doi:10.6041/j.issn.1000-1298.2025.11.053

基于改进 YOLO v10n 的虫情灯水稻害虫检测方法

姜　晟[1]　郭鸿沛[1]　王卫星[2]　欧阳聪[1]　杨尚林[1]　叶　云[3,4]　黄志宏[5]

(1. 华南农业大学电子工程学院(人工智能学院), 广州 510642; 2. 华南农业大学珠江学院, 广州 510900;
3. 广州海睿智能科技股份有限公司, 广州 510700;4. 广东轻工职业技术大学生态环境技术学院, 广州 528225;
5. 华南农业大学信息网络中心, 广州 510642)

摘要: 针对虫情测报杀虫灯下稻田害虫检测任务中害虫目标体积小、形态多样、堆积重叠所导致的检测精度低、速度慢等问题,提出一种基于改进 YOLO v10n 的识别方法(YOLO - FRP,即 YOLO - Five Rice Pest)。引入 BiFPN(Bi-directional feature pyramid network)结构以改善原有特征金字塔 FPN(Feature pyramid net),增强模型对低级特征和高级特征的融合,并引入 P2 小目标层,提升多尺度信息感知能力。设计轻量级增强模块 C2f_Star 替换主干网络中的浅层 C2f 模块,移植 YOLO v10s 的 C2fCIB 模块替换主干网络中的深层 C2f,在增强多尺度检测精度的同时降低计算量。结果表明,改进模型的平均精度均值 mAP@0.5 为 82.1%、召回率为 79.5%、参数量为 1.64×10^6、模型内存占用量为 4.3 MB。为了进一步实现模型高实时性检测与轻量化部署,采用蒸馏-剪枝联合策略,将结合 EMA 注意力机制和 C2f_DySnakeConv 动态蛇形卷积模块改进后的 YOLO v10s 模型作为教师模型,通过 L2 正则化蒸馏提高已改进 YOLO v10n 模型性能,再采用基于层自适应幅度的剪枝策略降低模型参数量。与 YOLO v10n 相比,经联合策略处理后模型 mAP@0.5、召回率分别提升 2.6、2.7 个百分点,帧率提升 158 f/s,参数量和模型内存占用量分别下降 65.64%、56.36%。实验对比结果表明,YOLO - FRP 在精度和速度上综合表现优异,且蒸馏-剪枝联合策略可进一步在精度无损的情况下压缩模型规模,显著提升模型推理速度,为农业害虫实时监测精度-速度平衡提供技术参考。

关键词: 水稻害虫; 特征增强; 目标检测; 轻量化; 知识蒸馏

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0550-10　　**OSID**:

Rice Pest Detection Method for Insecticidal Lamps Based on Improved YOLO v10n

JIANG Sheng[1]　GUO Hongpei[1]　WANG Weixing[2]　OUYANG Cong[1]　YANG Shanglin[1]
YE Yun[3,4]　HUANG Zhihong[5]

(1. *College of Electronic Engineering (College of Artificial Intelligence), South China Agricultural University, Guangzhou* 510642, *China*
2. *Zhujiang College, South China Agricultural University, Guangzhou* 510900, *China*
3. *Guangzhou Hairui Intelligent Technology Co., Ltd., Guangzhou* 510700, *China*
4. *School of Eco-environment Technology, Guangdong Industry Polytechnic University, Guangzhou* 528225, *China*
5. *Information Network Center, South China Agricultural University Guangzhou* 510642, *China*)

Abstract: Aiming to address the issues of low detection accuracy and slow speed in the task of detecting rice field pests under insect pest monitoring and control lamps, including small pest target size, morphological diversity, and stacked and overlapping pest clusters, a recognition method based on improved YOLO v10n (named YOLO - FRP, short for YOLO - five rice pest) was proposed. The bi-directional feature pyramid network (BiFPN) was introduced to improve the original feature pyramid network (FPN), reducing parameters for easier deployment while leveraging bidirectional feature propagation to enhance the model's fusion of low-level and high-level features. Meanwhile, a P2 small-target layer was further integrated into the BiFPN to strengthen multi-scale feature fusion, boosting stronger contextual awareness of diverse target sizes. A lightweight enhancement module, C2f_Star, was

收稿日期: 2025-05-15　修回日期: 2025-06-06

基金项目: 广东省重点领域研发计划项目(2023B0202100001)和国家重点研发计划项目(2017YFD0701700)

作者简介: 姜晟(1982—),男,高级实验师,博士,主要从事物联网与人工智能研究,E-mail: jiangsheng@scau.edu.cn

通信作者: 黄志宏(1981—),男,正高级工程师,主要从事物联网、大数据与网络安全研究,E-mail: huangzh@scau.edu.cn

designed to replace the shallow C2f modules in the backbone network to improve multi-scale detection accuracy and computational efficiency. Concurrently, the C2fCIB module from YOLO v10s was transplanted into the backbone to replace the deep C2f modules to reduce computational complexity while enhancing precision. The experimental results demonstrated that the improved model achieved mAP@0.5 of 82.1% and recall rate of 79.5%, with parameter count of 1.64×10^6 and model size of 4.3 MB. To further achieve high real-time detection and lightweight deployment of the model, a joint distillation-pruning strategy was adopted. The improved YOLO v10s model, which was enhanced with the EMA attention mechanism and the C2f_DySnakeConv dynamic snake-shaped convolution module, was used as the teacher model. L2 regularization distillation was applied to enhance the performance of the YOLO-FRP model, and a layer-adaptive magnitude-based pruning strategy was further adopted to reduce the model's parameter count. Compared with the YOLO v10n model, the pruned and distilled model achieved 2.6 percentage points higher mAP@0.5 and 2.7 percentage points higher recall rate, and its frame rate was raised by 158 f/s; its parameter count and model size were decreased by 65.64% and 56.36% respectively. Comparative experiments on the self-built dataset confirmed the effectiveness of the proposed improvements. The YOLO-FRP model exhibited superior detection accuracy and speed for five rice pest species under insect-attracting lamps, which validated that the distillation-pruning strategy could further compress the model size without accuracy loss and significantly improve the inference speed, providing technical reference for balancing accuracy and speed in real-time agricultural pest monitoring.

Key words: rice pests; feature enhancement; object detection; lightweight; knowledge distillation

0　引言

精准识别害虫种类对虫害防治、粮食安全及农业经济可持续发展具有重要意义。虫情早期发现有助于减少因杀虫剂滥用而引发的食品安全风险和环境污染问题[1]。由于害虫种类繁多且部分种类外观相似性高,比如鳞翅目就包含有数十种外观相近的田间作物害虫[2],而传统人工鉴别依赖专家经验,往往导致高昂的经济成本与低下的害虫防治效率[3]。

近年来,深度学习技术在各个领域受到越来越多关注,相较于传统图像处理方法,卷积神经网络(Convolutional neural network, CNN)、Transformer 等[4]架构凭借其强大的特征提取能力在金融[5]、医疗[6]等领域取得重大进展。然而,农业领域害虫检测场景复杂特殊,对网络架构与模型性能提出多重挑战,比如同属害虫不同生长阶段形态差异显著,害虫体积小[7]且易重叠,田间数据呈长尾分布,同时需兼顾高精度与高实时性,这些都增加了模型训练难度。

在目标检测算法领域,YOLO(You only look once)[8]单阶段检测器依托 CNN 的特征提取能力,因高精度和高实时性优势而得到广泛应用。近年来,随着 DETR[9]等模型推动 Transformer 在目标检测领域的应用,一些新的 YOLO 模型开始尝试引入其全局上下文建模思想,进一步拓展了技术边界。为了提升害虫目标检测精度[10],赵辉等[11]将 CSP Bottleneck(Cross stage partial bottleneck)与 Swin Transformer 结合,增设第 4 检测支路并引入 CBAM[12](Convolutional block attention module)模块,采用 Focal EIoU Loss[13](Focal efficient intersection over union loss)缓解目标重叠问题,最终模型的 mAP@0.5 较原模型提高 2.5 个百分点。刘双喜等[14]采用基于形色筛选的分割法对害虫图像进行分割,有效提高对棉铃虫、桃蛀螟和玉米螟 3 种害虫的平均识别精度。HU 等[15]引入全局上下文注意机制[16]降低复杂背景的干扰,利用 BiFPN[17]结构强化特征金字塔的跨尺度融合,最后引入 Swin Transformer[18]模块捕获害虫的全局上下文关系,使模型在复杂场景下精度提升 5.4 个百分点。姚青等[19]利用重叠滑动窗口和目标框抑制技术改进 CornerNet[20],在稻飞虱检测任务中实现 95.5% 的检测精度,证明算法优化对特定害虫检测的有效性。

为了实现模型轻量化与检测精度平衡,郑果等[21]将 MobileNetv3[22]作为 YOLO v7 的主干网络,结合深度可分离卷积,在保持精度的同时使模型检测速度提升 5 倍,验证了模型轻量化设计的可行性。王泰华等[23]利用 CoordConv(Coordinate convolution)和 Slim-neck 减少浮点运算量并增强模型特征处理能力,用 Soft-NMS 算法优化密集目标检测,使模型精度提高 3.8 个百分点。彭红星等[24]提出自适应坐标注意力机制,结合深度可分离卷积与逐点卷积,使改进 YOLO_PD 精度较改进前提高 2.1 个百分点,图像传输速率为 42.4 f/s。

综上,现有研究在害虫检测领域已取得显著进展,但针对虫情灯监测场景,现有方法仍存在局限,一方面,害虫体积小、密度高、相互遮挡以及设备清扫导致的虫体破损等复杂情况易使模型识别精度受

严重影响;另一方面,多数轻量化方案在压缩模型时会显著牺牲精度,难以兼顾“高精度”与“低资源消耗”。对此,本研究构建水稻害虫[25]相关数据集,提出基于 YOLO v10n 改进的 YOLO - FRP 模型,通过知识蒸馏和剪枝联合策略,在提升识别精度的同时实现模型轻量化,从而有效解决该场景下害虫识别难度大、部署资源消耗高的问题,以期为农业害虫监测智能化提供兼具高精度识别与模型轻量化的技术支撑。

1 材料与方法

1.1 数据集构建

所使用数据集来自广州海睿智能科技股份有限公司,在 HR - CQT - 1/D 型电击式虫情监测设备诱捕害虫后由成像系统拍摄采集的图像所构建,数据集图像特征与 Pest24[26]数据集类似。该设备部署于稻田环境,图像采集场地为广东省清远市清城区源潭镇大连村,如图 1 所示。



图 1 虫情测报杀虫灯在水稻田间部署示意图

Fig. 1 Deployment of pest detection and killing lamp in rice field

1. 太阳能板 2. 立杆 3. 电源按钮 4. 虫情测报杀虫灯 5. 底座

虫情测报杀虫灯分为上下两部分,上部为诱导装置和无线传输天线,下部为柜体结构,柜内设有控制电路与虫体处理存放装置。诱捕装置由诱虫灯管、电网和捕虫漏斗组成,诱虫灯安装在中间位置,周围是 3 块撞击玻璃屏,下方安装有连通拍摄仓的捕虫漏斗。设备采用特定频振灯管作为诱虫光源吸引害虫,害虫撞击玻璃屏后被高压电网击杀,随后落入拍摄仓中,由 1 200 万像素的定焦摄像头完成拍摄取样,最后,仓底开启,害虫落入集虫料斗,防止虫体堆积。

数据集害虫种类含常见的 5 种水稻害虫(稻飞虱、二化螟、稻纵卷叶螟、突背斑红蝽、稻绿蝽),共 1 026 幅图像,数据集样本如图 2 所示,图像背景复杂,虫体大小不等、分布疏密不一,图像分辨率为 4 000 像素 ×3 000 像素,数据采集时间为 2023 年 7 月 2 日—2024 年 8 月 22 日。

为了扩增图像数量,增强场景复杂度,使模型更好地学习各类害虫的特征,同时保留虫情测报杀虫灯特有的背景与光照条件,采用翻转、平移、旋转、改变对比度等方式对原始图像扩充,增强效果如图 3 所示,扩充后图像数量达到 2 052 幅。

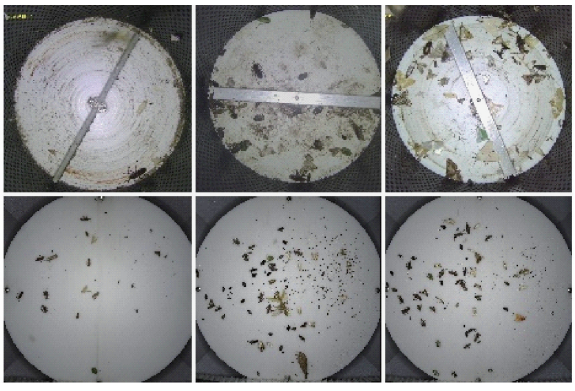


图 2 水稻害虫数据集样例

Fig. 2 Samples of rice pest dataset

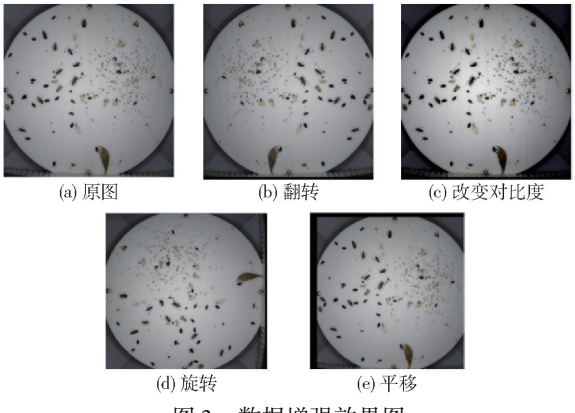


图 3 数据增强效果图

Fig. 3 Image samples after data enhancement

使用 LabelImg 软件标注害虫目标,标注格式设置为 YOLO 格式,标注完成后将数据集按比例 7∶1.5∶1.5 划分为训练集、验证集和测试集(其中训练集 1 436 幅,验证集和测试集各 308 幅)。害虫样本在各数据集中的标签数量如表 1 所示。当前数据集在类别覆盖与样本分布均衡方面仍存在局限,未来计划扩充至更多种类以提高模型泛化能力。

表 1 各类水稻害虫标签数量

Tab. 1 Number of pest labels

害虫种类	训练集标签数量	验证集标签数量	测试集标签数量
稻飞虱(Rice plant hopper)	2 653	565	543
二化螟(*Chilo suppressalis*)	682	140	196
稻纵卷叶螟(Rice leaf roller)	317	65	47
突背斑红蝽(*Physopelta gutta*)	2 774	510	728
稻绿蝽(*Nezara viridula*)	490	100	92

1.2 害虫识别模型

1.2.1 YOLO v10 模型

YOLO v10[27]是新一代实时端到端单阶段目标

检测算法，其核心改进分为两部分：

（1）主干网络优化。YOLO v10 首先提出基于空间通道解耦的下采样方法（Spatial-channel decoupled downsampling，SCDonw），先利用点卷积调整通道维度，再通过深度卷积（Depthwise convolution，DConv）进行空间下采样，在最大限度保留特征信息的同时，大大减少检测的延迟时间，提高检测速度。随后，提出轻量化的紧凑反向模块（Compact inverted block，CIB），通过分组深度可分离卷积（Depthwise separable convolution）降低跨阶段特征传递的计算冗余，既减少资源消耗又提升计算性能，最后，引入部分自注意力（Partial self-attention，PSA）模块，对输入特征图分组进行差异化卷积操作，动态调整各组输出的特征权重，增强模型对多尺度目标的感知能力。

（2）无 NMS 检测头设计。YOLO v10 提出无 NMS（Non-maximum suppression）的双重标签分配和一致性匹配度量策略。在模型训练阶段，多个预测框被分配给一个真实目标标签，这种策略提供了丰富的监督信号。同时使用一对一分配实现预测边界框精准匹配，再通过一致匹配度量使两个分支在训练过程中保持一致，确保优化方向相同。推理阶段则仅使用一对一头分配策略，彻底消除 NMS 后处理，实现更高效的端到端检测。

YOLO v10 在实时端到端检测方面展现出优异性能，是实现虫情测报杀虫灯下水稻害虫实时检测的理想方案。然而，在虫情灯复杂场景下，针对高分辨率图像中稻飞虱这类极小体积害虫的检测，仍存在技术挑战。一方面，随着网络深度增加，局部细节和小目标特征信息易丢失，模型的多尺度特征融合能力需要进一步提升；另一方面，受限于虫情监测设备算力资源不足的问题，需要进一步轻量化模型以适配边缘部署，从而提升实际应用价值。

1.2.2　YOLO－FRP 模型

提出了一种基于 YOLO v10n 改进的检测模型 YOLO－FRP，网络架构如图 4 所示，针对模型轻量化和精度平衡的难点，做出如下改进：

（1）构建轻量化双向特征金字塔 BiFPN。针对模型轻量化和增强多尺度特征融合能力的需求，引入基于 EfficientDet 的 BiFPN 结构。相较于传统的特征金字塔网络（Feature pyramid network，FPN），BiFPN 通过双向连接建立跨层级特征融合，增强上下文信息的关联，实现有效信息的共享，减少参数和计算复杂度，进而有效满足边缘设备的部署需求。

（2）引入 P2 目标检测层。在 BiFPN 的基础上引入 P2 小目标检测层以缓解微小害虫因深层下采样导致的细节丢失问题，P2 层拥有较高分辨率，能够保留更多目标边缘纹理等高频信息，结合双向跨尺度传播结构可以显著增强模型对不同尺度目标的感知，减少漏检。然而，P2 层的大尺寸特征图会使后续模块的计算复杂度显著上升，需通过其他轻量化设计与策略平衡精度与实时性的需求。

（3）C2f_Star 模块。传统 C2f 模块基于跨阶段部分连接 CSP（Cross stage partial）架构，通过堆叠 3×3 标准卷积实现层级间的特征融合，无法动态调整不同通道和空间特征的权重，小目标纹理等高频信息在深层网络中易被平滑稀释，且参数量与计算成本较高。同时，Bottleneck 的残差连接仅通过简单拼接的方式融合主路径和支路径特征，难以捕捉小目标的细节关联性。为了解决上述问题，构建 C2f_Star 模块，结构如图 5 所示。该模块在 C2f 的基础上将 Bottleneck 模块替换成 StarBlock[28]。其核心改进包含 3 个方面，首先采用动态特征增强机制，通过双分支架构实现通道交互，其中 F1 分支采用 1×1 卷积扩展通道实现特征增强，F2 分支保持原始通道数，通过逐元素乘法实现通道交互，在增强重要通道

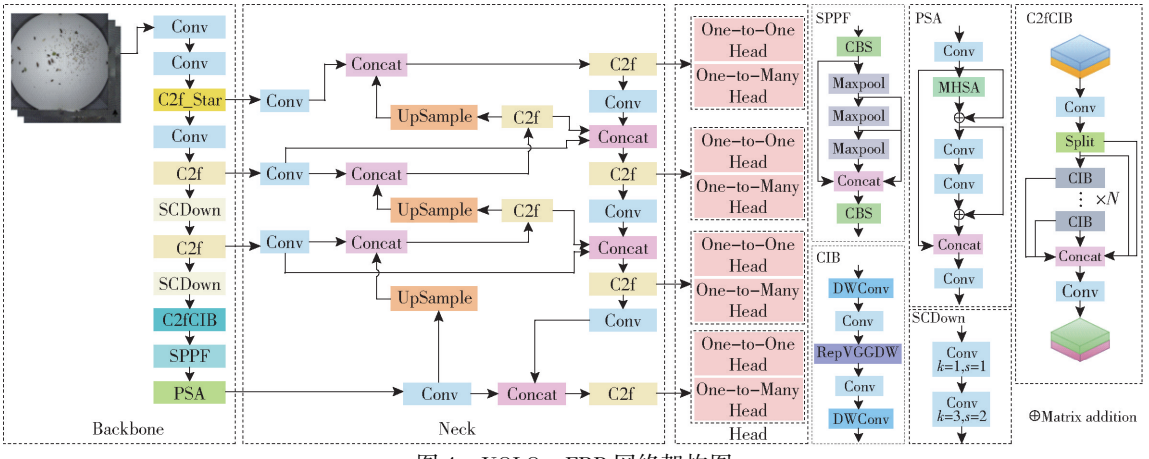


图 4　YOLO－FRP 网络架构图

Fig. 4　Architecture diagram of YOLO－FRP network

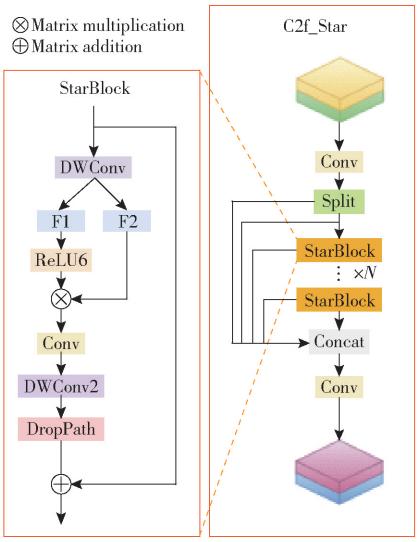


图 5 C2f_Star 模块结构图

Fig. 5 Structure diagram of C2f_Star module

响应的同时压制噪声。其次,采用深度可分离卷积作为基础特征提取器,在扩大感受野的同时,通过通道压缩策略减少参数量。最后集成 DropPath 正则化,在残差连接末端随机丢弃部分路径,强制模型分散特征学习焦点,缓解过拟合问题,提升对小样本害虫数据的泛化能力。

该设计应用于主干 P2 高分辨率特征层以保留更多小目标细节,减少特征平滑损失,达到计算效率与检测精度平衡。

(4)C2fCIB 模块。在主干网络 P5 层后引入基于 YOLO v10s 的 C2fCIB 模块,通过条件标识块 CIB 增强对小目标细节的提取。CIB 单元采用深度可分离卷积构建空间特征提取路径,通过缩放因子实现通道动态缩放,同时利用 lk(Large kernel)标志位自适应调整卷积结构,通过 shortcut 标记位实现条件化残差连接,将原始输入特征与细节特征融合,避免深层网络因下采样导致虫体边缘信息丢失。替换 C2f 模块后,模型在降低计算量的同时,提升了网络深层对虫体边缘细节的捕捉能力。

(5)基于逻辑的知识蒸馏[29](Knowledge distillation,KD)。使用的知识蒸馏以逻辑损失为主导,通过最小化学生模型与教师模型指定特征输出层的绝对差异实现知识迁移。具体而言,对比 L1、L2[30]逻辑蒸馏框架,用改进 YOLO v10s 即 YOLO-Teacher 作为教师模型,强制学生模型和教师模型的输出分布对齐并将损失权重设为常量以确保训练稳定性。为了使学生模型与教师模型的输出通道对齐,教师模型同样使用 BiFPN 和小目标层结构,并在主干网络浅层引入高效多尺度注意力机制(Efficient multi-scale attention,EMA),以提升高分辨率图像的小目标特征获取能力。同时,针对害虫可能呈现弯曲状态的情况,在教师模型主干网络 P5 层后将 C2f 模块替换为动态蛇形卷积模块 C2f_DySnakeConv,能够自适应优化细小弯曲目标的特征提取精度。L_1、L_2 蒸馏公式为

$$L_1 = \frac{1}{N}\sum_{i=1}^{N} |F_S^{(i)} - F_T^{(i)}| \tag{1}$$

$$L_2 = \frac{1}{N}\sum_{i=1}^{N} (F_S^{(i)} - F_T^{(i)})^2 \tag{2}$$

式中 L_1、L_2——不同的蒸馏损失算法

$F_S^{(i)}$——学生模型第 i 层特征图输出

$F_T^{(i)}$——教师模型第 i 层特征图输出

N——特征图总元素数

采用逻辑损失函数和常数损失权重衰减方式针对模型输出层进行蒸馏,公式为

$$D_{KL}(P \| Q) = \sum_i P(x_i) \lg \frac{P(x_i)}{Q(x_i)} \tag{3}$$

$$L_{logical} = T^2 D_{KL}\left(\sigma\left(\frac{z_S}{T}\right) \middle\| \sigma\left(\frac{z_T}{T}\right)\right) \tag{4}$$

$$\lambda_{KD}(t) = \lambda_0 \quad (t = 1, 2, \cdots, T_{\max}) \tag{5}$$

式中 D_{KL}——KL 散度 t——蒸馏训练轮次

$L_{logical}$——逻辑损失函数

$P(x_i)$——教师模型输出分布

$Q(x_i)$——学生模型输出分布

T——用于平滑分布的温度系数

σ——用于归一化的 Softmax 函数

z_S——学生模型输出 logits

z_T——教师模型输出 logits

λ_0——初始逻辑损失权重

$T_{\max}$——蒸馏训练的最大迭代轮次

(6)基于分层自适应幅度剪枝方法(Layer-adaptive magnitude-based pruning,LAMP)[31]。为了满足模型轻量化部署需求,在知识蒸馏基础上,采用 LAMP 对模型进行结构化稀疏,通过评估分层权重的重要性实现定向剪枝。首先,对权重向量按绝对值降序排列并对每个权重作归一化处理,在设定全局剪枝率阈值后,对比累积的 LAMP 得分与剪枝率,依次移除冗余低分权重,保留关键特征,计算 LAMP 得分,即

$$s(W_\mu) = \frac{W_\mu^2}{\sum_{v \geqslant \mu} W_v^2} \tag{6}$$

式中 W_μ——权重张量展平后索引为 μ 的权重

v——所有大于等于 μ 的权重项

W_v——权重张量展平后索引为 v 的权重

LAMP 能够在保持较高模型性能的前提下有效减少模型参数量,从而达到轻量化和加速推理的目的。

1.3 实验设计

1.3.1 实验平台

实验在 Ubuntu 22.04(64 位)操作系统下开展，硬件配置为 RTX 4090 GPU、120 GB 内存、24 GB 显存、Intel(R) Xeon ® Platinum 8352V CPU，软件环境为 Pytorch 2.1.2、CUDA 11.8 以及 Python 3.10。训练批次设置为 8，迭代轮次为 300，初始学习率为 0.01，权重衰减系数为 0.000 5，学习率动量为 0.937，模型知识蒸馏训练迭代轮次为 300，剪枝后微调阶段迭代轮次为 500。

1.3.2 评价指标

采用精确率(Precision，P)、召回率(Recall，R)、平均精度均值(mean Average Precision，mAP)、浮点运算量、模型参数量、模型内存占用量和帧率作为评价指标。

2 结果与分析

2.1 消融实验

为了验证 YOLO - FRP 模型各项改进的有效性，在自制数据集测试集上开展消融实验，结果如表 2 所示。由表 2 可知，相较于 YOLO v10n，不同的改进组合均实现不同程度的性能提升。引入 BiFPN 结构可使模型显著减少浮点运算量、参数量和模型内存占用量，但因上采样最高仅到达 P3 层，导致精确率、召回率和平均精度均值均下降。进一步添加 P2 小目标层，较添加前模型精确率提升 1.5 个百分点、召回率提升 3.1 个百分点、mAP@0.5 提升 1.6 个百分点。紧接着将模型主干 P2 层的 C2f 模块替换为 C2f_Star，较添加前召回率提高 2.1 个百分点，mAP@0.5 提高 0.5 个百分点，同时浮点运算量也有所降低。若不引入 C2f_Star 而只将模型 P5 层 C2f 模块改为 C2fCIB 模块，参数量和模型内存占用量都有明显降低。若在引入 C2f_Star 的基础上于主干 P5 层引入 C2fCIB 模块，较 YOLO v10n 召回率、mAP@0.5 分别提升 5.2、1.7 个百分点，参数量降至其 72.25%，模型内存占用量减少 1.2 MB，且推理速度未受影响，证明 C2f_Star 和 C2fCIB 模块联合引用的有效性。

表 2　消融实验结果

Tab.2　Ablation experiment results

BiFPN	P2	C2f_Star	C2fCIB	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	帧率/(f·s^{-1})	模型内存占用量/MB
×	×	×	×	78.2	74.3	80.4	6.50×10^{9}	2.27×10^{6}	313	5.5
√	×	×	×	77.8	74.1	79.8	6.00×10^{9}	1.72×10^{6}	288	4.2
√	√	×	×	79.3	77.2	81.4	1.23×10^{10}	1.86×10^{6}	219	4.8
√	√	√	×	77.2	79.3	81.9	1.22×10^{10}	1.86×10^{6}	285	4.8
√	√	×	√	79.2	75.3	80.1	1.21×10^{10}	1.64×10^{6}	205	4.3
√	√	√	√	75.3	79.5	82.1	1.21×10^{10}	1.64×10^{6}	312	4.3

注：√表示使用该模块，×表示不使用该模块。

2.2 蒸馏与剪枝

2.2.1 蒸馏实验参数设置

为平衡引入 P2 高分辨率小目标层所导致计算开销增加的问题，且进一步满足精度需求，采用蒸馏剪枝协同策略，使用基于 YOLO v10s 改进的 YOLO - Teacher 模型，通过 L1、L2 特征对齐损失与 KL 逻辑损失指导 YOLO - FRP 学生模型提高检测精度。

2.2.2 蒸馏实验结果对比

由表 3 可知，基于 L2 特征对齐的蒸馏方法对模型性能的优化效果更好。与蒸馏前相比，在模型复杂度不变的前提下，精确率和 mAP@0.5 分别提升 12.1、2 个百分点，推理速度相对提升 10.26%，达到 344 f/s。相较于 L1 损失，L2 损失平方误差特性对离群点信息更加敏感，放大了学生模型与教师模型输出特征间的显著差异，由于蒸馏损失权重设置为

表 3　不同蒸馏方法对比结果

Tab.3　Comparison result of different distillation methods

模型	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	帧率/(f·s^{-1})	模型内存占用量/MB
YOLO - Teacher	83.9	79.4	85.9	3.66×10^{10}	7.64×10^{6}	107	16.3
YOLO - FRP	75.3	79.5	82.1	1.21×10^{10}	1.64×10^{6}	312	4.3
YOLO - FRP + L1 distillation	83.8	75.9	83.4	1.21×10^{10}	1.64×10^{6}	316	4.3
YOLO - FRP + L2 distillation	87.4	74.1	84.1	1.21×10^{10}	1.64×10^{6}	344	4.3

常量,网络会优先拟合关键特征,从而在密集小目标场景下取得更优的检测精度。

2.2.3 剪枝实验参数设置与结果对比

为了解决模型浮点运算量大及部署问题,采用基于 LAMP 的全局自适应剪枝,设置剪枝率为 2,即模型压缩一倍,其余参数与蒸馏参数配置一致。剪枝效果如表 4 所示。结果表明,与剪枝前相比,虽然模型 mAP@0.5 下降 1.1 个百分点,但浮点运算量、参数量和模型内存占用量都显著下降,其中,浮点运算量从 1.21×10^{10} 下降至 6.7×10^{9},参数量从 1.64×10^{6} 缩减至 7.8×10^{5},相对降幅超 50%,模型内存占用量也从 4.3 MB 压缩至 2.4 MB,推理速度达到较高水平,基本满足虫情监测设备的实时性要求,在精度与效率间取得有效平衡。图 6 为 YOLO v10n 与 YOLO-FRP 蒸馏剪枝后模型的混淆矩阵对比,其中,横纵坐标标签相同,依次为稻飞虱、突背斑红蝽、稻绿蝽、二化螟、稻纵卷叶螟,可以看到最终模型在大部分害虫种类上的精度表现都优于 YOLO v10n,进一步证明模型改进和蒸馏剪枝联合策略的有效性,能够在性能与效率之间实现有效平衡。

表 4 蒸馏模型剪枝实验结果对比

Tab.4 Comparison result of distilled models after pruning

模型	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	帧率/(f·s^{-1})	模型内存占用量/MB
YOLO v10n	78.2	74.3	80.4	6.50×10^{9}	2.27×10^{6}	313	5.5
YOLO-FRP	75.3	79.5	82.1	1.21×10^{10}	1.64×10^{6}	312	4.3
+L2 distillation	87.4	74.1	84.1	1.21×10^{10}	1.64×10^{6}	344	4.3
+LAMP pruning	79.1	77.0	83.0	6.70×10^{9}	7.80×10^{5}	471	2.4

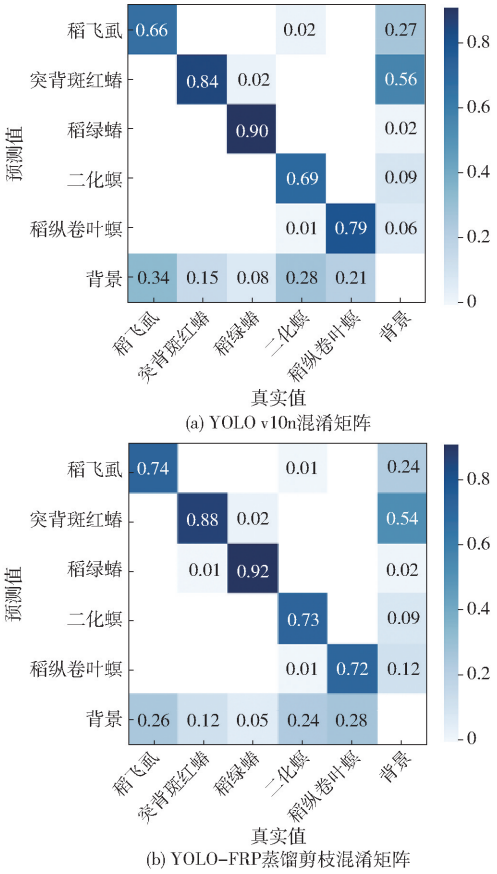


图 6 混淆矩阵对比

Fig.6 Comparison of confusion matrix

2.3 不同模型性能对比

为验证本研究所提出算法的性能优越性与轻量化改进的有效性,将蒸馏剪枝优化前后的 YOLO-FRP 模型与 RT-DETR-R18、YOLO v5n、YOLO v8n、YOLO 11n 等主流检测算法在相同条件下进行对比,结果如表 5 所示。Faster R-CNN 模型精度不足且体积过大,无法满足害虫检测任务需求,RT-DETR-R18 作为基于 Transformer 的端到端检测模型,在参数量和浮点运算量上相较 Faster R-CNN 有一定优势,但是与 YOLO 系列模型相比,其在检测速度与小目标识别精度上无显著优势。在 YOLO 系列模型的对比中,改进 YOLO v10n 模型(YOLO-FRP)的 mAP@0.5 较 YOLO v5n、YOLO v8n、YOLO 11n 分别提高 3.1、2.5、2.2 个百分点,较 YOLO v10n 提高 1.7 个百分点,证明研究所提方法对 YOLO v10n 改进的有效性。

经过蒸馏剪枝联合优化后,改进 YOLO v10n 模型(YOLO-FRP)在保持较高检测性能的同时,实现了模型轻量化,相较于 YOLO v10n,召回率提高 2.7 个百分点,mAP@0.5 提高 2.6 个百分点,参数量降低 65.64%,模型内存占用量缩小 56.36%,推理速度相对提高 50.48%,使得模型可以更高效地运行在虫情监测设备上,模型训练过程的 mAP@0.5 变化如图 7 所示。

2.4 模型特征可视化

为直观展示 YOLO-FRP 对害虫识别能力的提升,采用 Grad-CAM++(Gradient-weighted class activation mapping++)[32]方法生成可视化热力图。通过计算目标类别对最后一层卷积特征图的高阶梯度构造权重系数,再将各像素梯度权重与特征图进行线性组合,最终生成热力图。热力图中的明亮区域对应模型预测时依赖的关键特征区域,较暗区域表明对决策影响较小,能更直观验证模型在害虫识别任务中的特征定位能力和决策依据。由图 8 可知,YOLO-FRP 在非背景目标区域的感知能力更

表 5　对比实验结果

Tab. 5　Comparative experiment result

模型	精确率/%	召回率/%	mAP@0.5/%	浮点运算量	参数量	帧率/(f·s^{-1})	模型内存占用量/MB
Faster R－CNN（ResNet50）	53.5	68.2	59.8	2.02×10^{11}	4.13×10^{7}	70	158.2
RT－DETR－R18	78.3	77.9	80.9	5.94×10^{10}	2.02×10^{7}	104	38.5
YOLO v5n	81.1	74.8	79.0	4.10×10^{9}	1.77×10^{6}	270	3.7
YOLO v8n	79.8	72.9	79.6	8.10×10^{9}	3.00×10^{6}	350	6.0
YOLO 11n	78.1	73.6	79.9	6.30×10^{9}	2.58×10^{6}	328	5.3
YOLO v10n	78.2	74.3	80.4	6.50×10^{9}	2.27×10^{6}	313	5.5
YOLO－FRP	75.3	79.5	82.1	1.21×10^{10}	1.64×10^{6}	312	4.3
YOLO－FRP（KD）	87.4	74.1	84.1	1.21×10^{10}	1.64×10^{6}	344	4.3
YOLO－FRP（KD＋P）	79.1	77.0	83.0	6.70×10^{9}	7.80×10^{5}	471	2.4

注：KD 表示知识蒸馏，P 表示剪枝。下同。

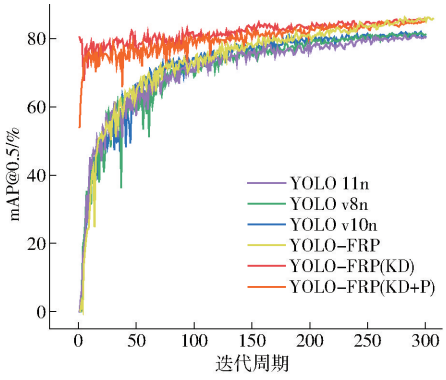


图 7　模型训练精度对比

Fig. 7　Comparison of model training accuracy

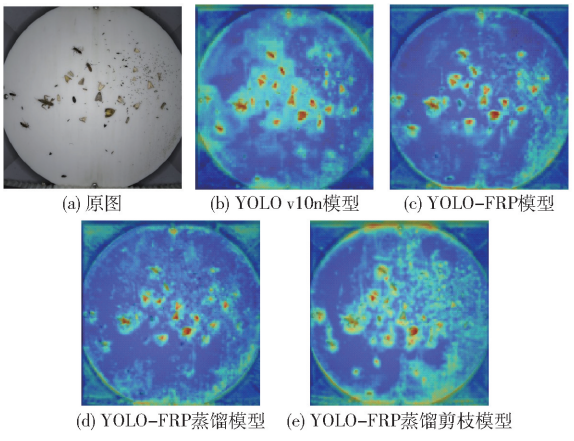


图 8　不同处理阶段模型可视化热力图

Fig. 8　Visualization heat maps of models under different configurations

强，而蒸馏剪枝后的模型进一步提升识别精度，检测到更多遗漏的目标。

YOLO－FRP、蒸馏后 YOLO－FRP 以及蒸馏剪枝后 YOLO－FRP 3 种不同阶段的改进模型在不同复杂背景下检测对比可视化如图 9 所示，在目标数量较少、目标数量适中和目标数量较多情况下，YOLO－FRP 可以识别出更多害虫目标，证明该算法可以改善小目标害虫难以识别的问题。根据密集目标识别结果对比可以看出，YOLO－FRP 能够检测到

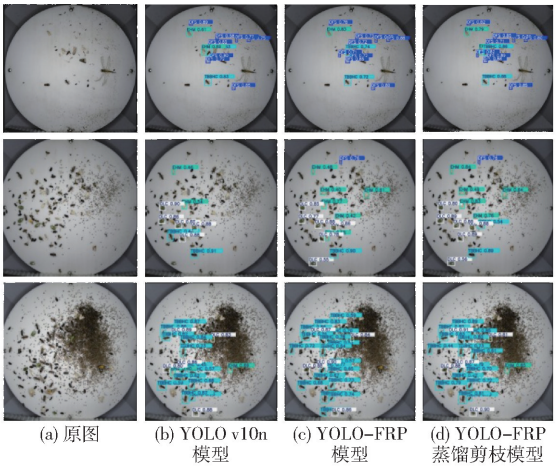


图 9　不同处理阶段模型目标检测对比实验结果

Fig. 9　Comparison results of target detection for models in different processing stages

堆叠虫群中的正确目标，证明其检测能力优于 YOLO v10n，而蒸馏剪枝后的 YOLO－FRP 在检测准确率上和 YOLO－FRP 大致相同，但是综合资源开销、推理速度等因素，轻量化后模型平衡了精度与资源消耗，总体上更占优势。

然而，蒸馏-剪枝策略性能表现受限于数量庞大的超参数调试与优化，后续将探究更多的参数配置以挖掘该策略的模型轻量化潜力。

3　结论

（1）针对虫情测报杀虫灯下水稻害虫小目标检测存在的虫体密度大、体积小、检测精度低以及精度与轻量化平衡等难题，提出基于 YOLO v10n 改进的检测算法 YOLO－FRP。该方法构建 BiFPN 与 P2 小目标层协同的双分支多特征融合网络，实现小目标检测性能提升，在浅层网络中采用轻量级 C2f_Star 模块强化小目标特征提取能力，在深层网络中引入 C2fCIB 模块，既优化多尺度特征融合效果，又有效降低模型参数量。消融实验结果表明，改进 YOLO v10n 模型平均精度均值、召回率较改进前提升 1.7、

5.2 个百分点,参数量下降 27.75%。

(2)采用蒸馏-剪枝联合策略实现目标检测模型高效轻量化,以改进 YOLO v10n(YOLO-FRP)作为学生模型,以改进 YOLO v10s(YOLO-Teacher)作为教师模型进行知识蒸馏,通过教师模型的特征引导增强学生模型的特征提取能力;在此基础上,再引入 LAMP 剪枝算法剔除冗余参数,进一步实现轻量化。实验结果表明,经蒸馏-剪枝联合策略优化后的 YOLO-FRP 模型平均精度均值(mAP@0.5)达到 83%,较优化前提升 2.6 个百分点,帧率为471 f/s,相对增幅高达 50.48%,参数量和模型内存占用量分别减少 65.64%、56.36%,满足虫情监测设备水稻害虫实时检测需求。

(3)热力图与对比实验结果证明了改进模型的有效性。热力图表明,模型改进与剪枝蒸馏策略使模型能有效增强模型对目标区域的感知能力;对比实验结果表明,改进后的 YOLO v10n(YOLO-FRP)较 YOLO 11n、YOLO v8n 等模型精度均具优势,证明改进的有效性。而经过蒸馏剪枝处理后的YOLO-FRP参数量、模型内存占用量、推理速度均优于其他对比模型,证明蒸馏-剪枝联合策略在兼顾精度与轻量化方面的有效性。

参 考 文 献

[1] 冉一茜,张熙. 农作物病虫害防治与农业生态的可持续发展探讨[J]. 农业灾害研究,2023,13(12):13-15.
RAN Yiqian, ZHANG Xi. Discussion on prevention and control of crop diseases and pests and sustainable development of agricultural ecology[J]. Journal of Agricultural Catastrophology, 2023,13(12):13-15. (in Chinese)

[2] 董伟,钱蓉,张洁,等. 基于深度学习的蔬菜鳞翅目害虫自动识别与检测计数[J]. 中国农业科技导报,2019,21(12):76-84.
DONG Wei, QIAN Rong, ZHANG Jie, et al. Vegetable lepidopteran pest auto recognition and detection counting based on deep learning[J]. Journal of Agricultural Science and Technology 2019, 21(12):76-84. (in Chinese)

[3] 刘万才,刘振东,黄冲,等. 近 10 年农作物主要病虫害发生危害情况的统计和分析[J]. 植物保护,2016,42(5):1-9,46.
LIU Wancai, LIU Zhendong, HUANG Chong, et al. Statistics and analysis of crop yield losses caused by main diseases and insect pests in recent 10 years[J]. Plant Protection, 2016, 42(5):1-9,46. (in Chinese)

[4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[5] 刘乐源,李湘叶,蓝天,等. 区块链系统中反洗钱技术研究综述[J]. 中国工程科学,2025,27(2):287-303.
LIU Leyuan, LI Xiangye, LAN Tian, et al. A survey on anti-money laundering techniques in blockchain systems[J]. Strategic Study of Chinese Academy of Engineering, 2025, 27(2): 287-303. (in Chinese)

[6] 石军,王天同,朱子琦,等. 基于深度学习的医学图像分割方法综述[J]. 中国图象图形学报,2025,30(6):2161-2186.
SHI Jun, WANG Tiantong, ZHU Ziqi, et al. Deep learning-based medical image segmentation methods[J]. Journal of Image and Graphics, 2025, 30(6): 2161-2186. (in Chinese)

[7] 胡可柏. 基于深度学习的农林业害虫检测方法研究[D]. 北京:北京林业大学,2021.
HU Kebo. Research on the detection method of agriculture and forestry pests based on deep learning[D]. Beijing: Beijing Forestry University, 2021. (in Chinese)

[8] REDMON J, FARHADI A. YOLO v3: an incremental improvement[J]. arXiv: 1804.02767,2018.

[9] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2020:213-229.

[10] XIANG Q, HUANG X, HUANG Z, et al. Yolo-Pest: an insect pest object detection algorithm via CAC3 module[J]. Sensors, 2023, 23(6): 3221.

[11] 赵辉,黄镖,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.
ZHAO 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)

[12] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.

[13] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient iou loss for accurate bounding box regression[J]. Neurocomputing, 2022,506: 146-157.

[14] 刘双喜,王云飞,张宏建,等. 基于形色筛选的苹果园羽化害虫粘连图像分割方法[J]. 农业机械学报,2024,55(3):263-274.
LIU Shuangxi, WANG Yunfei, ZHANG Hongjian, et al. Image segmentation of apple orchard feathering pest adhesion based on shape-color screening[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(3):263-274. (in Chinese)

[15] HU Y, DENG X, LAN Y, et al. Detection of rice pests based on self-attention mechanism and multi-scale feature fusion[J].

Insects, 2023, 14(3): 280.
[16] JIAO L, LI G, CHEN P, et al. Global context-aware-based deformable residual network module for precise pest recognition and detection[J]. Frontiers in Plant Science, 2022, 13: 895944.
[17] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10778 - 10787.
[18] LIU Z, LIN Y, CAO Y, et al. Swin Transformer: hierarchical vision transformer using shifted windows[C]// IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 9992 - 10002.
[19] 姚青,吴叔珍,蒯乃阳,等. 基于改进 CornerNet 的水稻灯诱飞虱自动检测方法构建与验证[J]. 农业工程学报,2021,37(7):183 - 189.
YAO Qing, WU Shuzhen, KUAI Naiyang, et al. Automatic detection of rice planthoppers through light-trap insect images using improved CornerNet[J]. Transactions of the CSAE, 2021,37(7):183 - 189. (in Chinese)
[20] LAW H, DENG J. CornerNet: detecting objects as paired keypoints[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 765 - 781.
[21] 郑果,姜玉松,沈永林. 基于改进 YOLO v7 的水稻害虫识别方法[J]. 华中农业大学学报,2023,42(3):143 - 151.
ZHENG Guo, JIANG Yusong, SHEN Yonglin. Recognition of rice pests based on improved YOLO v7[J]. Journal of Huazhong Agricultural University, 2023,42(3):143 - 151. (in Chinese)
[22] HOWARD A, SANDLER M, CHEN B, et al. Searching for mobileNetV3[C]// IEEE/CVF International Conference on Computer Vision (ICCV), 2019:1314 - 1324.
[23] 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)
[24] 彭红星,徐慧明,高宗梅,等. 基于改进 YOLOF 模型的田间农作物害虫检测方法[J]. 农业机械学报,2023,54(4):285 - 294,303.
PENG Hongxing, XU Huiming, GAO Zongmei, et al. Insect pest detection of field crops based on improved YOLOF model[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(4):285 - 294,303. (in Chinese)
[25] 王艳青. 近年来中国水稻病虫害发生及趋势分析[J]. 中国农学通报,2006(2):343 - 347.
WANG Yanqing. Analysis on the occurrence and development of rice diseases and insects in China[J]. Chinese Agricultural Science Bulletin, 2006(2):343 - 347. (in Chinese)
[26] WANG Q J, ZHANG S Y, DONG S F, et al. Pest24: a large-scale very small object data set of agricultural pests for multi-target detection[J]. Computers and Electronics in Agriculture, 2020, 175: 105585.
[27] WANG A, CHEN H, LIU L, et al. YOLO v10: real-time end-to-end object detection[J]. arXiv Preprint, arXiv:2405.14458, 2024.
[28] MA X, DAI X, BAI Y, et al. Rewrite the stars[C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 5694 - 5703.
[29] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. arXiv: 1503.02531, 2015.
[30] ROMERO A, BALLAS N, KAHOU S E, et al. FitNets: hints for thin deep nets[J]. arXiv: 1412.6550, 2014.
[31] LEE J, PARK S, MO S, et al. Layer-adaptive sparsity for the magnitude-based pruning[C]// International Conference on Learning Representations (ICLR), Virtual Conference, 2021.
[32] CHATTOPADHYAY A, SARKAR A, HOWLADER P, et al. Grad - CAM + +: improved visual explanations for deep convolutional networks[C]// IEEE Winter Conference on Applications of Computer Vision (WACV), 2018: 839 - 847.