如二化螟、稻纵卷叶螟、稻飞虱等。水稻害虫活动轨迹和运动量是其危害程度的关键指标,活体害虫识别对于地区害虫防控具有积极意义,对害虫轨迹观察等需在活体识别进行,因此对活体水稻害虫精准识别刻不容缓^[4-6]。识别出活体水稻害虫后采取适当措施区分害虫和益虫可减少误捕现象,但水稻害虫体型较小,常见二化螟体长 9~13 mm,稻纵卷叶螟 7~9 mm,甚至稻飞虱仅有 4~4.2 mm,因此对于活体水稻害虫识别,有着数据量少,尺寸小,姿态各异的情况,造成识别困难^[7]。

近年来,随着计算机硬件算力显著提升,深度学习技术得到飞速发展。深度学习模型在多个领域展现出卓越性能^[8-10],与传统机器学习模型相比^[11-13],深度学习模型具有更强泛化能力,性能更为稳定。谭泗桥等^[14]提出一种基于改进 YOLO v8m 模型的稻田害虫识别方法 FieldSentinel-YOLO v8,精确率达到 69.90%;林相泽等^[15]提出一种基于迁移学习和 Mask R-CNN 的稻飞虱图像分类方法,平均精度均值达到 92.3%;曾伟辉等^[16]提出一种基于 SCRResNeSt 的低分辨率水稻害虫图像识别方法,识别精确率达到 91.20%;梁勇等^[17]引入目标检测算法 YOLO v5,稻纵卷叶螟识别精确率达到 91.67%;赵辉等^[18]提出一种改进 YOLO v7 的害虫识别方法,将 CBAM 集成到 YOLO v7,精确率为 91.6%;何泽坤等^[19]提出改进 YOLO v5 网络的水稻害虫识别模型,平均精度均值达到 91.30%;王泰华等^[20]基于 YOLO v5 引入 CBAM 注意力机制等,水稻害虫的平均精度均值达到 94.3%;靳新宇等^[21]将 YOLO v8n 检测算法与 AFPN 结合,精确率达到 85.1%;TANG 等^[22]通过改进 ECA 机制和

transformer 编码器提出 Pest-YOLO,在 Pest24 数据集上实现平均精度均值 73.4%;WANG 等^[23]通过引入 CBAM 注意力模块提出 Insect-YOLO,水稻害虫识别的平均精度均值达到 93.8%。

针对国内外研究现状,当前多数害虫识别研究仍停留在静态图像或实验环境中,尚未聚焦田间环境活体害虫的动态识别。尽管部分模型在算法优化方面取得进展,但对小目标、多姿态识别精度仍有限,实际应用效果不理想。尤其在活体水稻害虫的识别与诱捕方面,尚缺乏可行的系统方案。为此,亟需构建一种适用于田间环境、具备高精度与强适应性的识别方法,以提升虫情监测的智能化水平^[24]。

1 材料与方法

1.1 一拖三活体靶向诱捕器

针对活体昆虫拍摄,设计改进一种活体水稻害虫诱捕拍摄装置——一拖三活体靶向诱捕器,该装置与山东祥辰科技集团有限公司联合研发。针对传统现有靶向诱捕器存在问题:仅有单个诱捕桶,诱捕效率低;识别功能只能等诱捕桶里昆虫死去滑落才可进行识别。改进后的一拖三靶向诱捕器效率更高,3 个诱捕装置同时进行工作,且诱捕桶为改进活体诱捕桶,可实现对活体水稻害虫进行拍摄,其结构如图 1 和图 2 所示。

该诱捕器通过将工业摄像头控制器等连接 4G 边缘数据网关^[25],可实时传输数据到网站,并可查看识别害虫种类,获取实时虫情数据。通过大数据分析,自动生成虫害发生趋势报告,可以实时看到诱捕器在线状态,进一步提高虫害管理效率,做到水稻虫害及时预防以采取措施。

1.2 诱捕器诱捕工作流程

一拖三靶向诱捕器工作时在水盆式诱捕装置内放置稻纵卷叶螟生物食诱捕剂^[26]对活体水稻害虫进行诱捕,采用红外线检测装置对昆虫进行检测并反馈给控制器,从而触发工业相机对目标昆虫进行拍照识别,实现图像数据采集与智能识别,工作流程如图 3 所示。




图1 一拖三活体靶向诱捕器

Fig. 1 One-to-three live targeted trapping device

1. 金属机箱 2. 太阳能蓄电池 3. 传输线 4. 直杆 5. 水盆式诱捕装置 6. 图像采集装置 7. 三角支架




图2 活体诱捕桶与图像采集装置

Fig. 2 Live trap bucket and image acquisition device

1. 锥筒 2. 第三红外传感器 3. 侧门 4. 斜板 5. 黄色背景板 6. 工业相机 7. 透明圆柱筒 8. 红外传感器




图3 诱捕器诱捕工作流程

Fig. 3 Intelligent identification of workflows

1.3 清晰度对比排序法制作数据集

为制作高质量数据集,提出一种图像逐帧清晰度对比排序法,该方法基于 Intel RealSense D435i 视频信息和 OpenCV^[27] 清晰度对比技术,通过对图像逐帧清晰度对比排序获取最优数据集。由于图像由视频逐帧提取,存在动态模糊,因此采用边缘强度和模糊度 2 种方法进行图像清晰度质量评估。边缘强度是指图像中物体轮廓的清晰度,动态模糊通常会导致图像的边缘模糊或消失^[28],模糊度评分是一类

专门用于定量评估图像模糊程度的指标,通常使用 Brenner 梯度和 Laplacian 方差^[29]。最终,结合边缘强度和模糊度评分计算综合评分。

使用 Canny 算子提取图像边缘,边缘强度评分 S_{edge} 为

$$S_{\text{edge}} = \frac{\sum_{i,j} E(i,j)}{N} \tag{1}$$

式中 $E(i,j)$ ——图像中位置 (i,j) 边缘强度
 N ——图像总像素数

使用 Brenner 梯度和 Laplacian 方差进行模糊度评分,Brenner 梯度通过计算像素强度的变化量化模糊度,公式为

$$S_{\text{Brenner}} = \sum_{i,j} (I(i,j) - I(i-1,j-1))^2 \tag{2}$$

Laplacian 方差衡量图像高频成分,模糊图像通常缺少高频信息,公式为

$$S_{\text{Laplacian}} = \text{Var}(\Delta^2 I(i,j)) \tag{3}$$

模糊度评分为两者加权组合,公式为

$$S_{\text{blur}} = \alpha S_{\text{Brenner}} + \beta S_{\text{Laplacian}} \tag{4}$$

式中 α, β ——边缘强度和拉普拉斯模糊度指标权重

为确定合适的权重组合,本文在初期选取多个图像样本集,并通过人工主观评价进行初步标注,将评分结果与人工清晰度判断进行比较分析,最终选择 $\alpha = 0.6, \beta = 0.4$ 。

结合边缘强度和模糊度评分计算综合评分为

$$S_{\text{total}} = \lambda S_{\text{edge}} - (1 - \lambda) S_{\text{blur}} \tag{5}$$

式中 S_{total} ——图像清晰度评分
 λ ——权重,取 0 ~ 1

为确定最优 λ 取值,在初步试验中以 0.1 为步长,在 $\lambda \in [0.1, 0.9]$ 范围内进行遍历测试,并通过与人工主观评分对比,计算识别准确率与一致性指标,最终选择 $\lambda = 0.7$ 作为最优参数配置。

S_{total} 值高则图像清晰,将所有图像进行该值计算,然后对所有值进行由大到小排序,在顺序排好的图像中删除模糊不清图像,最终得到 2 521 幅高质量数据集,图 4 为不同姿态稻纵卷叶螟图像片。

1.4 数据集扩增

目前稻纵卷叶螟原始图像数据集有 2 521 幅,无法满足模型训练需求。为提高模型识别精度,采用数据增强技术对原始数据集进行扩增。为获取高质量训练样本,对原始样本进行镜像翻转、多角度旋转、明暗调节和随机遮挡等转换进行样本扩增,最终数据集达到 7 563 幅图像。数据集扩增后用 labelImg 标注,将数据集划分为训练集、验证集和测试集,其比例为 7:2:1。数据增强效果如图 5 所示。



图 4 不同姿态稻纵卷叶螟图像

Fig. 4 Picture of rice leaf roller in different poses



图 5 数据增强效果

Fig. 5 Data enhancement renderings

2 活体水稻害虫检测方法

由于活体水稻害虫具有检测目标小、姿态各异的特点,YOLO v8n 模型存在漏检、错检、精度低的问题^[30],针对以上问题,对 YOLO v8n 进行改进。

2.1 YOLO v8n 网络结构改进

(1)针对稻纵卷叶螟在诱捕桶中姿态各异的问题,引入 CBAM 注意力机制^[31-33],使模型聚焦于其飞行姿态,并加入自适应机制动态调整通道和空间注意力强度,利用自注意力机制为不同位置和通道分配权重。

(2)对于稻纵卷叶螟在图像中目标较小,引入

自适应空间特征融合 (ASFF) 技术^[34-35],将 ASFF 加入 AFPN 中,即在 AFPN 的特征融合阶段引入 ASFF 机制,改进 AFPN,通过增加分辨率更高的 P2 层 (AFPN-P2),增强对小目标的感知能力,同时减少非相邻特征层之间的语义差异,提升检测精度。

改进 YOLO v8n 结构图如图 6 所示。

2.2 引入自适应动态调整 CBAM

通道空间注意力机制结合通道和空间的注意力计算,有助于聚焦关键特征。但是,传统注意力机制通常是静态,未能对动态自适应输入特征。针对稻纵卷叶螟在复杂背景下识别需求,提出一种自适应




Fig. 6 Improved YOLO v8 structure diagram

动态调整方案,使通道和空间注意力更加灵活,以便提高对活体稻纵卷叶螟的检测精度。

通道注意力模块(Channel attention module, CAM)主要基于全局平均池化和最大池化获取全局特征,但在各通道之间的加权是固定的。为实现动态调整,本文引入自注意力机制(Self - Attention)增强通道注意力,使其权重能够根据每个通道特征动态生成。

首先,给定输入特征图 $X \in R^{HWC}$,通过全局平均池化和全局最大池化获得每个通道的静态特征表示,即

$$\begin{cases} Z_{\text{avg}} = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W X_{i,j,c} \\ Z_{\text{max}} = \max_{i,j} X_{i,j,c} \end{cases} \quad (6)$$

式中 Z_{avg} ——全局平均池化
 Z_{max} ——全局最大池化
 H ——特征图的高度
 W ——特征图的宽度

加入自注意力机制动态调整通道权重,将特征 Z_{avg} 和 Z_{max} 通过自注意力机制进行加权,公式为

$$Z_{\text{dynamic}} = \text{SelfAttention}(Z_{\text{avg}} + Z_{\text{max}}) \quad (7)$$

式中 Z_{dynamic} ——动态通道权重

$$Z_{\text{ca}} = \sigma(C_2(\text{ReLU}(C_1(Z_{\text{avg}} + Z_{\text{max}} + Z_{\text{dynamic}})))) \quad (8)$$

这样生成的通道注意力能够根据输入特征不同,自适应地调整各通道的权重,从而提升小目标检测效果。

同理空间注意力模块(Spatial attention module, SAM)通常是通过通道池化得到空间特征计算每个位置的注意力分布。最终空间注意力图计算公式为

$$Z_{sa} = \sigma(Conv_5(Z_{avg} + Z_{max} + Z_{dynamic})) \quad (9)$$

在通道和空间注意力生成之后,可以对 2 种注意力进行自适应融合。为实现自适应融合,在通道和空间注意力之间引入加权参数 α_1 , 调节二者权重,即

$$Z_{\text{fused}} = \beta_1 Z_{\text{ca}} + (1 - \alpha_1) Z_{\text{sa}} \quad (10)$$

在训练过程中进行更新,以实现通道和空间注意力的自适应组合,从而使得模型在不同场景中能够灵活调整注意力的权重分布,提高检测精度。最终将融合后的注意力图作用于输入特征图,得到加权输出特征图为

$$X_{\text{out}} = X \odot Z_{\text{fused}} \quad (11)$$

改进的 CBAM 机制结构如图 7 所示。通道和空间细化流程如图 8 所示。




图7 改进的 CBAM
Fig.7 Improved CBAM




Fig. 8 Channel thinning and space thinning processes

为验证改进 CBAM 的优势,与当前热门注意力机制进行对比试验,加入 SE - Net、ECA - Net 注意力机制,注意力机制对比试验结果如表 1。由表 1

可以看出,加入自适应机制的 CBAM 在平均精度均值、精确率以及召回率较其他注意力机制要高,体现其在增强特征表达和提升小目标识别精度方面的显著优势。

表 1 注意力机制试验结果

Tab. 1 Comparative test results of attention mechanism

模型	平均精度均值 (mAP@0.5)	精确率	召回率
YOLO v8n	86.70	86.2	85.6
YOLO v8n + SE	88.24	86.7	85.2
YOLO v8n + ECA	87.66	88.2	86.8
YOLO v8n + CBAM	89.10	90.4	88.5
YOLO v8n + CBAM - self	91.85	91.7	90.9

动态调整通道和空间注意力方案通过在 CAM 和 SAM 中引入自注意力机制,使得模型注意力生成过程可以自适应地响应输入特征的不同信息,提升对小目标的检测能力。本文方法在通道和空间维度上引入动态调整机制,使得网络能够更灵活地捕捉到小目标的特征,从而提高检测精度。

2.3 引入 AFPN - P2 结构

ASFF(Adaptive spatial feature fusion)有效地解决单阶段目标检测器中特征金字塔的不一致性问题。特征金字塔中不同尺度的特征图之间通常存在冲突,这些冲突可能会干扰训练期间的梯度计算,进而降低金字塔特征的有效性。ASFF 通过自适应学习优化特征图融合过程,使网络能够在空间上过滤掉无用的特征信息,仅保留有用信息,从而提升特征的尺度不变性。在特征金字塔中融合 4 个不同尺度特征,即 ASFF-4,图 9 为 4 个不同层级特征图自适应空间融合网络结构。




图 9 ASFF-4 网络结构

Fig.9 ASFF-4 network structure

ASFF 核心流程包括恒等缩放和自适应融合,学习到的权重随后被用于加权融合不同尺度的特征图,以生成最终的融合特征。ASFF-4 自适应融合

公式为

$$F_{ij}^l = \alpha_{ij}^l x_{ij}^{1-l} + \beta_{ij}^l x_{ij}^{2-l} + \gamma_{ij}^l x_{ij}^{3-l} + \delta_{ij}^l x_{ij}^{4-l} \quad (12)$$

式中 x_{ij}^{n-l} ——将第 n 层级特征图调整为与第 l 层级特征图相同分辨率后得到的第 (i,j) 个位置上向量

$\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l, \delta_{ij}^l$ ——输出特征图 $\alpha^l, \beta^l, \gamma^l, \delta^l$ 中第 (i,j) 个位置上向量及 4 个不同层级特征图的空间权重

对于第 l 层级特征图中第 (i,j) 个位置上的空间重要性权重,由网络自适应地学习,满足以下条件

$$\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l + \delta_{ij}^l = 1$$
$$(\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l, \delta_{ij}^l \in [0.1]) \quad (13)$$

YANG 等^[36]提出 AFPN(自适应特征金字塔网络)通过引入 ASFF(自适应空间特征融合)抑制不同层级特征图之间矛盾,确保有效信息保留并减少无关信息干扰。同时,AFPN 采用一种渐进式特征层融合策略,融合相邻低层特征,然后逐步将较高级别特征图纳入融合过程。P2 层通常代表卷积网络中较低层级,具有较高的空间分辨率。P2 层分辨率高于 P3、P4 和 P5 层,能保留更多细节,有助于检测稻纵卷叶螟等小目标,提高检测精度。

AFPN-P2 网络结构如图 10 所示。ASFF 先将低分辨率 P2 和 P3 融合,再继续与 P4 层特征层融合,最后 P2 到 P5 层 4 个特征层进行融合,该渐进式融合策略借助 ASFF 机制,有效缓解多尺度特征图之间的信息干扰,增强有用信息在融合过程中的保留能力,同时减小非相邻层之间的语义鸿沟,进而提升对小目标的检测精度。




图 10 AFPN-P2 网络结构

Fig. 10 AFPN-P2 network structure

为确保 P2 层特征图能够与其他层(如 P3、P4、P5)兼容,通过适当采样和融合策略,使得 P2 层高分辨率特征图能够有效地与较低分辨率特征图(如 P3、P4)进行融合。P2 层特征图通过公式(14)生成。

$$F_{P_2}' = \text{UpSample}(F_{P_3}, r_2) \quad (14)$$

式中 F_{P_3} ——P3 层特征图

r_2 ——上采样比例因子,将 P3 层特征图映射到 P2 层高分辨率空间

改进后 P2 层不仅能够提供高分辨率特征图,还通过 AFPN 中自适应融合模块与其他层级特征图进

行加权融合。自适应融合机制能够根据任务需求和数据特性,自动学习每个特征图的重要性并调整融合权重。给定不同层级的特征图 F'_{p_k} (其中 $k \in \{2, 3, 4, 5\}$),通过加权平均方式将各层级的特征图融合成最终输出特征图,公式为

$$F_{\text{fused}} = \sum_{k=2}^5 W_{p_k} F'_{p_k} \tag{15}$$

式中 W_{p_k} ——由网络在训练过程中学习得到的自适应权重,表示每个层级特征图对最终融合结果的贡献

引入 P2 层使 YOLO v8n 能捕捉更多细节,提升水稻害虫等小目标的检测精度。同时,借助 AFPN 的自适应融合机制,P2 层的高分辨率特征图能够与低分辨率的特征图有效融合,增强模型对不同尺度目标的综合感知能力。

3 试验结果与分析

3.1 试验环境及评价指标

使用 Anaconda 集成开发环境结合 PyTorch 深度学习框架进行模型构建,操作系统为 Windows 11 专业版,CPU 型号为 Intel(R) Core(TM) i9-14900k@3.0 GHz,单核 5.40 GHz, GPU 型号为 NVIDIA GeForce RTX4090,运行内存为 128 GB,1 T 固态,编程语言为 Python 3.11,训练过程中的模型参数设置:分辨率为 640 像素 × 640 像素,批量大小为 64,迭代次数为 200,优化器为 SGD,初始学习率为 0.01。

为定量评估模型在活体水稻害虫识别中的性能,采用平均精度均值 (mAP)、检测速度和模型内存占用量作为主要评估指标。精确率 (Precision) 可衡量模型正确检测到的害虫个体与所有检测到的目标害虫的比率,而召回率 (Recall) 则表示模型成功识别出的害虫个体与实际存在害虫的比率。对于活体水稻害虫的识别任务,精确率的检测和较高的召回率尤为重要,因为害虫个体较小,必须确保高精确率和召回率以避免漏检。

3.2 模型对比试验

为评估改进 YOLO v8n 模型在活体稻纵卷叶螟识别检测中表现,引入当前主流目标检测模型,包括 Faster R-CNN、YOLO v5n、YOLO v7、YOLO v9n、YOLO v10n、YOLO 11n 以及 YOLO v12n 和 YOLO v8n,与改进 YOLO v8n 模型进行对比试验,不同模型试验结果见表 2。

从表 2 可以看出,改进的 YOLO v8n 模型平均精度均值 (mAP@0.5% 为 95.65%)、精确率 (94.80%)、召回率 (94.25%) 等指标均表现优异。其中,改进的 YOLO v8n 相较于 Faster R-CNN、

表 2 不同模型试验结果

Tab.2 Test results of different models

模型	mAP@0.5/	精确率/	召回率/	检测速度/
	%	%	%	(f·s ⁻¹)
Faster R-CNN	84.45	83.95	83.59	12
YOLO v5n	79.63	79.13	78.24	145
YOLO v7	75.22	74.76	74.16	180
YOLO v8n	86.70	86.27	85.64	200
YOLO v9n	91.66	91.21	90.82	156
YOLO v10n	93.72	94.17	93.61	142
YOLO 11n	93.20	93.59	92.96	135
YOLO v12n	85.87	84.53	83.25	165
改进 YOLO v8n	95.65	94.80	94.25	185

YOLO v5n、YOLO v7、YOLO v8n、YOLO v9n、YOLO v10n、YOLO 11n 以及 YOLO v12n 的 mAP@0.5 分别提升 11.20、16.02、20.43、8.95、3.99、1.93、2.45、9.78 个百分点;精确率分别提升 10.95、15.67、20.20、8.53、3.59、0.63、1.21、10.27 个百分点;召回率分别提升 10.66、16.01、20.09、8.61、3.43、0.64、1.29、11 个百分点。这些结果表明,改进后的 YOLO v8n 在图像的快速检测任务中具有显著优势,能够对稻田活体水稻害虫实时检测,并及时反馈检测情况。

从表 2 可以看出,改进 YOLO v8n 模型在水稻活体害虫识别任务中的性能表现。改进后的模型加入自适应 CBAM 模块和添加 P2 层 AFPN,各项性能指标都有很大提高。

不同模型检测效果如图 11 所示,试验结果表明,改进 YOLO v8n 模型对于水稻活体虫害的检测能力具有明显提升,更加准确地定位并识别稻纵卷叶螟小型害虫个体,预测框与真实目标的重合度更高,其他模型在复杂背景和虫体姿态变化情况下容易出现漏检或精确度偏低的问题,而改进的 YOLO v8n 模型能准确捕捉害虫边缘特征,显著降低误检率,同时不仅提高了检测准确性,还能实时为虫害监测提供技术支持。

3.3 消融试验

为进一步研究改进后模型对水稻害虫的识别效果,使用 7 组不同的模型进行消融试验,利用平均精度均值对试验结果进行分析,从而明确各模块对模型检测性能的提升效果,不同模型消融试验结果如表 3 所示。

由表 3 可以看出,在 YOLO v8n 模型基础上,仅引入 CBAM 模块时,mAP 提升 2.40 个百分点;加入 AFPN 模块时,mAP 提升 5.77 个百分点;结合 CBAM 和 AFPN 模块时,mAP 提升 7.25 个百分点;替换为自适应 CBAM-self 模块时,mAP 提升 5.15 个百分点;单独




图 11 不同模型检测效果

Fig. 11 Each model inspection effect

表 3 不同模型消融试验结果

Tab. 3 Comparison of ablation test results				
模型	平均精度均值 (mAP@0.5/%)	精确 率/%	召回 率/%	浮点运 算量
YOLO v8n	86.70	86.2	85.6	8.20×10^9
YOLO v8n + CBAM	89.10	90.4	88.5	8.20×10^9
YOLO v8n + CBAM - self	91.85	91.7	90.9	8.40×10^9
YOLO v8n + AFPN	92.47	91.9	90.3	8.90×10^9
YOLO v8n + AFPN - P2	91.20	91.0	89.7	1.71×10^{10}
YOLO v8n + CBAM + AFPN	93.95	93.0	91.5	1.67×10^{10}
YOLO v8n + CBAM - self + AFPN - P2	95.65	94.8	94.3	1.76×10^{10}

3.4 田间试验

为验证本文所提出的改进 YOLO v8n 模型在实际应用中的效果与适用性,在稻田自然环境条件下进行田间测试,评估该模型在稻田环境中对稻纵卷叶螟识别精度。试验基地和所安装设备如图 12 所示。



图 12 试验基地和所安装设备

Fig. 12 Working equipment drawing

加入 P2 层的 AFPN 模块后,mAP 显著提升 4.50 个百分点;当结合 CBAM - self 和 P2 层的 AFPN 模块(改进 YOLO v8n 模型)时,mAP 达到最高值 95.65%,相比 YOLO v8n 模型提升 8.95 个百分点。

通过消融试验结果可得,AFPN 模块和加入 P2 层的 AFPN 模块对模型性能提升作用尤为显著,而结合自适应的 CBAM - self 和 P2 层的 AFPN 模块后,模型综合性能达到最佳。表明本文所提出的改进 YOLO v8n 模型优化方案对稻田活体虫害检测任务具有较强的实用性和有效性。

表 4 田间试验数据

Tab. 4 Field trial data								
试验田 序号	稻纵卷叶螟 识别个数/只	诱捕到稻纵卷 叶螟总数/只	诱捕到昆虫 总数/只	其中捕捉到 益虫总数/只	蜘蛛数量/ 只	寄生蜂数量/ 只	食蚜蝇数量/ 只	精确 率/%
1	19	21	26	3	2	1	0	90.48
2	21	22	25	1	1	0	0	95.45
3	15	16	24	5	1	3	1	93.75
4	10	12	19	5	3	0	2	83.33
5	12	16	22	4	0	2	2	75.00
6	13	16	23	5	3	1	1	81.25

图 13 为活体水稻害虫识别结果,可以清晰地看出前 3 列采用原 YOLO v8n 模型有些图像识别不出或识别精度低,后 3 列采用改进的 YOLO v8n 模型所有图像都可以识别且精度高。

田间试验在山东省济南市槐荫区五洲都市农业科技有限公司农场水稻田进行,时间为 2024 年 7—8 月晴朗天,试验按照每 0.67 hm² 地为 1 组,每组放置 1 个靶向诱捕器,通过对比性诱捕剂和食诱捕剂的诱捕效果,使用深圳百乐宝生物农业科技有限公司等生产的生物食诱捕剂,诱捕器内放置稻纵卷叶螟靶向食诱捕剂,试验田 1、2、3 采用改进 YOLO v8n 模型,试验田 4、5、6 采用 YOLO v8n 模型,试验结果如表 4 所示。

由表 4 可以看出,试验田 1、2、3 稻纵卷叶螟精确率分别为 90.48%、95.45%、93.75%;试验田 4、5、6 稻纵卷叶螟精确率分别为 83.33%、75.00%、81.25%。由此可见,改进 YOLO v8n 模型在实际田




图 13 活体水稻害虫识别结果

Fig. 13 Identification of live rice pests

间环境下识别精度显著优于原模型,尤其在试验田 1、2、3 中,精确率均超过 90%,展现出较高稳定性和准确性。相比之下,使用 YOLO v8n 模型装置在试验田 4、5、6 表现出的精确率相对较低,最高为 83.33%,在识别条件较为复杂或目标特征模糊的情况下,表现出一定局限性。表明改进 YOLO v8n 模型能够更好地适应田间环境的多样性,对稻纵卷叶螟识别更加准确。

综合来看,改进 YOLO v8n 模型结合一拖三活体靶向诱捕器,在田间试验中表现出优异识别能力,与通过数据集训练得出的结果基本一致,进一步验证改进的模型有效性与实用性。改进模型显著弥补了原模型在实际应用中不足,为稻田活体昆虫实时检测提供技术支持,具备推广应用的潜力和价值。未来可进一步优化设备的部署方式与模型参数,以适应更复杂的田间环境,提高识别精度和效率。

4 结论

(1) 基于 YOLO v8n 模型提出改进方案,通过引

入 CBAM-self 模块、AFPN 模块以及增加 P2 层,显著提升模型在活体水稻害虫检测任务中的性能。改进 YOLO v8n 模型在 mAP@0.5、精确率和召回率方面表现优异, mAP@0.5 达到 95.65%, 精确率为 94.80%, 召回率为 94.25%, 表明改进后模型在稻田虫害检测任务中具有显著优势。

(2) 通过田间试验验证,改进 YOLO v8n 模型在稻田环境下对水稻害虫的检测表现优异,能够在不同虫害密度下准确地完成害虫识别任务。同时,消融试验结果表明,AFPN 模块和增加 P2 层 AFPN 模块对模型检测性能提升效果尤为显著,其中单独引入 P2 层 AFPN 模块时 mAP@0.5 提升 4.50 个百分点,而结合 CBAM-self 与 P2 层的 AFPN 模块后, mAP@0.5 达到最高值 95.65%, 模型性能达到最佳。

(3) 综合试验结果表明,改进 YOLO v8n 模型能够满足稻田活体害虫实时检测需求,为精准农业和稻田作业质量的实时监测提供重要技术支持。

参 考 文 献

[1] 刘双喜,刘思涛,屈彗星,等. 基于 MS-YOLO v7 的多尺度稻飞虱识别分类方法[J]. 农业机械学报,2023,54(增刊1): 212-221.

LIU Shuangxi, LIU Sitao, QU Huixing, et al. Multi-scale rice planthopper image recognition and classification based on lightweight MS-YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 212-221. (in Chinese)

[2] 刘万才,陆明红,黄冲,等. 水稻重大病虫害跨境跨区域监测预警体系的构建与应用[J]. 植物保护,2020,46(1): 87-92.

LIU Wancai, LU Minghong, HUANG Chong, et al. Construction and application of cross-border and cross regional monitoring and early warning system for major rice diseases and insect pests[J]. Plant Protection, 2020, 46(1): 87-92. (in Chinese)

[3] 蒲建,李明阳,王浩,等. 四川省稻区越冬代二化螟寄生蜂资源研究[J]. 应用昆虫学报,2024,61(5): 1091-1103.

PU Jian, LI Mingyang, WANG Hao, et al. Parasitoids of the overwintering population of *Chilo suppressalis* in Sichuan Province [J]. Chinese Journal of Applied Entomology, 2024, 61(5): 1091-1103. (in Chinese)

[4] 邹修国,丁为民,刘德营,等. 基于 4 种不变矩和 BP 神经网络的稻飞虱分类[J]. 农业工程学报,2013,29(18): 171-178.

ZOU Xiuguo, DING Weimin, LIU Deying, et al. Classification of rice planthopper based on invariant moments and BP neural networks[J]. Transactions of the CSAE, 2013, 29(18): 171-178. (in Chinese)

- [5] 刘德营,王家亮,林相泽,等. 基于卷积神经网络的白背飞虱识别方法[J]. 农业机械学报,2018,49(5):51–56.
LIU Deying, WANG Jialiang, LIN Xiangze, et al. Automatic identification method for *Sogatella furcifera* based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(5):51–56. (in Chinese)
- [6] 慕君林,马博,王云飞,等. 基于深度学习的农作物病虫害检测算法综述[J]. 农业机械学报,2023,54(增刊2):301–313.
MU Junlin, MA Bo, WANG Yunfei, et al. Review of crop disease and pest detection algorithms based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(Supp. 2):301–313. (in Chinese)
- [7] 刘文定,田洪宝,谢将剑,等. 基于全卷积神经网络的林区航拍图像虫害区域识别方法[J]. 农业机械学报,2019,50(3):179–185.
LIU Wending, TIAN Hongbao, XIE Jiangjian, et al. Identification methods for forest pest areas of UAV aerial photography based on fully convolutional networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(3):179–185. (in Chinese)
- [8] 马鹏鹏,周爱明,姚青,等. 图像特征和样本量对水稻害虫识别结果的影响[J]. 中国水稻科学,2018,32(4):405–414.
MA Pengpeng, ZHOU Aiming, YAO Qing, et al. Influence of image features and sample sizes on rice pest identification[J]. Chinese Journal of Rice Science, 2018,32(4):405–414. (in Chinese)
- [9] 李波,刘占宇,黄敬峰,等. 基于PCA和PNN的水稻病虫害高光谱识别[J]. 农业工程学报,2009,25(9):143–147.
LI Bo, LIU Zhanyu, HUANG Jingfeng, et al. Hyperspectral identification of rice diseases and pests based on principal component analysis and probabilistic neural network[J]. Transactions of the CSAE, 2009,25(9):143–147. (in Chinese)
- [10] 王金星,马博,王震,等. 基于改进Mask R-CNN的苹果园害虫识别方法[J]. 农业机械学报,2023,54(6):253–263,360.
WANG Jinxing, MA Bo, WANG Zhen, et al. Pest identification method in apple orchard based on improved Mask R-CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(6):253–263,360. (in Chinese)
- [11] RAHMAN C R, ARKO P S, ALI M E, et al. Identification and recognition of rice diseases and pests using convolutional neural networks[J]. Biosystems Engineering, 2020, 194:112–120.
- [12] 毛罕平,张红涛. 储粮害虫图像识别的研究进展及展望[J]. 农业机械学报,2008,39(4):175–179,186.
MAO Hanping, ZHANG Hongtao. Research progress and prospect for image recognition of stored-grain pests[J]. Transactions of the Chinese Society for Agricultural Machinery, 2008,39(4):175–179,186. (in Chinese)
- [13] SAUFI A. White rice stem borer pest detection system using image-based convolution neural network[J]. Procedia Computer Science, 2024,245:518–527.
- [14] 谭泗桥,陈涵,朱磊,等. 基于改进YOLO v8m的稻田害虫识别方法[J]. 农业工程学报,2025,41(2):185–195.
TAN Siqiao, CHEN Han, ZHU Lei, et al. Identifying pests in rice fields using improved YOLO v8m[J]. Transactions of the CSAE, 2025,41(2):185–195. (in Chinese)
- [15] 林相泽,朱赛华,张俊媛,等. 基于迁移学习和Mask R-CNN的稻飞虱图像分类方法[J]. 农业机械学报,2019,50(7):201–207.
LIN Xiangze, ZHU Saihua, ZHANG Junyuan, et al. Rice planthopper image classification method based on transfer learning and Mask R-CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(7):201–207. (in Chinese)
- [16] 曾伟辉,张文凤,陈鹏,等. 基于SCResNeSt的低分辨率水稻害虫图像识别方法[J]. 农业机械学报,2022,53(9):277–285.
ZENG Weihui, ZHANG Wenfeng, CHEN Peng, et al. Low-resolution rice pest image recognition based on SCResNeSt[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(9):277–285. (in Chinese)
- [17] 梁勇,邱荣洲,李志鹏,等. 基于YOLO v5和多源数据集的水稻主要害虫识别方法[J]. 农业机械学报,2022,53(7):250–258.
LIANG Yong, QIU Rongzhou, LI Zhipeng, et al. Identification method of major rice pests based on YOLO v5 and multi-source datasets[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(7):250–258. (in Chinese)
- [18] 赵辉,黄鏢,王红君,等. 基于改进YOLO v7的农田复杂环境下害虫识别算法研究[J]. 农业机械学报,2023,54(10):246–254.
ZHANG Hui, HUANG Biao, WANG Hongjun, et al. Pest identification method in complex farmland environment based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(10):246–254. (in Chinese)
- [19] 何泽坤,黄操军,许善祥,等. 基于改进YOLO v5的水稻害虫识别方法[J]. 江苏农业科学,2025,53(5):223–230.
HE Zeshen, HUANG Caojun, XU Shanxiang, et al. Identification method for rice pests based on improved YOLO v5[J]. Jiangsu Agricultural Sciences, 2025,53(5):223–230. (in Chinese)
- [20] 王泰华,郭亚州,张家乐,等. 基于改进YOLO v5s的水稻害虫识别研究[J]. 农业机械学报,2024,55(11):39–48.
WANG Taihua, GUO Yazhou, ZHANG Jiale, et al. Rice pest identification based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(11):39–48. (in Chinese)
- [21] 靳新宇,于复兴,索依娜,等. 基于改进YOLOv8的水稻病害检测算法[J]. 江苏农业学报,2025,41(3):537–548.
JIN Xinyu, YU Fuxing, SUO Yina, et al. Rice disease detection algorithm based on improved YOLOv8[J]. Jiangsu Journal of Agricultural Sciences, 2025,41(3):537–548. (in Chinese)
- [22] TANG Z, LU J, CHEN Z, et al. Improved Pest-YOLO: real-time pest detection based on efficient channel attention mechanism and transformer encoder[J]. Ecological Informatics, 2023,78:102340.

[23] WANG N, FU S, RAO Q, et al. Insect – YOLO: a new method of crop insect detection[J]. Computers and Electronics in Agriculture, 2025, 232: 110085.

[24] 韩瑞珍, 何勇. 基于计算机视觉的大田害虫远程自动识别系统[J]. 农业工程学报, 2013, 29(3): 156 – 162.
HAN Ruizhen, HE Yong. Remote automatic identification system of field pests based on computer vision[J]. Transactions of the CSAE, 2013, 29(3): 156 – 162. (in Chinese)

[25] ZHOU Z, YU D, CHEN M, et al. An edge intelligence-based model deployment method for CNC systems[J]. Journal of Manufacturing Systems, 2024, 74: 716 – 751.

[26] 何毅方, 顾士光, 朱彩华, 等. 稻纵卷叶螟双性引诱剂、生物食诱剂田间药效试验简报[J]. 上海农业科技, 2023(2): 35 – 38.
HE Yifang, GU Shiguang, ZHU Caihua, et al. Field efficacy trial of bisexual attractant and biological food attractant of rice leaf roller[J]. Shanghai Agricultural Science and Technology, 2023(2): 35 – 38. (in Chinese)

[27] 李越. OpenCV 应用现状综述[J]. 工业控制计算机, 2017, 30(7): 123 – 124, 126.
LI Yue. Research on present status review of OpenCV[J]. Industrial Control Computer, 2017, 30(7): 123 – 124, 126. (in Chinese)

[28] 王玲, 孟建瑶. 基于特征变权的动态模糊特征选择算法[J]. 计算机研究与发展, 2018, 55(5): 893 – 907.
WANG Ling, MENG Jianyao. Dynamic fuzzy features selection based on variable weight[J]. Journal of Computer Research and Development, 2018, 55(5): 893 – 907. (in Chinese)

[29] 王宇轩, 梁潇, 吴奋陟, 等. 结合多区域窗口的梯度阈值清晰度评价方法[J]. 空间控制技术与应用, 2025, 51(1): 43 – 53.
WANG Yuxuan, LIANG Xiao, WU Fenzhi, et al. The method of gradient thresholds sharpness evaluating combined multi-region window[J]. Aerospace Control and Application, 2025, 51(1): 43 – 53. (in Chinese)

[30] 刘鹏, 张天翼, 冉鑫, 等. 基于 PBM – YOLOv8 的水稻病虫害检测[J]. 农业工程学报, 2024, 40(20): 147 – 156.
LIU Peng, ZHANG Tianyi, RAN Xin, et al. Detecting rice disease using PBM – YOLOv8[J]. Transactions of the CSAE, 2024, 40(20): 147 – 156. (in Chinese)

[31] 蒲攀, 刘勇, 张越, 等. 融合动态词典特征和 CBAM 的苹果病虫害命名实体识别方法[J]. 农业机械学报, 2024, 55(12): 333 – 343.
PU Pan, LIU Yong, ZHANG Yue, et al. Named entity recognition of apple diseases and pests based on dynamic dictionary features and CBAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 333 – 343. (in Chinese)

[32] 李兆东, 章艳芳, 汪蕴红, 等. 基于 YC – YOLO v7 模型的油菜幼苗株数识别方法[J]. 农业机械学报, 2024, 55(12): 322 – 332.
LI Zhaodong, ZHANG Yanfang, WANG Yunhong, et al. Identification of rapeseed seedling number based on YC – YOLO v7 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 322 – 332. (in Chinese)

[33] 张楠楠, 张晓, 白铁成, 等. 基于 CBAM – YOLO v7 的自然环境下棉叶病虫害识别方法[J]. 农业机械学报, 2023, 54(增刊 1): 239 – 244.
ZHANG Nannan, ZHANG Xiao, BAI Tiecheng, et al. Identification method of cotton leaf pests and diseases in natural environment based on CBAM – YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 239 – 244. (in Chinese)

[34] 苗荣慧, 李港澳, 黄宗宝, 等. 基于 YOLO v7 – ST – ASFF 的复杂果园环境下苹果成熟度检测方法[J]. 农业机械学报, 2024, 55(6): 219 – 228.
MIAO Ronghui, LI Gang’ao, HUANG Zongbao, et al. Maturity detection of apple in complex orchard environment based on YOLO v7 – ST – ASFF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 219 – 228. (in Chinese)

[35] 陈志旺, 李宗轩, 吕昌昊, 等. 基于 HRNet 和 ASFF 的特征融合目标检测算法[J]. 控制与决策, 2024, 39(10): 3207 – 3215.
CHEN Zhiwang, LI Zongxuan, LÜ Changhao, et al. A feature fusion objection detection algorithm based on HRNet and ASFF[J]. Contral and Decision, 2024, 39(10): 3207 – 3215. (in Chinese)

[36] YANG G, LEI J, ZHU Z, et al. AFPN: asymptotic feature pyramid network for object detection[C] // 2023 IEEE International Conference on Systems, Man, and Cybernetics(SMC). IEEE, 2023: 2184 – 2189.