

doi:10.6041/j.issn.1000-1298.2026.20.015

基于改进 YOLO 11 与自适应通道 DepGraph 剪枝的轻量化水稻病虫害检测方法

李恩华^{1,2} 杨昊³ 刘孟祥⁴ 曾启明³ 骆超宇³ 闫梦若⁵ 李紫荷³ 周稀艳³

(1. 长沙工业学院软件工程学院, 长沙 410200; 2. 湖南信息职业技术学院软件学院, 长沙 410200;
3. 长沙学院计算机科学与工程学院, 长沙 410022; 4. 长沙工业学院产教融合与科研处, 长沙 410200;
5. 湖南科技职业学院软件学院, 长沙 410118)

摘要: 针对当前水稻病虫害深度学习识别模型参数量大、计算复杂度高,难以在资源受限的农业嵌入式终端实现实时检测的工程难题,本文提出一种面向边缘端部署的轻量化水稻病虫害检测方法 YOLO 11-DG。以 YOLO 11n 为基线模型,设计融合 FlexConv 通道动态匹配算法的 FC-C3K2 模块,有效解决了传统 C3K2 模块在结构化剪枝过程普遍存在的通道维度失配问题;在损失函数层面,提出引入归一化距离惩罚项的边界框回归损失函数 YIoU,显著缓解了 CIoU 损失在预测框与真实框高度重合时出现的梯度消失缺陷。在此基础上,引入 FC-DepGraph 结构化剪枝方法构建模型轻量化框架,实现了剪枝过程跨模块通道的自动对齐,大幅提升了剪枝效率与模型压缩性能。试验结果表明,YOLO 11-DG mAP50 达到 84.5%,参数量仅 2.36×10^6 ,浮点运算量降至 2.6×10^9 。相较于 YOLO 11n mAP50 提升 12.4 个百分点,参数量减少 21.3%,浮点运算量降低 49.0%;与 YOLO v8-Corn、YOLO 11-LAMP、SCD-YOLO 11 等典型方法相比,均表现出显著优势,可为资源受限边缘端水稻病虫害实时检测提供技术支撑。

关键词: 水稻病虫害识别; YOLO 11; DepGraph 依赖图剪枝; 自适应通道剪枝; 轻量化模型

中图分类号: S435; TP391.4 文献标识码: A 文章编号: 1000-1298(2026)20-0163-09 OSID: 

Lightweight Rice Pest and Disease Detection Method Using Improved YOLO 11 with Adaptive Channel-wise FC-DepGraph Pruning

Li Enhua^{1,2} Yang Hao³ Liu Mengxiang⁴ Zeng Qiming³ Luo Chaoyu³ Yan Mengruo⁵
Li Zihe³ Zhou Xiyan³

(1. School of Software Engineering, Changsha Institute of Technology, Changsha 410200, China
2. School of Software, Hunan College of Information, Changsha 410200, China
3. School of Computer Science and Engineering, Changsha University, Changsha 410022, China
4. Office of Industry-Education Integration and Scientific Research, Changsha Institute of Technology, Changsha 410200, China
5. School of Software, Hunan Vocational College of Science and Technology, Changsha 410118, China)

Abstract: Aiming to address the challenge of deploying deep learning models with large parameter sizes and high computational costs for rice pest and disease detection on resource-constrained agricultural edge devices, a lightweight method, YOLO 11-DG was proposed. With YOLO 11n as the baseline, an FC-C3K2 module incorporating a FlexConv dynamic channel matching mechanism was designed to resolve the channel dimension mismatch that occurred with the original C3K2 during structured pruning. A bounding box regression loss, YIoU, containing a normalized distance penalty term was introduced to alleviate the gradient vanishing problem of CIoU when predicted and ground-truth boxes were highly overlapped. On this basis, an FC-DepGraph structured pruning framework was constructed to automatically align channels across modules during pruning, significantly improving pruning efficiency and model compression. Experimental results showed that YOLO 11-DG achieved an mAP50 of 84.5%, with only

收稿日期: 2026-06-02 修回日期: 2026-07-05
基金项目: 湖南省自然科学基金项目(2026JJ80017)、湖南信息职业技术学院校级重点课题(2025hniukt03)和湖南省教育厅科学研究重点项目(25A0793)
作者简介: 李恩华(1989—),男,讲师,主要从事目标检测和算法优化研究,E-mail:2021051@mail.hnui.cn
通信作者: 刘孟祥(1973—),男,教授,博士,主要从事智能制造和智能算法研究,E-mail:liumengxiang@ccsut.edu.cn

2.36×10^6 parameters and 2.6×10^9 FLOPs. Compared with the baseline YOLO 11n, the mAP50 was increased by 12.4 percentage points, the number of parameters was reduced by 21.3%, and the computational cost dropped by 49.0%. The method also outperformed YOLO v8 - Corn, YOLO 11 - LAMP, and SCD - YOLO 11, providing an effective lightweight solution for real-time rice pest and disease detection on edge devices.

Key words: rice pest and disease detection; YOLO 11; DepGraph dependency graph pruning; adaptive channel pruning; lightweight model

0 引言

我国是水稻种植大国,病虫害常年频发已成为制约我国水稻安全生产的关键因素,特别是稻飞虱、稻纵卷叶螟、二化螟以及稻瘟病、水稻纹枯病等“三虫两病”发生范围广、危害程度重^[1],是当前水稻病虫害监测与防控的重点对象。传统水稻病虫害识别与监测主要依赖基层农技人员专业素养和农户种植经验,存在时效性差、主观性强、覆盖面有限等不足^[2-4],难以满足规模化种植条件下精准防控的现实需求。

近年来,基于卷积神经网络的目标检测方法因在实现高精度检测的同时保持实时推理速度的特点,逐渐成为智慧农业领域的研究热点。特别是以 YOLO(You only look once)系列为代表的单阶段目标检测算法,在农作物病虫害检测、表型分析、杂草识别等农业场景中展现出显著的实时性与鲁棒性优势,是当前智慧农业领域视觉感知任务的重要技术基础^[5-8]。随着农业边缘设备检测的需求日益增长,YOLO 系列模型正持续向轻量化架构方向演进,为农田实时监测提供了可行的技术路径^[9-10]。但当前 YOLO 模型依然存在参数量大、计算开销高,难以在资源受限的边缘设备上直接部署等限制,亟须通过轻量化优化加以解决^[11]。

YOLO 轻量化技术主要通过模型改进和模型压缩实现:模型改进,即通过引入 ShuffleNet、GhostNet 等轻量级模块重构骨干网络,或采用部分卷积(PConv)等高效算子降低特征提取的计算冗余;模型压缩,是以剪枝、量化和知识蒸馏为代表的技术^[12]。Altaie 等^[13]认为将上述 2 种策略有机结合能在保持检测精度的同时显著压缩模型体积与运算量。面向实际部署任务,Zhai 等^[14]系统总结了视觉检测深度网络的边缘部署知识体系,涵盖模型选择、部署优化方法、边缘计算框架及部署设备等关键技术环节。董甲东等^[15]对当前目标检测算法的轻量化技术进行了系统综述,指出资源受限设备实时推理是当前研究面临的核心挑战。

在模型压缩技术中,结构化通道剪枝因能直接

移除冗余参数与通道、与硬件加速高度适配,已成为研究的主流方向^[16]。Sabaghian 等^[17]为 YOLO v8 设计了三阶段压缩框架,将模型参数压缩 73.5%,全类别 mAP50 下降 2.7 个百分点。王晓军等^[18]提出的面向硬件对齐的通道剪枝可有效削减 YOLO v8 参数量。DepGraph(Dependency graph)依赖图剪枝方法通过建模网络层间的相互依赖关系,实现跨架构的自动化剪枝^[19],具有较好的剪枝效果。当前,DepGraph 剪枝应用已从 YOLO v5/v8 拓展至 YOLO 11^[20],并应用在农业检测场景中。Liu 等^[21]提出的 SCD - YOLO 11n 结合 DepGraph 剪枝与通道级蒸馏,将稻田病害检测模型压缩至 1.9 MB,实测推理速度达 184 f/s。Dai 等^[22]同样验证了 DepGraph 结构化剪枝对 YOLO 模型的有效压缩效果,剪枝后浮点运算量与参数量分别降至原 YOLO v8 的 29.6% 和 10.2%。然而,高剪枝率下病虫害微小病斑等细粒度特征易丢失、剪枝率与精度的平衡缺乏标准化评估框架,以及现有剪枝方法对 YOLO 11 中 C3k2 等新型模块的依赖关系有待深入,仍是当前面临的核心瓶颈^[11]。

综上,YOLO 系列目标检测方法已成为水稻病虫害检测的研究热点,关于 YOLO 的轻量化研究已形成“模型改进 + 模型压缩”的技术主线,但当前面向 YOLO 11 的剪枝适配与优化研究尚不充分。其中,DepGraph 剪枝作为一种高效跨架构的模型轻量化方案,部分学者已尝试应用到 YOLO 11 中,但传统 DepGraph 剪枝方法无法精准适配 YOLO 11 中 C3k2 等新型模块,限制了剪枝效果和应用。

针对边缘计算场景下水稻病虫害实时检测对模型轻量化的迫切需求,本文提出一种基于改进 YOLO 11 与自适应通道 DepGraph 剪枝的轻量化检测方法 YOLO 11 - DG。在模型改进上,设计融合 Flex - Concat 机制的 FC - C3K2 模块,实现剪枝过程通道数量的自适应匹配,保证结构化剪枝的稳定执行;同时引入带有距离惩罚项的边界框回归损失 YIoU,缓解 CIoU 在预测框与真实框高度重合时的梯度消失问题,提升定位精度。在模型压缩上,构建 FC - DepGraph 依赖图剪枝框架,通过

显式建模层间通道依赖关系实现跨层协同剪枝，进一步提高压缩效率。以期在显著压缩模型参数量与计算量的同时，有效提升检测精度，为水稻病虫害在资源受限边缘端高效部署提供轻量化解决方案。

1 试验材料

试验数据集由网络收集与实地拍摄 2 部分构成。网络采集数据为 Hadiur^[23] 发布于 Kaggle 平台的“Rice Leaf Spot Disease Annotated Dataset”数据集，共包含 3 567 幅水稻叶片图像，涵盖水稻铁甲虫 (Rice hispa)、穗颈瘟 (Neck blast)、窄褐斑病 (Narrow brown leaf spot)、叶烧病 (Leaf scald)、叶瘟病 (Leaf blast)、褐斑病 (Brown spot)、白叶枯病 (Bacterial leaf blight)、健康叶片共 8 个类别。该数据集已被用于水稻叶部病害检测的相关研究^[24]，但

存在样本总量有限、微小病斑漏标注等缺陷，本研究通过实地拍摄进一步补充数据集。实地拍摄设备为手机，拍摄时间为 2024 年 9 月—2025 年 9 月，拍摄地点为湖南省益阳市、长沙市望城区等水稻种植区，为充分反映田间复杂作业环境，拍摄时段覆盖 06:00—18:00，共拍摄 19 084 幅图像。

最终数据集包括 22 651 幅图像，涵盖象甲科 (Curculionidae)、飞虱科 (Delphacidae)、叶蝉科 (Cicadellidae)、管蓟马科 (Phlaeothripidae)、瘿蚊科 (Cecidomyiidae)、弄蝶科 (Hesperiidae)、草螟科 (Crambidae)、秆蝇科 (Chloropidae)、水蝇科 (Ephyridae)、夜蛾科 (Noctuidae)、蓟马科 (Thripidae)、细菌性叶枯病 (Bacterial leaf blight)、叶斑病 (Brown spot)、稻叶黑粉病 (Leaf smut)、稻叶瘟病 (Leaf blast) 共 15 种常见水稻虫害与病害。数据集样本示例如图 1 所示。




图 1 数据集图像示例

Fig. 1 Illustration of dataset images

数据集具体处理流程：①图像预处理：对原始图像进行人工筛选，剔除因拍摄模糊或病害特征不可辨识的低质量样本，并将图像尺寸统一缩放至 640 像素 × 640 像素。②数据标注：采用 LabelMe 工具，按照 YOLO 格式对筛选后图像进行人工标注。③数据核验：由专业技术人员随机抽检，核实标注信息的真实性与准确性，确保数据集质量可靠。

表 1 为最终数据集中病虫害类别的样本、训练集、验证集、测试集数量，每幅图像至少包含 1 处标注的病虫害实例。受限于数据采集条件、病虫害分布以及危害常见程度的影响，采集数据中常见的病害类别更为充实，如叶斑病、稻叶黑粉病、稻叶瘟病；

部分虫害数据相对较少，如蝇科、夜蛾科。但考虑到虫害目标通常特征更为显著、检测难度相对较低，对样本量的需求相对较小，因此数据不均衡对模型训练的整体影响可控。

2 检测方法

2.1 改进 YOLO 11 模型

YOLO 11 模型是 Ultralytics 公司于 2024 年 9 月发布的单阶段通用目标检测模型，相对于 YOLO v8，YOLO 11 增加 1 个新的骨干模块 C3K2，同时使用 CIoU 作为回归损失函数，具有较好的性能表现，是当前 YOLO 系列主力版本。但 YOLO 11 在小目

表 1 水稻病虫害类别样本分布

Tab.1 Sample distribution of rice pest and disease categories				
名称	样本数量	训练集数量	验证集数量	测试集数量
象甲科	978	659	165	154
飞虱科	863	576	151	136
叶蝉科	750	493	139	118
管蓟马科	1 721	1 160	290	271
瘿蚊科	439	294	76	69
弄蝶科	466	330	63	73
草螟科	547	379	82	86
秆蝇科	182	121	32	29
水蝇科	991	649	186	156
夜蛾科	245	176	30	39
蓟马科	392	264	66	62
细菌性叶枯病	3 398	2 274	589	535
叶斑病	4 725	3 207	774	744
稻叶黑粉病	2 622	1 783	426	413
稻叶瘟病	4 332	2 902	748	682

标检测任务中易受噪声与遮挡干扰,且较高的内存消耗限制了其在资源严重受限场景下直接应用^[25-26]。YOLO 11-DG 模型结构如图 2 所示。

如图 2 所示,YOLO 11-DG 模型的改进主要有 2 点:①设计了融合 FlexConv 通道动态匹配算法的 FC-C3K2 模块,并使用 FC-C3K2 模块替换 C3K2 模块。②提出引入距离惩罚项的边界框回归损失函数 YIoU。

2.1.1 FC-C3K2 模块

C3K2 模块是 YOLO 11 中用来替代 C2f/C3 的组合模块,结构如图 3a 所示。其中,标准卷积层 Conv 对输入特征图通道数具有严格约束,在结构化剪枝方法动态改变各层通道数过程,一旦后续卷积层输入的特征图通道数及权重与期望不符,就会引发前向传播崩溃,造成剪枝失败。与此同时,结构化剪枝方法会动态改变 C3K2 模块内部各卷积层的实际输出通道数,造成拼接后通道数 actual_in_c 与




图 2 YOLO 11-DG 结构
Fig.2 Architecture of YOLO 11-DG

cv2 卷积层权重所期望的输入通道数 target_in_c 不匹配,导致剪枝出错。针对上述问题,设计了融合 FlexConv 通道动态匹配算法的 FC-C3K2 模块,如图 3b 所示,以实现动态通道切分与物理通道自适应对齐。

FC-C3K2 模块相较于 C3K2 模块进行了 3 处改进:①FlexConv1 替换 Conv1。将 Conv1 的标准卷积层替换为 FlexConv1,使其在接收输入特征图($c \times w \times h$, c 、 w 、 h 分别表示特征图通道数、高度、宽度)时能自动适配实际输入通道数,输出特征图($c \times w_1 \times h_1$)。由于 Conv1 步长固定为 1,空间尺寸保持不变($w_1 = w$, $h_1 = h$),FlexConv1 输出通道数与 Conv1 一致。②Ds-Split 替换 Split。将固定通道分割的 Split 替换为动态通道分割模块 Ds-Split。Ds-Split




图 3 C3K2 模块和 FC-C3K2 模块结构
Fig.3 Architectures of C3K2 and FC-C3K2 modules

根据 FlexConv1 实际输出的通道总数 c ,以 $c_1 = c/2$ 、 $c_2 = c - c_1$ 方式完成分割,始终保证 $c_1 + c_2 = c$,从根本上消除了 Split 因奇偶通道约束而崩溃的问题。

③ FlexConv2 替换 Concat + Conv2。将 Concat 与

Conv2 组合替换为单个 FlexConv2。FlexConv2 接收 Ds-Split 直接输出(c_1 分支,即跳跃连接)与 $C3k \times n$ 处理结果的拼接张量,通过 FlexConv 通道动态匹配算法实现自动对齐拼接后的实际通道数。

FlexConv 在拼接操作之后,执行 FlexConv 通道动态匹配算法,具体如下:①if actual_in_c == target_in_c,特征图直接通过,无需额外处理。②if actual_in_c > target_in_c,执行特征图通道裁剪操作,保留前 target_in_c 个通道,截断多余部分。③if actual_in_c < target_in_c,在特征图尾部补充零填充通道,使特征图通道数等于 target_in_c。

2.1.2 平滑回归损失函数 YIoU

目标检测任务中,损失函数通过同时约束分类与边界框回归的训练方向,直接决定模型定位精度与收敛质量,是影响检测性能的核心要素之一^[27-29]。YOLO 11 模型中损失函数由置信度、分类和回归损失组成,其中回归函数为 CIoU 函数。CIoU 函数在梯度下降过程,预测框宽度与高度无法同时朝正确方向优化,一方趋近真实值必然导致另一方偏离,从而限制了边界框回归精度。上述缺陷是影响 YOLO 11 在复杂图像检测任务效果的 1 个关键因素。为消除 CIoU 损失函数的上述缺点,提出 YIoU 函数替代 CIoU 函数引导模型回归。YIoU 函数定义为

$$L_{YIoU} = 1 - IoUP = 1 - IoUe^{-\alpha\Delta} \quad (1)$$

$$\text{其中} \quad P = e^{-\alpha\Delta} \quad (2)$$

$$\Delta = \frac{1}{4} \left(\frac{|x_1^p - x_1^g| + |x_2^p - x_2^g|}{w^g} + \frac{|y_1^p - y_1^g| + |y_2^p - y_2^g|}{h^g} \right) \quad (3)$$

式中 P ——YIoU 引入的距离惩罚项

Δ ——YIoU 距离惩罚项

α ——权重系数

$x_1^p, x_2^p, y_1^p, y_2^p$ ——预测框左、右、上、下坐标

$x_1^g, x_2^g, y_1^g, y_2^g$ ——真实框左、右、上、下坐标

h^g, w^g ——真实框高和宽

IoU ——交并比

YIoU 直接度量预测框 4 条边与真实框对应边的归一化坐标偏差,从而有效提升边界框定位精度。

联立式(2)、(3),对 P 求偏导,得

$$\begin{cases} \frac{\partial P}{\partial w_1} = \frac{\partial P}{\partial w_2} = \frac{1}{4w_{gt}} \\ \frac{\partial P}{\partial h_1} = \frac{\partial P}{\partial h_2} = \frac{1}{4h_{gt}} \end{cases} \quad (4)$$

式中 w_1, w_2 ——预测框左、右边界横坐标

h_1, h_2 ——预测框上、下边界纵坐标

w_{gt}, h_{gt} ——真实框宽、高

由式(4)可得, P 对 4 个边界坐标的梯度均为常数项,与预测框当前状态无关,无论重叠程度如何始终保持非零梯度,能够规避 CIoU 因预测框宽、高 w_{pre}, h_{pre} 偏导数趋近于零造成的梯度消失问题,提升模型定位精度与收敛稳定性。

2.2 FC-DepGraph 剪枝方法

目前 YOLO 算法中常用的结构化剪枝方法为范数剪枝和 BN 通道剪枝。其中,范数剪枝以通道权重的 L1/L2 范数作为重要性指标,剪除低范数通道,实现简单、速度快。BN 通道剪枝则利用 BatchNorm 层中缩放因子 γ 绝对值作为通道重要性的衡量指标,对 γ 较小的冗余通道予以剪除。但当网络存在残差连接、多分支结构、跨层依赖时,上述 2 种剪枝方法易导致通道维度不匹配、结构非法。

DepGraph 剪枝方法通过构建全局计算依赖图,精确建模层与层之间的通道关联与约束关系,对存在依赖关系的通道进行同步、协同剪枝,从而实现复杂网络下安全可靠的结构化剪枝。

图 4 为 DepGraph 剪枝方法流程,核心思想是先对网络执行 1 次前向追踪,构建层间依赖图,再通过求图的最大连通分量识别出必须同步剪枝的“剪枝组”,最后以组为单位整体移除参数。DepGraph 剪枝 Conv2 会沿依赖链自动触发 BN2、Conv1、BN1、Conv_sc、BN_sc 的联动剪枝。相较于传统范数剪枝和 BN 通道剪枝方法,DepGraph 剪枝方法不仅能自动处理残差连接、密集连接、多分支等任意复杂拓扑,省去针对特定网络手工设计剪枝规则的步骤,还拥有更优的重要性联合评估策略,剪枝精度损失更小,并且 DepGraph 剪枝方法可无缝迁移至 CNN、Transformer、RNN、GNN 等不同架构,能显著降低结构化剪枝的工程成本。




图 4 DepGraph 剪枝示意图

Fig. 4 Schematic of DepGraph pruning

但 DepGraph 方法在面向 YOLO 11 中 C3K2 等

新型复合模块时存在适配局限: C3K2 内部 Split 模块对通道数的奇偶性有严格要求, 而 DepGraph 依赖的建模机制无法感知这一约束, 剪枝过程一旦产生奇数通道输出, 会引发 Split 模块崩溃; 与此同时, Bottleneck 链和 cv2 之间的多路 Concat 通道数在剪枝后动态变化, DepGraph 剪枝方法亦无法自动完成物理对齐。为此, 设计 FC - DepGraph 剪枝方法, 如图 5 所示。




图 5 FC - DepGraph 剪枝流程

Fig. 5 FC - DepGraph pruning process

FC - DepGraph 剪枝通过将改进 YOLO 11 模型的通道依赖关系建模转换为可计算的有向图, 当剪枝到某一节点时, 首先判断是否为 FC - C3K2 模块, 若是, 则将目标保留通道数向上取整对齐至偶数, 再依照各通道的 L1 范数重要性执行剪枝, 最后对剪枝后通道进行物理对齐; 若不是, 则直接计算各通道的 L1 范数重要性并依此执行剪枝。2 条路径汇合后,

检查剪枝后各层通道是否对齐, 若对齐, 则对模型进行微调后输出压缩后模型; 若不对齐, 则回到判断是否为 FC - C3K2 模块处, 继续剪枝流程, 直到剪枝后通道对齐。FC - DepGraph 剪枝方法无需手动处理跨层、跨分支的依赖约束, 即可实现剪枝过程模块通道的自动对齐, 大幅降低了 DepGraph 剪枝方法在 YOLO 11 应用的出错率。

3 试验结果与分析

3.1 试验环境和评价指标

所用设备 GPU 为 NVIDIA A10, 内存为 32 GB, 操作系统为 CentOS 7, 基于深度学习框架 PyTorch 2. 7. 1 和 Python 3. 11 进行训练调试, 其中模型训练轮次均设置为 50, 剪枝率设置为 0. 25, 学习率设置为 0. 01。使用召回率、平均检测精度 (mAP)、模型参数量、浮点运算量作为评价指标, 对试验模型进行评价。

3.2 试验结果

YOLO 11n (YOLO 11 Nano) 是 YOLO 11 系列的轻量化版本, 尤其适合资源受限的边缘计算场景。选用 YOLO 11n 作为基线模型, 使用相同训练环境和数据集对 YOLO 11n、YOLO 11 - DG 方法进行训练。图 6 为 YOLO 11n 和 YOLO 11 - DG 2 种方法检测效果。

图 6 中对于 RP02160. jpg 图像目标检测任务, YOLO 11 - DG 与 YOLO 11n 模型相比, 检测框定位更为精准紧凑, 置信度评分由 0. 79 上升至 0. 92, 提升明显。图 6 其他检测任务中, YOLO 11 - DG 对病斑区域的边界回归均更贴近真实标注框, 同时对小目标病虫害漏检现象均有所改善, 整体检测效果明显优于 YOLO 11n。表 2 为 YOLO 11 - DG 对数据集中各类别病虫害检测结果。

由表 2 可知, 尽管数据集各类别的实例数分布




图 6 YOLO 11n 和 YOLO 11 - DG 检测效果

Fig. 6 Detection results between YOLO 11n and YOLO 11 - DG

表 2 YOLO 11 – DG 病虫害检测结果

Tab.2 Test results of YOLO 11 – DG for rice pest and disease detection

类别	图像数	实例数	召回率/ %	mAP50/ %	mAP50 – 95/ %
所有类别	3 817	9 659	76.2	84.5	56.2
象甲科	165	226	72.1	79.9	57.7
飞虱科	151	383	59.3	67.4	46.1
叶蝉科	139	179	68.2	74.7	47.5
管蓟马科	290	954	73.3	87.2	51.0
瘿蚊科	76	94	85.1	89.5	62.4
弄蝶科	63	64	89.1	94.9	71.2
草螟科	82	97	92.3	94.3	73.2
秆蝇科	32	35	62.9	74.9	54.7
水蝇科	186	232	83.6	90.5	64.2
夜蛾科	30	32	57.9	73.4	51.3
蓟马科	66	91	79.7	86.7	60.9
细菌性叶枯病	589	664	92.5	95.7	64.3
叶斑病	774	3 930	71.0	83.4	42.7
稻叶黑粉病	426	1 340	91.8	95.1	61.2
稻叶瘟病	748	1 338	64.1	80.5	34.4

不均,但模型在多数类别上检测性能表现稳定,召回率、mAP50 和 mAP50 – 95 类别间标准差分别为 11.9%、8.8% 和 10.4%,说明改进后模型对数据不平衡具有一定鲁棒性。

表 4 消融试验结果

Tab.4 Ablation study results

试验序号	改进 YOLO 11	FC – DepGraph	召回率/%	mAP50/%	mAP50 – 95/%	参数量	浮点运算量
1	×	×	66.2	72.1	50.6	3.00×10^6	5.1×10^9
2	×	√	72.5	80.4	54.3	2.36×10^6	2.6×10^9
3	√	×	66.1	77.3	51.6	3.00×10^6	5.1×10^9
4	√	√	76.2	84.5	56.2	2.36×10^6	2.6×10^9

注:√表示使用该方法,×表示未使用该方法。

由试验 2 结果可以看出,应用 FC – DepGraph 剪枝方法后,模型参数量和浮点运算量降幅分别约为 21.3% 和 49.0%。由于卷积计算量与输入输出通道数乘积成正比,通道缩减在计算维度上产生了远大于参数缩减的效果,这也是浮点运算量降幅明显高于参数量降幅的原因。与此同时,召回率由 66.2% 提升至 72.5%,mAP50 由 72.1% 提升至 80.4%,mAP50 – 95 由 50.6% 提升至 54.3%,是因为 FC – DepGraph 剪枝使模型结构更加紧凑,模型泛化能力得到改善。

由试验 3 结果可以看出,应用改进 YOLO 11 模型后,回归梯度在两框高度重合时仍能保持非零且方向独立,改善了边界框定位精度,在召回率保持基本一致的情况下,使 mAP50 由 72.1% 提升至 77.3%,mAP50 – 95 由 50.6% 提升至 51.6%。

为验证 YOLO 11 – DG 方法效果,与 YOLO 11n 基准模型进行检测效果对比,如表 3 所示。由表 3 可知,YOLO 11 – DG 与 YOLO 11n 相比,召回率提高 10 个百分点;mAP50 提高 12.4 个百分点;mAP50 – 95 提升 5.6 个百分点;参数量减少约 21.3%;浮点运算量减少约 49.0%。结果表明 YOLO 11 – DG 在精度提升的同时,显著降低模型复杂度,具有更好的轻量化特性,更适合在资源受限的场景中部署。

表 3 YOLO 11n 和 YOLO 11 – DG 检测效果

Tab.3 Detection results between YOLO 11n and YOLO 11 – DG

模型	召回率/%	mAP50/ %	mAP50 – 95/%	参数量	浮点运算量
YOLO 11n	66.2	72.1	50.6	3.00×10^6	5.1×10^9
YOLO 11 – DG	76.2	84.5	56.2	2.36×10^6	2.6×10^9

3.3 消融试验

为进一步验证 YOLO 11 – DG 中“模型改进 + 模型压缩”策略有效性,在相同训练环境、超参数设置下开展消融试验,分别测试本文改进 YOLO 11 模型和 FC – DepGraph 剪枝方法的作用。试验结果如表 4 所示。

试验 4 为本文 YOLO 11 – DG 方法,同时应用了 FC – DepGraph 剪枝方法和改进 YOLO 11 模型,实现了最优表现,不仅模型参数量由 3.00×10^6 降至 2.36×10^6 ,浮点运算量由 5.1×10^9 降至 2.6×10^9 ,召回率由 66.2% 提升至 76.2%,同时 mAP50 由 72.1% 提升至 84.5%,mAP50 – 95 由 50.6% 提升至 56.2%。

图 7 为消融试验精确度变化曲线,可以看到试验 4 在训练轮次大于 25 后,明显优于其他 3 种试验方法。

上述结果表明,本文提出的改进 YOLO 11 模型和 FC – DepGraph 剪枝方法均能有效提升 YOLO 11 的检测效果,同时 FC – DepGraph 剪枝方法能有效压缩 YOLO 11 模型,较 YOLO 11n 模型有较大的提升作用。




图7 消融试验精度变化曲线

Fig.7 Precision curves of ablation study

3.4 不同方法性能试验

为进一步证明本文方法有效性和优越性,将YOLO 11 - DG 与主流同类方法进行对比试验,对比的同类典型方法包括:YOLO v8 - Corn^[30]、YOLO 11 - LAMP^[31]、SCD - YOLO 11^[21]。

试验结果如表 5 所示。由表 5 可知,与当前主流的同类方法横向对比中,本文方法在检测精度与模型效率 2 个维度上均表现出明显优势。在检测精度方面,本文方法 mAP50 达到 84.5%,分别高于YOLO v8 - Corn (76.0%)、YOLO 11n (72.1%)、YOLO 11 - LAMP (76.4%) 和 SCD - YOLO 11 (76.2%),提升 8.1 ~ 12.4 个百分点。在 mAP50 - 95 上,本文方法同样以 56.2% 位居首位,分别高于

YOLO v8 - Corn (55.1%)、YOLO 11n (50.6%)、YOLO 11 - LAMP (54.2%) 和 SCD - YOLO 11 (54.6%),提升 1.1 ~ 5.6 个百分点,表明本文方法具备较强的鲁棒性。在召回率方面,本文方法以 76.2% 超过所有对比方法,表明改进模型能够检测出更多目标,漏检率更低。在模型轻量化方面,YOLO 11 - DG 参数量为 2.36×10^6 ,浮点运算量仅为 2.6×10^9 ,在所有对比模型中均为最低,比 SCD - YOLO 11 分别降低 2.9% 和 53.5%。表明本文对 C3K2 模块的改进有效压缩了模型体积,降低了计算开销,在保持高精度的同时具有更强的轻量化优势。不同方法性能试验结果如图 8 所示。

表 5 YOLO 11 - DG 与同类方法性能试验结果

Tab.5 Performance results between YOLO 11 - DG and comparable methods					
方法	召回率/%	mAP50/%	mAP50 - 95/%	参数量	浮点运算量
YOLO v8 - Corn	74.4	76.0	55.1	3.01×10^6	8.1×10^9
YOLO 11n	66.2	72.1	50.6	3.00×10^6	5.1×10^9
YOLO 11 - LAMP	68.8	76.4	54.2	2.59×10^6	6.1×10^9
SCD - YOLO 11	69.6	76.2	54.6	2.43×10^6	5.6×10^9
YOLO 11 - DG	76.2	84.5	56.2	2.36×10^6	2.6×10^9




图8 不同方法性能试验结果

Fig.8 Performance results of different methods

从图 8a、8b 可知,本文方法在训练初期收敛速度较快,最终在 mAP50 和 mAP50 - 95 上均稳定优于其他方法,并且本文方法具有良好的训练稳定性,整体训练过程平稳,未出现明显振荡。图 8c 召回率曲线同样表明,本文方法在训练过程召回率持续领先于其他方法,进一步验证了本文改进策略的有效性。

综上所述,与现有主流方法相比,YOLO 11 - DG 在精度、轻量化以及训练稳定性等方面均具有明显优势,能在资源受限条件下实现更高质量的目标检测,具有较强实用价值。

4 结论

(1)以 YOLO 11n 为基线模型,融合 FC - C3K2

模块与 YIoU 损失函数以改进检测精度,并构建 FC-DepGraph 依赖图剪枝框架实现结构化压缩,提出轻量化水稻病虫害检测方法 YOLO 11-DG。试验结果表明,改进后的 YOLO 11 通过 FC-C3K2 模块与 YIoU 损失函数有效提升了定位精度与收敛质量,FC-DepGraph 剪枝框架在移除冗余通道的同时维持了模型泛化能力。与基线 YOLO 11n 相比, YOLO 11-DG mAP50 提升 12.4 个百分点,参数量

减少 21.3%,浮点运算量降低 49.0%,在显著轻量化的同时有效提高了检测精度。

(2)相较于 YOLO v8-Corn、YOLO 11-LAMP 及 SCD-YOLO 11 等主流同类方法,YOLO 11-DG 在 mAP50、mAP50-95 上均有提升,且参数量仅为 2.36×10^6 ,浮点运算量仅为 2.6×10^9 ,综合性能具有明显优势,可为复杂田间环境下水稻病虫害目标的实时检测提供轻量化技术支撑。

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] 岳学军,谭修灿,肖佳仪,等. 水稻害虫智能检测技术的研究现状与发展趋势[J]. 华南农业大学学报,2026,47(2):196-208.
Yue Xuejun, Tan Xiucan, Xiao Jiayi, et al. Research status and development trend of intelligent detection technology for rice pest[J]. Journal of South China Agricultural University, 2026, 47(2): 196-208. (in Chinese)

[3] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报,2021,52(7):1-18.
Zhai Zhaoyu, Cao Yifei, Xu Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1-18. (in Chinese)

[4] Ismail U I, Chua H N, Nordin R, et al. A comprehensive review of deep learning approaches for rice disease detection: datasets, methodologies, and future directions[J]. Smart Agricultural Technology, 2025, 11: 100976.

[5] 翟肇裕,张梓涵,徐焕良,等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报,2024,55(11):1-20.
Zhai Zhaoyu, Zhang Zihan, Xu Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 1-20. (in Chinese)

[6] 徐彦威,李军,董元方,等. YOLO 系列目标检测算法综述[J]. 计算机科学与探索,2024,18(9):2221-2238.
Xu Yanwei, Li Jun, Dong Yuanfang, et al. Survey of development of YOLO object detection algorithms[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(9): 2221-2238. (in Chinese)

[7] Badgujar C M, Poullose A, Gan H. Agricultural object detection with you only look once (YOLO) algorithm: a bibliometric and systematic literature review[J]. Computers and Electronics in Agriculture, 2024, 223: 109090.

[8] 公徐路,张淑娟. 基于改进 YOLOv5s 的苹果叶片小目标病害轻量化检测方法[J]. 农业工程学报,2023,39(19):175-184.
Gong Xulu, Zhang Shujuan. Lightweight detection of small target diseases in apple leaf using improved YOLOv5s[J]. Transactions of the CSAE, 2023, 39(19): 175-184. (in Chinese)

[9] 郭丽峰,黄俊杰,吴禹竺,等. 基于 YOLOv8n 改进的水稻病害轻量化检测[J]. 农业工程学报,2025,41(8):156-164.
Guo Lifeng, Huang Junjie, Wu Yuzhu, et al. Detecting rice diseases using improved lightweight YOLOv8n[J]. Transactions of the CSAE, 2025, 41(8): 156-164. (in Chinese)

[10] 张鹏程,矫桂娥,毕卓. 基于 YOLOv7 的轻量化农田害虫检测算法[J]. 湖南农业大学学报(自然科学版),2025,51(2):103-112.
Zhang Pengcheng, Jiao Guie, Bi Zhuo. Lightweight farmland pest detection algorithm based on YOLOv7[J]. Journal of Hunan Agricultural University(Natural Sciences), 2025, 51(2): 103-112. (in Chinese)

[11] He J, Jiang J, Zhang C. A survey of lightweight methods for object detection networks[J]. Array, 2026, 29:100589.

[12] Raza S M, Abidi S M H, Masuduzzaman M, et al. Lightweight deep learning for visual perception: a survey of models, compression strategies, and edge deployment challenges[J]. Neurocomputing, 2025, 656: 131357.

[13] Altaie U K, Abdalkareem A E, Alhasanat A. Lightweight optimization of YOLO models for resource-constrained devices: a comprehensive review[J]. Diyala Journal of Engineering Sciences, 2025, 4: 1-26.

[14] Zhai H, Du J, Ai Y, et al. Edge deployment of deep networks for visual detection: a review[J]. IEEE Sensors Journal, 2024, 25(11): 18662-18683.

[15] 董甲东,桑飞虎,郭庆虎,等. 基于深度学习的目标检测算法轻量化研究综述[J]. 计算机科学与探索,2025,19(8):2057-2084.
Dong Jiadong, Sang Feihu, Guo Qinghu, et al. Review of lightweight object detection algorithms based on deep learning[J]. Journal of Frontiers of Computer Science and Technology, 2025, 19(8): 2057-2084. (in Chinese)

[16] He Y, Xiao L. Structured pruning for deep convolutional neural networks: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 46(5): 2900-2919.

[17] Sabaghian M, Keyvanrad M A, Moghadami S M. A novel compression framework for YOLOv8: achieving real-time aerial object detection on edge devices via structured pruning and channel-wise distillation[PP/OL]. V3. arXiv (2025-09-16) [2026-06-16]. <https://arxiv.org/abs/2509.12918>.

[17] 张新,刘崇宣,许继平,等. 基于多链的果蔬全程全息信息管理模型构建与系统化实现[J]. 农业机械学报,2024,55(6): 365 – 379.
Zhang Xin, Liu Chongxuan, Xu Jiping, et al. Construction and systematic implementation of multi-chain-based management model for fruits and vegetables in full-process and information scheme[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(6):365 – 379. (in Chinese)

[18] 王文娟,汪海燕,陈明,等. 基于多链存储优化的水产品交易匹配模型研究[J]. 农业机械学报,2024,55(6):272 – 283.
Wang Wenjuan, Wang Haiyan, Chen Ming, et al. Aquatic product trading matching model based on multi-chain storage optimization[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(6):272 – 283. (in Chinese)

[19] Stranieri S, Riccardi F, Meuwissen P M, et al. Exploring the impact of blockchain on the performance of agri-food supply chains[J]. Food Control, 2021, 119: 107495.

[20] Sowah R A, Kuuboore M, Ofoli A, et al. Decision support system (DSS) for fraud detection in health insurance claims using genetic support vector machines (GSVMs)[J]. Journal of Engineering, 2019, 2019(1): 1432597.

[21] De Camargo F, Antunes R S, De Ramos G. On social consensus mechanisms for Federated learning aggregation[M]//Xavier-Junior C, Rios R A, et al. Intelligent systems. Cham: Springer International Publishing, 2022: 236 – 250.

(上接第 171 页)

[18] 王晓军,陈高宇,李晓航. 应用动态激活函数的轻量化 YOLOv8 行人检测算法[J]. 计算机工程与应用,2024,60(15): 221 – 233.
Wang Xiaojun, Chen Gaoyu, Li Xiaohang. Lightweight YOLOv8 pedestrian detection algorithm using dynamic activation function[J]. Computer Engineering and Applications, 2024, 60(15): 221 – 233. (in Chinese)

[19] Fang G, Ma X, Song M, et al. Depgraph: towards any structural pruning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 16091 – 16101.

[20] Fan Q, Chen R, Li B. Rice disease detection method based on multi-scale dynamic feature fusion[J]. Frontiers in Plant Science, 2025, 16: 1543986.

[21] Liu W, Duan B, Fan Z, et al. A lightweight edge-deployable framework for intelligent rice disease monitoring based on pruning and distillation[J]. Sensors, 2025, 26(1): 35.

[22] Dai J, Ren J, Li S. PHL – YOLO: a real-time lightweight yarn inspection method[J]. Journal of Real-Time Image Processing, 2025, 22(1): 20.

[23] Hadiur R N. Rice leaf spot disease annotated dataset[DS/OL]. V1.0. Kaggle[2026 – 06 – 16]. <https://www.kaggle.com/datasets/hadiurrahmannabil/rice-leaf-spot-disease-annotated-dataset>.

[24] Song Y, An K, Wang L, et al. Multi-scale closed-loop tuning via spatial frequency collaborative sensitivity for rice leaf disease detection[J]. PLoS One, 2026, 21(6): e0351727.

[25] Jegham N, Koh C Y, Abdelatti M F, et al. YOLO evolution: a comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions[PP/OL]. V4. arXiv(2024 – 10 – 31)[2026 – 06 – 16]. <https://arxiv.org/abs/2411.00201>.

[26] Gong X, Yu J, Zhang H, et al. Aed – YOLO 11: a small object detection model based on YOLO 11[J]. Digital Signal Processing, 2025, 166: 105411.

[27] Liu C, Wang K, Li Q, et al. Powerful – IoU: more straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism[J]. Neural Networks, 2024, 170: 276 – 284.

[28] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IoU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146 – 157.

[29] Zheng Z, 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.

[30] 李龙海,王铁哲,吴禹竺,等. 基于剪枝与蒸馏的轻量化玉米病害检测方法[J]. 农业工程学报,2025,41(17):194 – 202.
Li Longhai, Wang Yizhe, Wu Yuzhu, et al. Method for lightweight corn leaf diseases based on pruning and distillation[J]. Transactions of the CSAE, 2025, 41(17): 194 – 202. (in Chinese)

[31] Wen C, Liu L, Li S, et al. Sugarcane stem node detection with algorithm based on improved YOLO11 channel pruning with small target enhancement[J]. PLoS One, 2025, 20(9): e0332870.