

doi:10.6041/j.issn.1000-1298.2025.06.022

基于 YOLO v8 - STSF 的多类别害虫识别算法 与监测系统研究

王兴旺^{1,2} 查海涅² 卢浩男¹ 王禹彬¹ 吴东昇¹ 王旭峰³ 胡 灿³ 陈学永¹

(1. 福建农林大学机电工程学院, 福州 350108; 2. 安庆师范大学计算机学院, 安庆 246000;

3. 塔里木大学机械电气化工程学院, 阿拉尔 843300)

摘要: 水稻害虫危害十分巨大, 不仅对水稻造成直接的生理破坏, 还传播病害, 严重时导致稻田绝收, 造成难以估量的损失。水稻害虫精准识别与实时监测是减少农业损失的关键, 针对虫情测报灯图像中害虫密集、体态差异细微及小目标漏检等问题, 提出一种基于 YOLO v8 - STSF 模型的水稻害虫智能识别方法。通过引入 Swin Transformer 模块增强骨干网络的多尺度特征提取能力, 结合分布移位卷积 (DSCConv) 优化颈部网络特征融合, 并采用 Focal EIou 损失函数提升密集小目标定位精度。构建了包含多类水稻害虫的 7 000 幅图像数据集进行识别验证, YOLO v8 - STSF 模型在测试集上的精确率为 95.45%、召回率为 90.45%、F1 值为 90.03%, 较原 YOLO v8 模型分别提升 2.13、0.33、3.09 个百分点, 在 PC 端的推理速度为 32 f/s, 满足实时需求。同时以 Web 端监测系统为基础, 设计基于 Android 移动端的虫情监测系统, 在田间测试中系统平均响应时间为 1.38 s, 识别准确率为 96.34%, 漏检率为 3.86%。研究结果可为水稻害虫精准防控提供高效技术支持, 推动农业病虫害监测智能化发展。

关键词: 多类别害虫; 害虫识别; YOLO v8 - STSF; 监测系统; Android

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2025)06-0228-09

OSID:



Multi-category Pest Identification Algorithm and Monitoring System Based on YOLO v8 - STSF

WANG Xingwang^{1,2} ZHA Hainie² LU Haonan¹ WANG Yubin¹ WU Dongsheng¹ WANG Xufeng³
HU Can³ CHEN Xueyong¹

(1. College of Mechanical and Electrical Engineering, Fujian Agriculture and Forestry University, Fuzhou 350108, China

2. College of Computer Science, Anqing Normal University, Anqing 246000, China

3. College of Mechanical and Electronic Engineering, Tarim University, Alar 843300, China)

Abstract: Rice pests critically threaten rice cultivation by inflicting direct physiological damage, spreading diseases, and potentially causing catastrophic field extinction, leading to significant agricultural losses. To address challenges such as dense pest clusters, subtle morphological variations, and frequent small-target missed detections in pest detection lamp images, an intelligent recognition method was proposed by using an enhanced YOLO v8 - STSF model. Key innovations included integrating a Swin Transformer module to boost backbone network multi-scale feature extraction, optimizing neck network feature fusion via distribution shift convolution (DSCConv), and adopting the Focal EIou loss function to enhance small-target localization. Validated on a 7 000-image multi-species pest dataset, the improved model achieved 95.45% of precision, 90.45% of recall, and 90.03% of F1-score, surpassing the original YOLO v8 by 2.13, 0.33, and 3.09 percentage points, respectively, while operating at 32 f/s for real-time PC-based monitoring. A dual-platform system (Web and Android mobile) demonstrated field performance with 1.38 s average response time, 96.34% of accuracy, and 3.86% of missed detection rate. This system can provide an efficient solution for precision pest control and advance intelligent agricultural monitoring.

Key words: multi-category pests; pest identification; YOLO v8 - STSF; monitoring system; Android

收稿日期: 2025-03-18 修回日期: 2025-04-29

基金项目: 安徽省科技重大专项 (202203a06020007)、福建省重点科技创新研究项目 (2023XQ005) 和安徽省高校创新团队项目 (2023AH010039)

作者简介: 王兴旺 (1994—), 男, 博士生, 主要从事农业信息化和农业智能装备研究, E-mail: 22412098002@fafu.edu.cn

通信作者: 陈学永 (1970—), 男, 教授, 博士生导师, 主要从事农业信息智能感知技术与装备研究, E-mail: 13905001093@163.com

0 引言

水稻是中国主要粮食作物之一,水稻害虫(如稻飞虱、二化螟、稻纵卷叶螟等)通过吸食汁液、蛀食茎秆或破坏叶片,导致水稻光合作用受阻、养分流失,严重时造成减产甚至绝收^[1-4],全国每年因水稻害虫造成的直接经济损失达数十亿元。因此水稻害虫的防治极为重要,害虫防治离不开精准的识别和分类,通过早期识别和分类害虫^[5],可以精准施药,降低防治成本,同时避免因虫害导致的减产和经济损失。

早期害虫图像分类与识别通过机器视觉技术实现^[6]。陈月华等^[7]使用SVM分类器和基于K-均值聚类的分类方法对小麦害虫进行自动识别。邱道尹等^[8]使用神经网络分类器对常见的9种大田害虫进行分类,并设计了大田害虫实时检测系统。然而,传统机器视觉因依赖人工特征和有限泛化能力,难以应对害虫识别的复杂需求。因此需要更加快速准确的识别方法来对害虫进行识别分类。

随着深度学习技术的发展,深度学习卷积神经网络的使用已成为标准的分类与检测研究方法。经典模型如YOLO、Faster R-CNN、SSD和Mask-RCNN^[9-12]等被用于害虫分类与识别,与传统方法相比,表现出更好的鲁棒性和泛化能力^[13-14]。肖德琴等^[15]利用Faster R-CNN并改进其特征网络以提取目标图像特征,在对黄板上的小菜蛾、黄曲条跳甲和烟粉虱等主要害虫进行识别与计数方面取得良好效果,但在高密度下的害虫检测精度较低。刘双喜等^[16]提出了一种MS-YOLO v7轻量化稻飞虱识别分类模型,有效解决了稻飞虱图像识别过程中存在分布密集、体态微小、易受背景干扰等造成识别精度不高的问题。张佳敏等^[17]提出了一种基于改进Mask-RCNN模型的害虫图像智能识别模型,使用DeAnchor算法改进Mask-RCNN的锚框引导机制,使用NDCC(Novelty detection consistent classifiers)训练分类器进行联合分类和检测,改善非目标杂虫的误识别问题。改进后模型对无杂虫、不同虫体密度图像的识别准确率最高达到96.1%,最密集时可达90.6%。李善军等^[18]改进了YOLO v8木虱识别模型,召回率、F1值及精确率分别达到91.20%、91%、90.60%,并开发了Web和手机APP客户端,实现虫情数据的可视化展示与远程控制。

尽管上述方法在分类检测中取得了良好效果,但现有研究多针对田间复杂背景(如植株遮挡、光照变化),而虫情测报灯采集的害虫图像虽背景单一,但虫体密集、尺寸差异大且种类相似度高,传统模型易因特征混淆导致误检。在图像中由于害虫大

小差异明显且物种之间体态差异较大,以及密集虫体识别时仍存在问题,当这些方法直接应用于小目标害虫的识别时,其准确度不理想,或识别害虫过于单一,在进行具体数量统计时,存在一定漏检,难以作为多种类水稻害虫早期预警和防控提供依据。针对害虫密集小目标的问题,近期研究多采用特征金字塔增强(BiFPN)或注意力机制(CBAM),但计算成本较高。近年来,Transformers的出现解决了CNN和RCNN在全局特征提取方面的不足,目前在多领域得到了广泛应用。FANG等^[19]优化了Transformer模型,提出了一种基于Transformer的混合卷积神经网络模型(Pest-ConFormer),使其具有多尺度弱监督特征选择机制,在细粒度视觉分类(FGVC)中表现出优异的多尺度判别特征提取能力,同时在作物害虫识别领域比基于CNN的方法更有效,且可以部署在实际自然环境中。

为解决虫情测报灯采集的水稻害虫图像虫体密集、尺寸差异大且种类相似度高问题,本文通过结合YOLO v8^[20]与Swin Transformer^[21]模型,充分发挥YOLO v8模型的高识别精度与Transformer模型的精确分类能力,增加模型提取小目标特征能力。将训练好的模型移植到Android手机端,以实现水稻多种类害虫信息的识别和监测。

1 材料与方法

1.1 图像采集装置

图像采集装置为自主研发的智能虫情测报灯(YG-ZC2024型),其结构如图1所示,主要包括诱虫灯部、主体箱部和基座。整体结构采用不锈钢喷塑工艺,安装防雷装置,可以有效防止雷击。主体箱内置高清工业摄像机,且摄像头像素不低于2000万,可以精准拍摄虫体图像。诱虫灯部高度可以实现升降,采用多时段控制,根据害虫生活习性规律,设定工作时间段,可对不同作物的生长周期所遭受害虫进行诱捕。使用太阳能板供电,可持续工作长时间,内置无线网络传输模块,支持5G入网,实现远程数据传输。

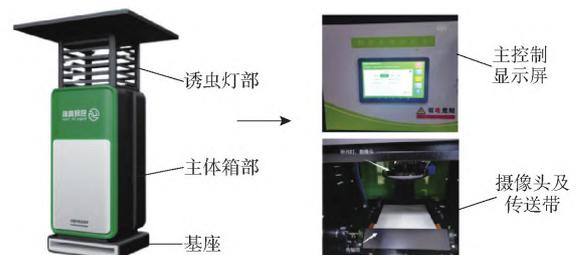


图1 智能虫情测报灯实物图

Fig. 1 Diagram of intelligent pest detection lamp device

虫情测报灯使用特定波长光源。在夜间工作

时,光源发出波长 320 ~ 680 nm 可见光。由于昆虫趋光性具有显著的波段特异性,波长 320 ~ 400 nm 的长波紫外光对鳞翅目(如棉铃虫、菜蛾)、鞘翅目(如金龟子、天牛)等害虫具有强吸引力,而 400 ~ 680 nm 的可见光则对蚜虫、飞虱等小型害虫更有效,所以选用 320 ~ 680 nm 的可见光可实现对多种害虫进行捕获。被光源吸引的害虫与仪器玻璃屏幕发生碰撞,随后掉入主体箱内的远红外加热处理室。进入处理室的害虫将接受远红外加热处理,能够有效杀死害虫而不损坏其身体。活虫在掉落 3 ~ 5 min 内会被杀死。害虫死亡后会定期将害虫从处理室转移到干燥室,并继续对害虫进行加热干燥,之后将干燥后的害虫转移到虫体收纳盒进行存储。为提高灭杀效率,设置 2 层远红外加热箱,并交替打开 2 个可移动门,确保每只害虫至少经历一次远红外加热处理循环。经过处理的害虫将根据设定时间间隔自动掉到拍摄工作台上。工作台上配备振动铺设装置和小型传送带。害虫落到工作台后,通过振动均匀分布在传送带上,并沿着传送带被运输到拍摄区域。系统相机拍摄害虫并将图像传输到图像采集系统,拍摄到的害虫将被运输到收集装置。

1.2 数据集构建

1.2.1 图像采集

试验样本于 2023 年 5—10 月采自安徽省蚌埠市五河县数字农业技术示范基地,基地位于沱湖乡(23°17'N, 108°52'E),基地稻田总面积为 20 hm²,每 2 hm²设置 1 台虫情测报灯,按均等面积进行分布,共计 10 台。虫情测报灯配备 1 台 2 000 万像素高清工业摄像头,摄像头以对接模式安装在工作台上方,用于拍摄被光源吸引的害虫高清图像。随后,摄像头拍摄图像及时上传到本地存储,拍摄的图像如图 2 所示。



图 2 虫情测报灯采集图像示例

Fig. 2 Insect detection lamp collection map

1.2.2 图像筛选

由于虫情测报灯所拍摄的害虫个体之间存在较大差异,并且某些种类害虫可能在同一季节大量出

现,这极大影响数据集质量。为解决该问题,对训练数据集进行过滤,剔除质量较差的数据样本。在深度学习算法中,要求图像分辨率较高,图像越清晰,识别效果越好。本文使用 2 000 万像素高清摄像头拍摄害虫,分辨率低于 4 096 像素 × 2 160 像素图像会被剔除。同样,包含叶片或害虫不完整图像也会被剔除。从不同季节中按一定比例选取高清图像,确保每种害虫图像数量足够,以满足深度学习训练需求,选用图像共计 1 000 幅。

1.2.3 图像数据增强及标注

因采集的图像害虫过于密集,构建一个多类型害虫数据集,试验前将所有图像尺寸进行统一处理,设置为 640 像素 × 640 像素。为保障试验样本多样性,采用数据增强方式来增加数据量^[22],包括将原始图像水平翻转、垂直翻转、270° 旋转、色彩变化和添加噪声等,如图 3 所示。数据增强方法有助于丰富数据集的多样性,并增强模型的鲁棒性和泛化能力。此外,适当添加噪声数据以进一步提高模型在实际应用中的稳定性。通过这些操作,数据量扩大到原来的 7 倍,最终共得到 7 000 幅图像。使用 LabelImg 工具进行标注,每幅图像标签以 XML 文件保存在图像所在目录,标注样式如图 4 所示。最后,扩展后数据样本按比例 8:1:1 划分为训练集、验证集和测试集,用于模型训练和评估。

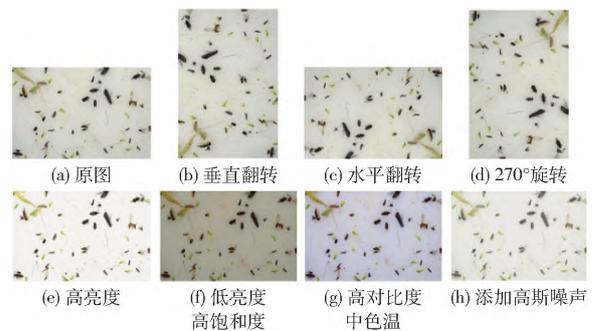


图 3 数据增强效果

Fig. 3 Data enhancement effect



图 4 LabelImg 标注图像

Fig. 4 LabelImg labeled image

1.3 分类与识别算法模型

1.3.1 YOLO v8 模型

YOLO v8^[23]是一种高效深度学习模型,主要应

用于目标检测领域,其继承了 YOLO 系列算法的传统模式,能实现高精度、高速的目标检测。YOLO v8 骨干网络采用 YOLO v5^[24] 的 CSP (Cross-stage partial) 结构,但对模块设计进行了优化。主要改进点为 YOLO v8 使用 C2f 模块替换原 YOLO v5 中的 C3 模块,进一步减小模型内存占用量并提高计算效率。同时,YOLO v8 还采用改进的路径聚合网络 (PANet) 作为特征融合模块,并引入 CIoU 损失函数,有效提高目标框回归准确性。此外,YOLO v8 还优化数据增强和训练策略,使模型在不同规模和背景下的性能更加稳定。YOLO v8 模型结构如图 5 所示。

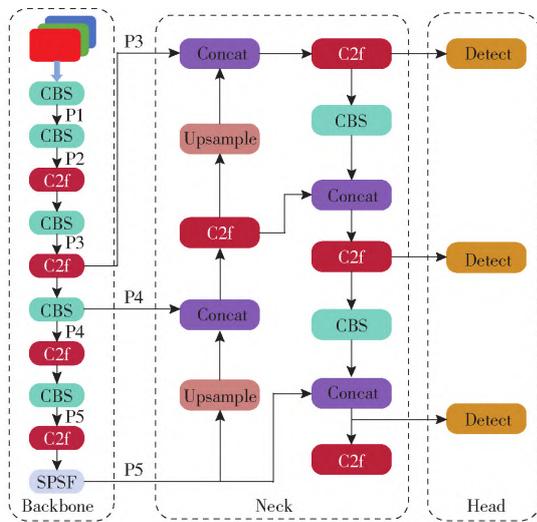


图 5 YOLO v8 模型结构图

Fig. 5 Structure diagram of YOLO v8 model

YOLO v8 网络结构可分为 3 部分:Backbone 骨干网络、Neck 颈部网络和 Head 头部网络。YOLO v8 骨干网络使用高效的 CSP Dark Net 结构从图像中提取特征。这种网络架构经过优化,可提取更丰富的图像特征,同时确保更低的计算复杂性,为后续检测任务提供更准确信息。颈部网络采用更高级的特征金字塔网络(FPN)融合方法。在目标检测任务中,不同尺度目标可在图像中产生不同大小特征,FPN 可以有效处理这个问题。YOLO v8 中使用 FPN 和 PANet(Path aggregation network) 组合,可进一步增强多尺度特征融合。通过该设计,YOLO v8 能更好地处理小型和大型目标,并在多尺度图像中保持良好的检测精度。Head 头部网络负责最终的目标分类和边界框回归,该部分使用自适应特征层和新的检测头来完成分类和定位任务,使网络不仅能有效处理更复杂场景,且能保证高效的计算性能。

尽管 YOLO v8 在大多数应用场景中表现良好,但在一些特定情况下仍存在一些性能瓶颈。例如,在复杂背景下的小目标检测方面,YOLO v8 可能会

出现漏检和误检。这主要是由于其特征提取网络捕获细粒度小目标的能力有限,在复杂背景下可能难以有效区分目标和干扰。因此,对 YOLO v8 进一步改进,旨在增强小目标检测性能,提高模型在复杂背景下的鲁棒性,并优化计算效率以适应更广泛的实际应用。

1.3.2 Swin Transformer 模型

Swin Transformer^[25] 是一种创新的视觉 Transformer 架构,通过引入局部窗口自注意力机制和窗口移位操作,解决传统 Transformer 在高分辨率图像处理中存在的计算与内存瓶颈问题。其将图像划分为多个固定大小窗口,并计算每个窗口内的自注意力以降低计算复杂性,同时移动窗口允许不同窗口之间的特征相互通信,从而有效地对长期依赖关系进行建模。Swin Transformer 还采用分层设计,逐步降低特征图分辨率并捕获不同尺度特征,该设计可以提高传统 Transformer 中的计算效率和降低内存消耗。Swin Transformer 结构如图 6a 所示。

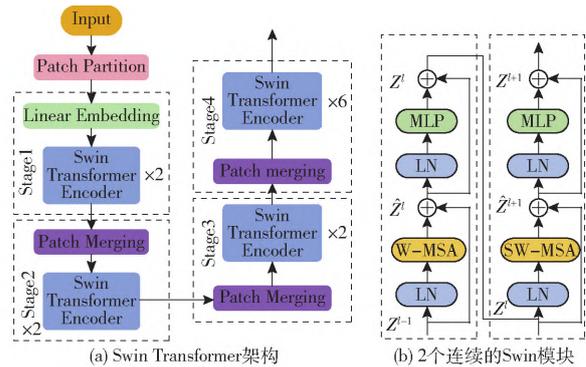


图 6 Swin Transformer 架构和 2 个连续的 Swin 模块

Fig. 6 Architecture of Swin Transformer and two successive Swin

Swin Transformer 结构主要包括补丁分割层 (Patch Partition layer)、线性嵌入层 (Linear Embedding layer)、补丁合并层 (Patch Merging layers) 和 ST 编码器层 (Swin Transformer Encoder layers)。在进行特征提取时分为 4 个阶段:进入第 1 阶段前,输入图像被 Patch Partition 分割成不重叠、大小相等的补丁,每个补丁被视为一个“标记”,获得一个特征序列。将此特征序列发送到线性嵌入层进行投影以获得新的特征维度,在 2 个 Swin Transformer 块进行自注意力计算后,进入第 2 阶段。在第 2 阶段,首先通过 patch fusion 减少特征维度,然后在 2 个 Swin Transformer block 之后将特征转到更深的层以计算注意力,依次到第 3 阶段和第 4 阶段以获取最终功能。在第 3、4 阶段,通过补丁融合特征,然后通过 Swin Transformer block 计算自注意力,将特征转化为更深层次。不同之处在于,在第 3

阶段,通过 6 个 Swin 变压器块(2 个块在 1 个组中)。每个阶段都会更改序列维数,从而产生分层表示。

通过这种分层的多尺度特征表示, Swin Transformer 能有效地捕获图像中不同尺度信息并提高模型性能。在目标检测任务中,图像中的目标通常具有不同比例差异,而这种比例差异可能是由图像中目标距离、目标之间相互遮挡或目标本身大小差异造成的。由于目标尺度不同,有效目标检测变得更具挑战性。因此,在网络骨干部分引入 Swin Transformer 模块,以增强网络提取不同尺度目标特征的能力。

1.3.3 改进的 YOLO v8 模型

为解决在虫情测报灯采集图像中,由于害虫密集度不同、同科不同属之间相似度、分布姿态以及虫体大小不同等诸多因素,导致难以准确检测目标,或者在检测害虫过程中采用传统检测方法导致检测精度不高,而引起漏检和误检问题,同时为了更准确地定位害虫和识别害虫类别,提出了一种改进的 YOLO v8 - STSF 算法模型。

改进的模型结构如图 7 所示。在 YOLO v8 骨干网部分引入 Swin Transformer 模块。借助 Transformer 机制增强特征的全局建模能力。特别是在处理长距离依赖时, Swin Transformer 的自注意机制可更有效地捕获细粒度的上下文信息。这一特性在害虫分类检测任务中尤为重要,因为不同害虫种类的判断通常基于体型、颜色、触角、翅膀等特征差异,并且 Swin Transformer 能在复杂的光线变化和背景噪声存在的情况下提高区分小目标和相似目标的能力,从而显著提高害虫检测的准确性。

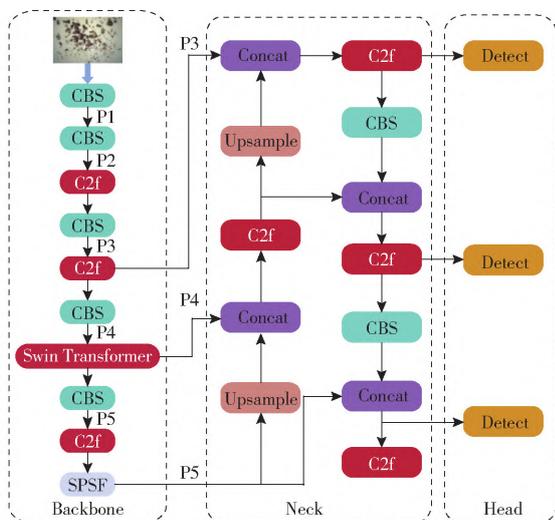


图 7 改进的 YOLO v8 - STSF 模型结构图

Fig. 7 Improved YOLO v8 - STSF model structure

在 Neck 部分,使用新的分布移位卷积

(DSCConv) 替代原本的标准卷积,并对 C2f 中的卷积结构进行调整。DSCConv 通过移位运算增强了特征多样性和不变性,这在多类别害虫检测中特别有效。特别是在体型、颜色差异较大的害虫中, DSCConv 可以更好地捕捉不同尺度的局部特征,从而提高模型鲁棒性和适应性,使其在处理不同种类害虫时更具鉴别性。

将原来的 CIoU 损失函数替换为 Focal EIou 损失函数。该损失函数结合 Focal Loss 的加权机制和 EIou 的准确率增强特性,在面对类别不平衡问题时更加有效。在害虫分类检测任务中,叶蝉类害虫与飞虱类害虫、螟蛉类害虫与蛾类害虫之间因体态和颜色之间存在相似度,传统损失函数通常难以准确区分这些类别。Focal EIou 损失函数能动态调整难以分类的样本权重,特别关注那些颜色和体态存在差异的害虫,这显著提高了模型在复杂数据集上的检测精度。与传统的 CIoU 相比, Focal EIou 在处理小而密集的目标时可以更准确地优化目标定位和分类,从而进一步提高害虫类别测定的准确性。同时,在后处理阶段还可以通过非极大抑制 (Non-maximum suppression, NMS) 删除冗余预测框,并保留最高的置信度检测结果,检测到的标签数量用于对害虫计数。

将 YOLO v8 - STSF 多类别害虫识别模型通过 Docker 容器部署至阿里云服务器,采用 Fast API 搭建 API 服务,接收客户端上传的田间害虫图像,实时推理并返回检测结果,同时将检测数据通过 MySQL 存储检测记录,实现端到端的数据通信与持久化存储,最后完成从图像上传、害虫识别到数据管理的全链路闭环。

2 试验与结果分析

2.1 运行环境配置

用于训练和测试模型的硬件处理器为 Intel Core i7 9700、CPU 为 3.20 GHz、GPU 为 GeForce RTX3080Ti 以及运行内存为 16 GB。软件开发环境为 Pytorch 深度学习框架,操作平台 Windows 10,其他为 Ubuntu 16.04、Python 3.6、Anaconda 9.12 和 CUDA 10.0。训练总轮数为 300,初始学习率设置为 0.01,动量为 0.9,优化器采用 Adam。试验过程随机重复 5 次,以 5 次试验结果平均值计算最终评价指标结果。

2.2 模型评价指标

使用精确率 (Precision)、召回率 (Recall)、F1 值和推理速度 (Frames per second, FPS) 作为模型性能的评价指标。精确率表示模型预测为正例的样本中

真正为正例的比值。召回率表示模型正确检测到害虫数量与检测到目标数量比值。F1 值为精确率和召回率的加权平均值。推理速度为每秒帧数,表示模型每秒处理的图像数量,是衡量算法速度和实时性的核心指标。FPS 越高,模型速度越快,实时性越强。

2.3 试验结果分析

2.3.1 不同算法模型对比

为验证 YOLO v8 - STSF 模型在检测精度和实时性上的综合性能,选取 ResNet^[26]、Faster R - CNN、SSD、YOLO v5 和 YOLO v8 共 5 种主流模型进行试验对比分析,所有模型均在相同环境下测试,试验结果如表 1 所示。

表 1 不同模型检测结果对比

Tab. 1 Comparison of detection results of different models

| 模型 | 精确率/ % | 召回率/ % | F1 值/ % | 推理速度/ (f·s ⁻¹) |
|----------------|-----------|-----------|------------|-------------------------------|
| ResNet | 81.22 | 75.31 | 78.32 | 8 |
| Faster R - CNN | 92.12 | 82.34 | 86.45 | 12 |
| SSD | 90.98 | 83.21 | 87.85 | 28 |
| YOLO v5 | 91.66 | 82.97 | 85.52 | 40 |
| YOLO v8 | 93.32 | 90.12 | 86.94 | 45 |
| YOLO v8 - STSF | 95.45 | 90.45 | 90.03 | 32 |

由表 1 可得, YOLO v8 - STSF 模型精确率为 95.45%、召回率为 90.45% 以及 F1 值为 90.03%, 均显著优于其他对比模型,较原 YOLO v8 模型分别提升 2.13、0.33、3.09 个百分点,验证了改进策略的有效性。尽管其推理速度为 32 f/s,略低于 YOLO v8 的 45 f/s,但仍高于田间实时监测的阈值要求(大于等于 30 f/s),且在综合指标上远超单阶段模型 SSD 和两阶段模型 Faster R - CNN。由表 1 也可以看出,传统模型 ResNet 推理速度为 8 f/s,难以满足实际需求,而轻量化模型 YOLO v5 虽速度较快,为 40 f/s,但其特征融合能力不足导致 F1 值偏低,为 85.52%。综上, YOLO v8 - STSF 在精度与速度间实现了最佳平衡,为水稻害虫的实时监测提供了高效可靠的技术方案。

2.3.2 消融试验

为验证 YOLO v8 - STSF 模型对比 YOLO v8 原模型的优越性,设计了消融试验,结果如表 2 所示,其中√表示采用该改进方式,×表示未采用该改进方式。

由表 2 可得, Swin Transformer 因全局注意力机制增强了小目标的特征提取能力,对精确率提升最显著,提升 1.35 个百分点,但计算量增加导致推理速度下降 7 f/s。DSConv 通过局部特征多样性优

表 2 消融试验结果

Tab. 2 Results of ablation experiments

| Swin Transformer | DSConv | Focal EIoU | 精确率/% | 召回率/% | F1 值/% | 推理速度/(f·s ⁻¹) |
|------------------|--------|------------|-------|-------|--------|---------------------------|
| × | × | × | 93.32 | 90.12 | 86.94 | 45 |
| √ | × | × | 94.67 | 90.45 | 89.12 | 38 |
| × | √ | × | 93.85 | 90.30 | 88.21 | 43 |
| × | × | √ | 93.50 | 90.45 | 87.95 | 44 |
| √ | √ | √ | 95.45 | 90.45 | 90.03 | 32 |

化,召回率提升 0.18 个百分点,且推理速度仅下降 2 f/s,平衡了性能与效率。Focal EIoU 主要改善密集目标的定位精度即 F1 值,提升 1.01 个百分点,但对推理速度影响较小,下降 1 f/s。YOLO v8 - STSF 综合性能最优, F1 值为 90.03%,验证了改进策略的互补性。尽管推理速度下降至 32 f/s,仍满足田间实时监测大于等于 30 f/s 的需求。

2.4 模型可视化检测结果对比

为直观展示 YOLO v8 模型改进前后对害虫的检测效果,设置了对比试验,对比改进前后对不同害虫类型的识别效果,检测结果如图 8 所示。图 8a 中 YOLO v8 模型存在严重的漏检和错检,共漏检灰飞虱 54 只(黄色标记);漏检蓟马 36 只(红色标记),错检蓟马 6 只(蓝色标记);漏检稻螟蛉 7 只(绿色标记);漏检水稻负泥虫 35 只(黑色标记)。图 8b 中, YOLO v8 - STSF 能对图像中特征相似的害虫进行有效识别,并检测出原 YOLO v8 模型漏检的目标。该结果表明,得益于 Swin Transformer 的局部窗口注意力和分布移位卷积(DSConv)的多尺度特征融合,对不同类别害虫细节特征的分析能力更强, YOLO v8 - STSF 模型在密集分布和小目标个体众多场景下表现显著,识别性能良好,验证了其对于虫情测报灯检测的适应性。

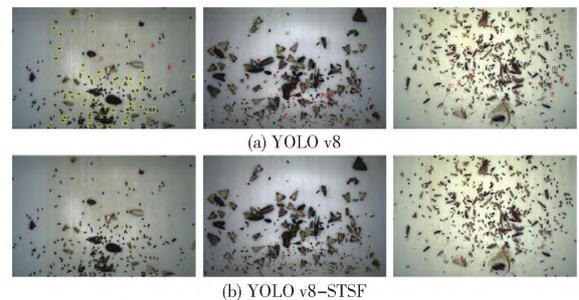


图 8 YOLO v8 改进前后图像检测结果

Fig. 8 Image detection results before and after YOLO v8 improvement

3 害虫监测系统设计

3.1 系统组成与 Web 端

害虫监测系统由 4 部分组成,包括虫情测报灯

图像采集装置、虫情数据无线传输系统、云服务器和客户端,如图9所示。通过虫情测报灯远程采集害虫图像信息,然后由物联网设备通过5G网络将采集数据实时传输至云服务器,通过REST API接收数据,结合YOLO v8-STSF模型对害虫进行识别分析,最后将分析结果反馈到客户端,以使用户实时知晓稻田的虫害情况,可以及时对害虫进行防治。

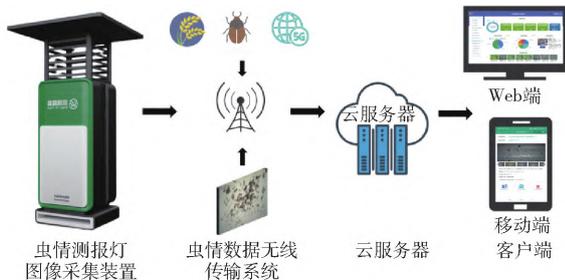


图9 害虫监测系统架构

Fig. 9 Pest monitoring system architecture

系统设计采用前后端分离架构,后端通过MTV架构和Spring Boot框架实现,数据库使用MySQL构建,MySQL是一个关系数据库,可以实现数据交互式存储。Web端使用Vue框架设计,通过HTTPS调用云服务器API获取数据。如图10所示,Web端主要以后端数据管控为主,展示任务管理界面,用于追踪虫情测报灯的工作和采集任务状态,以及提供实时分析结果与历史记录。二者共同构成虫情监测系统的“采集-分析-展示”闭环,体现数据一致性与用户交互设计。

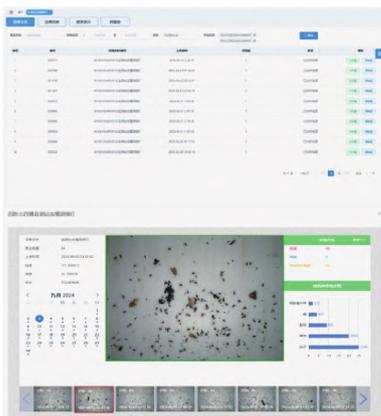


图10 Web 端界面

Fig. 10 Web interface

3.2 Android 移动端

为将虫情监测系统Web端移植到Android移动端,构建了响应式设计界面,通过折叠式筛选面板优化设备与时间选择,集成轻量化地图组件;同时强化实时虫情警报,底层沿用MQTT/HTTP协议并引入Protobuf压缩数据,结合Flutter实现跨平台高性能渲染,最终开发出Android移动端APP,兼顾离线缓存与弱网传输可靠性,提升田间场景下的操作效率

与用户体验。移动端界面如图11所示,主要功能包含用户登录、场景切换、设备筛选、时间筛选、数据统计、地图展现等,可自由切换需要查看的页面。



图11 Android 移动端界面

Fig. 11 Android mobile interface

3.3 应用性能验证

为更好地验证移动端害虫监测系统对害虫的识别效果,于2024年9月在安徽省五河县沱湖乡四陈村和双庙村基地进行田间测试,覆盖四陈村北点位、四陈村东点位及双庙村点位。测试环境包含密集遮挡、多类共存及小目标等复杂场景,模型在NVIDIA RTX3080Ti GPU上的推理速度为32 f/s,即单幅图像处理时间约31 ms;移动端使用小米手机13,内核处理器为骁龙8 Gen2,通过TensorRT轻量化部署后推理速度为18 f/s,满足程序的实时性和鲁棒性要求,达到田间实时监测需求。

测试结果如图12所示,从虫情测报灯图像采集、5G传输至云端分析,再到移动端结果推送,全流程平均响应时间为1.38 s,满足虫情监测的适用性要求。检测虫体数量共30373只,未检测共计1173只,识别准确率为96.34%,在密集虫体场景中,漏检率降至3.86%,在小目标占比多的场景中,召回率提升至89.2%,较原模型提高6.8个百分点,这得益于Focal EIoU损失函数的定位优化。

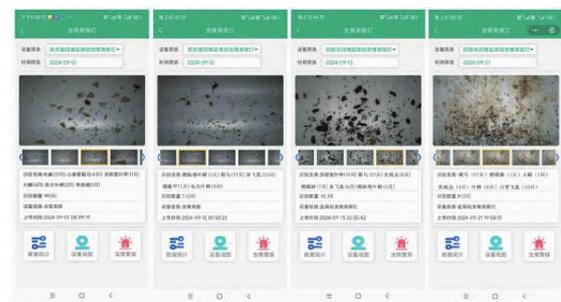


图12 APP 识别结果

Fig. 12 APP recognition result

通过MySQL数据库存储检测记录,并基于时空数据生成虫情数据图,系统日均处理图像5000幅,可实时预警虫害爆发区域,如四陈村东点位漏检率为5.81%,存在潜在风险。并可以结合害虫种群动态分析进行历史数据回溯,为精准施药提供

科学依据。综上所述,本系统在实际应用中,性能表现良好。

4 结论

(1)针对虫情测报灯采集到的图像中害虫密集、体态差异细微及小目标漏检等问题,提出了一种基于YOLO v8-STSF模型的水稻害虫智能识别方法,通过融合Swin Transformer的全局注意力机制、分布移位卷积(DSConv)的多尺度特征优化及Focal EIoU损失函数的定位增强,在测试集上精确率为95.45%,F1值为90.03%,较原YOLO v8提升

2.13/3.09个百分点。消融试验结果表明,3个模块协同作用使密集遮挡场景漏检率降低至3.86%,验证了模型设计的有效性。

(2)设计了一体化虫情监测系统,包括虫情测报灯图像采集装置、虫情数据无线传输系统、云端服务器及客户端。系统通过轻量化模型压缩部署使得移动端推理速度为18 f/s,在田间测试中平均响应时间为1.38 s,识别准确率为96.34%,漏检率为3.86%,Web端与Android移动端通过响应式设计优化用户体验,支持实时虫情监测与历史数据分析,具有良好的实用性。

参 考 文 献

- [1] 卓富彦,陈学新,夏玉先,等. 2013—2022年我国水稻病虫害发生特点与绿色防控技术集成[J]. 中国生物防治学报, 2024,40(5):1207-1213.
ZHUO Fuyan, CHEN Xuexin, XIA Yuxian, et al. The occurrence characteristics of rice diseases and insect pests and the integration of green control technology in China from 2013 to 2022[J]. Chinese Journal of Biological Control, 2024,40(5):1207-1213. (in Chinese)
- [2] 蔡玉彪,张坤杰,王雅宣,等. 水稻品种对褐飞虱趋向二化螟危害株习性的影响[J]. 中国农业科学, 2024,57(20):3998-4006.
CAI Yubiao, ZHANG Kunjie, WANG Yaxuan, et al. Effect of rice varieties on the preference of *Nilaparvata lugens* to rice plants infested by *chilo suppressalis*[J]. Scientia Agricultura Sinica, 2024,57(20):3998-4006. (in Chinese)
- [3] 杨宝云,李正飞,何艳艳,等. 5种杀虫剂对旱地水稻田稻纵卷叶螟和东方黏虫幼虫的田间防效[J]. 植物保护, 2025, 51(1):334-340.
YANG Baoyun, LI Zhengfei, HE Yanyan, et al. Field control efficacy of five insecticides against *Cnaphalocrocis medinalis* and *Mythimna separata* in nonirrigated farmland rice[J]. Plant Protection, 2025,51(1):334-340. (in Chinese)
- [4] 李有志,方继朝. 水稻害虫:研究进展与展望[J]. 昆虫学报, 2024,67(4):443-455.
LI Youzhi, FANG Jichao. Rice pests: research progresses and prospects[J]. Acta Entomologica Sinica, 2024,67(4):443-455. (in Chinese)
- [5] 李军,李志伟,李艳红. 基于多原型指导的小样本水稻害虫识别与分类[J]. 江苏农业科学, 2023,51(20):193-200.
LI Jun, LI Zhiwei, LI Yanhong. Recognition and classification of rice pests in small samples based on multi-prototype guidance[J]. Jiangsu Agricultural Sciences, 2023,51(20):193-200. (in Chinese)
- [6] 李文勇,李明,陈梅香,等. 基于机器视觉的作物多姿态害虫特征提取与分类方法[J]. 农业工程学报, 2014,30(14):154-162.
LI Wenyong, LI Ming, CHEN Meixiang, et al. Feature extraction and classification method of multi-pose pests using machine vision[J]. Transactions of the CSAE, 2014,30(14):154-162. (in Chinese)
- [7] 陈月华,胡晓光,张长利. 基于机器视觉的小麦害虫分割算法研究[J]. 农业工程学报, 2007,23(12):187-191.
CHEN Yuehua, HU Xiaoguang, ZHANG Changli. Algorithm for segmentation of insect pest images from wheat leaves based on machine vision[J]. Transactions of the CSAE, 2007,23(12):187-191. (in Chinese)
- [8] 邱道尹,张红涛,刘新宇,等. 基于机器视觉的大田害虫检测系统[J]. 农业机械学报, 2007,38(1):120-122.
QIU Daoyin, ZHANG Hongtao, LIU Xinyu, et al. Design of detection system for agriculture field pests based on machine vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007,38(1):120-122. (in Chinese)
- [9] TIAN Yunong, WANG Shihui, LI En, et al. MD-YOLO: multi-scale dense YOLO for small target pest detection[J]. Computers and Electronics in Agriculture, 2023,213:12.
- [10] LI R K, DUAN J L, DENG J Y, et al. Pest detection based on lightweight locality-aware Faster R-CNN[J]. Agronomy, 2024,14(10):2303.
- [11] LYU Zongwang, JIN Huifang, ZHEN Tong, et al. Small object recognition algorithm of grain pests based on SSD feature fusion[J]. IEEE Access, 2021,9:43202.
- [12] LI Wei, ZHU Tengfei, LI Xiaoyu, et al. Recommending advanced deep learning models for efficient insect pest detection[J]. Agriculture, 2022,12(7):1065.
- [13] MA Ali, SHARMA A K, DHANARAJ R K. Heterogeneous features and deep learning networks fusion-based pest detection, prevention and controlling system using IoT and pest sound analytics in a vast agriculture system[J]. Computers and Electrical Engineering, 2024,116:109146.
- [14] ZHOU Congliang, LEE W S, ZHANG Shuhao, et al. A smartphone application for site-specific pest management based on

- deep learning and spatial interpolation[J]. *Computers and Electronics in Agriculture*, 2024, 218: 108726.
- [15] 肖德琴, 黄一桂, 张远琴, 等. 基于改进 Faster R-CNN 的田间黄板害虫检测算法[J]. *农业机械学报*, 2021, 52(6): 242-251.
XIAO Deqin, HUANG Yigui, ZHANG Yuanqin, et al. Pest detection algorithm of yellow plate in field based on improved Faster R-CNN[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(6): 242-251. (in Chinese)
- [16] 刘双喜, 刘思涛, 屈慧星, 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)
- [17] 张佳敏, 闫科, 王一非, 等. 基于改进 Mask-RCNN 算法的作物害虫分类识别[J]. *农业工程学报*, 2024, 40(7): 202-209.
ZHANG Jiamin, YAN Ke, WANG Yifei, et al. Classification and identification of crop pests using improved Mask-RCNN algorithm[J]. *Transactions of the CSAE*, 2024, 40(7): 202-209. (in Chinese)
- [18] 李善军, 梁千月, 余勇华, 等. 柑橘木虱 YOLO v8-MC 识别算法与虫情远程监测系统研究[J]. *农业机械学报*, 2024, 55(6): 210-218.
LI Shanjun, LIANG Qianyue, YU Yonghua, et al. Research on Asian citrus psyllid YOLO v8-MC recognition algorithm and insect remote monitoring system[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(6): 210-218. (in Chinese)
- [19] FANG Mingwei, TAN Zhiping, TANG Yu, et al. Pest-ConFormer: a hybrid CNN-Transformer architecture for large-scale multi-class crop pest recognition[J]. *Expert Systems With Applications*, 2024, 255: 124833.
- [20] 刘梦姝, 张春琪, 晁金阳, 等. 基于 YOLO v8n 改进的小麦病害检测系统[J]. *农业机械学报*, 2024, 55(增刊1): 280-287, 355.
LIU Mengshu, ZHANG Chunqi, CHAO Jinyang, et al. Improved wheat disease detection system based on YOLO v8n[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(Supp. 1): 280-287, 355. (in Chinese)
- [21] MA Wenlong, LIU Weisheng. Improving UAV image target detection: a novel approach using OptiDETR with Swin Transformer[J]. *IAENG International Journal of Computer Science*, 2025, 52(3): 771-780.
- [22] CHEN Yuqi, ZHU Xiangbin, LI Yonggang, et al. Enhanced semantic feature pyramid network for small object detection[J]. *Signal Processing: Image Communication*, 2023, 113: 116919
- [23] XIE Weining, SUN Xiaoyong, MA Weifeng. A light weight multi-scale feature fusion steel surface defect detection model based on YOLO v8[J]. *Measurement Science and Technology*, 2024, 35(5): 055017.
- [24] 胡灿, 王兴旺, 王旭峰, 等. 基于 Android 手机的田间棉花产量预测系统设计[J]. *农业机械学报*, 2023, 54(增刊2): 252-259, 277.
HU Can, WANG Xingwang, WANG Xufeng, et al. Field cotton yield prediction system based on Android mobile phone[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(Supp. 2): 252-259, 277. (in Chinese)
- [25] LI Rumei, ZHANG Liyan, ZUN Wang, et al. FCSwinU: fourier convolutions and Swin Transformer UNet for hyperspectral and multispectral image fusion[J]. *Sensors*, 2024, 24(21): 7023.
- [26] WANG Jian, ZHANG Bo, YIN Dong, et al. Distribution network fault identification method based on multimodal ResNet with recorded waveform-driven feature extraction[J]. *Energy Reports*, 2025, 13: 90-104.