赵泽阳,段有厚,卢峰,等.基于Fert-YOLO的高粱育性检测模型研究[J].山西农业大学学报(自然科学版),2025,45(4):46-56.
Zhao Z Y, Duan Y H, Lu F, et al.Research on a sorghum fertility detection model based on Fert-YOLO[J].Journal of Shanxi Agricultural University(Natural Science Edition), 2025,45(4):46-56.
doi: 10.13842/j.cnki.issn1671-8151.202503051

基于Fert-YOLO的高粱育性检测模型研究

赵泽阳,段有厚,卢峰,柯福来,朱凯,杨琳琳,张飞*

(辽宁省农业科学院 高粱研究所,辽宁 沈阳 110161)

摘　要:[目的]高粱作为重要粮食与能源作物,其育性检测对品种选育与产量提升至关重要。但田间复杂背景干扰导致传统检测效率低下,亟需高效精准的检测技术。[方法]本研究基于YOLOv8n提出了一种针对高粱育性的轻量化检测模型Fert—YOLO。首先,使用多种离线数据增强方法,扩充数据多样性,提升模型的泛化能力。其次,为了减少网络复杂度的同时有效提升网络对高粱育性的检测能力,使用StarNet替换YOLOv8n的骨干特征提取网络;在特征融合部分,对C2F进行重设计,引入混合局部空间注意力(MLCA)机制,增强网络对有效特征的捕捉能力。最后使用轻量化共享卷积(LSCD)检测头,通过共享卷积层参数,大幅削减模型参数数量,降低模型复杂度。[结果]Fert—YOLO模型在高粱育性检测任务中表现卓越。相较原YOLOv8n模型,其平均精度均值($Map_{0.5}$)提升了1.5%,模型对高粱育性的检测精度进一步提高。模型的浮点运算量(FLOPs)、参数量相较于原模型降低了40.0%和47.8%,显著提升了模型的推理速度和部署效率。与其它常见单阶段轻量级检测模型对比,Fert—YOLO在检测精度与模型轻量化方面均展现出明显优势。[结论]本研究成果为田间条件下高粱育性的高效检测提供了可靠的技术支持,对推动高粱智能化育种和精准农业发展具有重要意义。

关键词:高粱; 育性检测; YOLOv8n; 模型优化
中图分类号:S514　　**文献标识码**:A　　**文章编号**:1671-8151(2025)04-0046-11

Research on a sorghum fertility detection model based on Fert-YOLO

Zhao Zeyang, Duan Youhou, Lu Feng, Ke Fulai, Zhu Kai, Yang Linlin, Zhang Fei*

(*Sorghum Research Institute, Liaoning Academy of Agricultural Sciences, Shenyang 110161, China*)

Abstract:[Objective]As an important crop for both food and energy production, sorghum's fertility detection is crucial for variety breeding and yield improvement. However, traditional detection methods suffer from low efficiency due to complex field backgrounds, necessitating highly efficient and accurate detection technologies. [Method]This study proposed Fert-YOLO, a lightweight detection model for sorghum fertility, based on YOLOv8n. First, multiple offline data augmentation methods were used to enhance data diversity and improve the model's generalization ability. Second, to reduce network complexity while effectively improving detection performance, StarNet was used to replace YOLOv8n's backbone feature extraction network. In the feature fusion stage, the C2F module was redesigned by incorporating mixed local channel attention (MLCA) mechanism, strengthening the network's ability to capture critical features. Finally, a lightweight shared convolution detection (LSCD) head was introduced, which shared convolutional layer parameters to significantly reduce model size and complexity. [Results] The Fert-YOLO model demonstrated outstanding performance in sorghum fertility detection. Compared to the original YOLOv8n model, it achieved a 1.5% improvement in mean average precision($Map_{0.5}$), further enhancing detection accuracy. Additionally, the model's , floating-point operations per second (FLOPs) and parameters were reduced by 40.0% and 47.8%,

收稿日期:2025-03-31　　**修回日期**:2025-06-24
基金项目:国家现代农业产业技术体系高粱栽培岗位(CARS-06-13.5-A22);国家现代农业产业技术体系辽宁高粱创新团队项目;辽宁省藏粮于技重大专项(2023020405-JH1/102);沈阳种业创新性专项(24-215-2-02)
作者简介:赵泽阳(ORCID:0009-0009-1756-4527),研究实习员,E-mail:zhaozeyangzz@163.com
*通信作者:张飞(ORCID:0000-0001-9310-9264),研究员,研究方向:高粱育种与栽培;E-mail:zhangfei19821121@163.com

respectively, significantly improving inference speed and deployment efficiency. When compared to other common single-stage lightweight detection models, Fert-YOLO showed clear advantages in both detection accuracy and model efficiency. [Conclusion]This research provided a reliable technical support for efficient sorghum fertility detection in field conditions, contributing significantly to smart sorghum breeding and precision agriculture.

Keywords: Sorghum, Fertility detection, YOLOv8n, Model optimization

高粱[*Sorghum bicolor*(L.)Moench]是中国主要的粮食作物之一,其可用于食用、酿造、生物燃料、饲草等多方面,在国民经济中占有重要地位[1-2]。由于高粱是常异花作物,在高粱制种工作中,会在不育系中出现其它可育个体,进而影响后续制种的纯度。因此在田间复杂情况下快速、准确地检测高粱育性尤为重要。

随着人工智能技术的飞速发展,基于深度学习进行目标检测成为当前研究的热点,其目标检测模型主要分为2大类,一类是基于候选区域的双阶段(Two-stage)目标检测模型,其主流的模型有R-CNN[3]、Faster R-CNN[4]、Mask R-CNN[5]等。另一类是基于回归的单阶段(One-stage)目标检测模型,其主流模型主要有SSD[6]、YOLO系列模型[7-9]等,当前很多学者将目标检测技术应用于作物检测方面,朱旭等[10]提出了一种基于Faster R-CNN模型的蓝莓冠层果实检测方法,通过对区域候选网络、感兴趣区域池化进行改进,并结合分类器和边界回归算法,实现了对蓝莓果实的高效检测与识别,准确率分别达到97%、95%和92%。龙洁花等[11]针对Mask R-CNN模型网络参数多、计算量大等问题,通过融合跨阶段局部网络与Mask R-CNN的残差网络,增加跨区域拆分和级联策略,大幅减少模型参数。将该模型部署在采摘机器人上,模型识别正确度达90%。然而,双阶段检测模型虽然识别精度高,但模型的参数量大且计算复杂度较高,检测速度较慢,难以满足实时检测的需求。与之相比,单阶段检测模型省略了候选区域生成步骤,可直接对特征进行提取,在保持检测精度的同时,却只有较低的模型参数量,使其在复杂环境下更具部署的可行性。近年来,已有学者将单阶段检测模型用于作物的识别和检测,其中田有文等[12]提出了一种轻量化蓝莓检测模型MSC-YOLOv8,该模型通过引入MobileNetV3作为特征提取网络,增加CBAM模块、改进损失函数,平均精度相较原模型提升了3.9%。董耿耿等[13]改进YOLOv5s模型用于新梅检测,通过引入CA机制提取关键特征、应用加权双向特征金字塔网络融合特征信息,采用SIoU损失函数优化模型,显著提升了检测准确率和效率,平均精度均值($Map_{0.5}$)达到了97.7%。王金鹏等[14]为解决油茶果检测问题设计了COF-YOLOv5s模型,该模型引入小目标检测层,将FasterBlock嵌入到主干结构中的C3模块、融入了Biformer注意力机制,结果表明,COF-YOLOv5s模型在测试集上$Map_{0.5}$为99.1%。

上述研究结果表明采用目标检测模型可有效检测田间作物并识别作物的生长状态。但在高粱育性检测方面,还未有相关研究。在高粱育种工作中,育性检测是一项关键的基础性研究,其核心作用在于筛选出具有正常生殖功能的可育植株或不育系,对于后续的杂交育种和保证制种纯度具有重要意义。在高粱的开花授粉过程中,通过直接观察植株的雄蕊数量、形态以及花药发育状态等特征,可以初步判断植株的生殖能力,因此可以应用目标检测技术实现高粱育性的初步检测。另外原始检测模型计算复杂度和体积都很大,受田间边缘设备的性能限制,在这些设备上部署该模型难以满足实时检测的需求,因此模型轻量化研究也尤为重要。综上,本研究设计了基于YOLOv8n的高粱育性检测模型,通过增加离线数据增强、替换模型的特征提取网络、优化特征融合模块、重新设计检测头提升模型对高粱育性的检测能力,实现模型的轻量化,从而为高粱育性检测提供技术支持。

1　试验材料

1.1　数据采集

本研究高粱图像采集自辽宁省农业科学院高粱研究所试验基地(41°31′23" N, 123°27′15" E),采集日期为2024年7月15-8月15日,每日采集时段为当地时间10:00-18:00,采用iPhone 13 Pro智能手机(Apple Inc.,美国)后置主摄像头(24 mm焦距,ƒ/1.6光圈)获取原始影像数据。共采集高粱

图像910张,原始图像分辨率为2268×4032像素,图像格式为JPEG。为减少网络运行时间,提升计算效率,调整图像像素为1024×1840像素。数据集包含可育植株405株,不可育植株505株,试验数据集如图1所示。采用LabelImg 4.5.6开源图像标注工具对高粱植株进行数据标注,构建高粱育性检测试验数据集。

为提升模型训练效果,增加数据多样性,并避免数据泄露干扰试验结果,本研究采用数据划分和数据增强策略。首先将采集的高粱图像按照7:2:1的比例划分为训练集、验证集、测试集,然后再利用albumentations库对训练集进行数据增强操作。所采用的数据增强方式涵盖仿射变换、图像翻转、图像裁剪、亮度调整、图像变形等,如图2所示。经数据增强后训练集图像增加了648张,有效缓解了样本数相对不足的问题。



图1 试验数据集中的可育和不可育植株

Fig.1 Fertile and non-fertile plants in the experimental dataset

1.2 YOLOv8网络结构

YOLOv8作为YOLO系列算法中精度与推理性能均衡的代表模型,在目标检测领域得到广泛应用。该模型的网络结构由骨干网络,颈部和检测头部构成。输入的图像经过数据增强处理后,采用自适应缩放策略生成标准图像,在骨干网络完成对多尺度特征的提取;在颈部,获取不同尺度的特征信息在特征金字塔完成特征融合;检测头部利用来自骨干网络和颈部的特征进行边界框预测、类别识别以及置信度评估。通过后处理技术滤除冗余预测结果并保留最优候选框,最终产生输出结果,其网络结构如图3所示。此外,YOLOv8具备灵活的模型调整机制,用于满足不同的模型应用场景。其中,YOLOv8n作为轻量化版本,在保证基础性能的同时显著降低了计算复杂度和参数数量,尤其适用于资源受限的嵌入式设备和移动端应用场景。

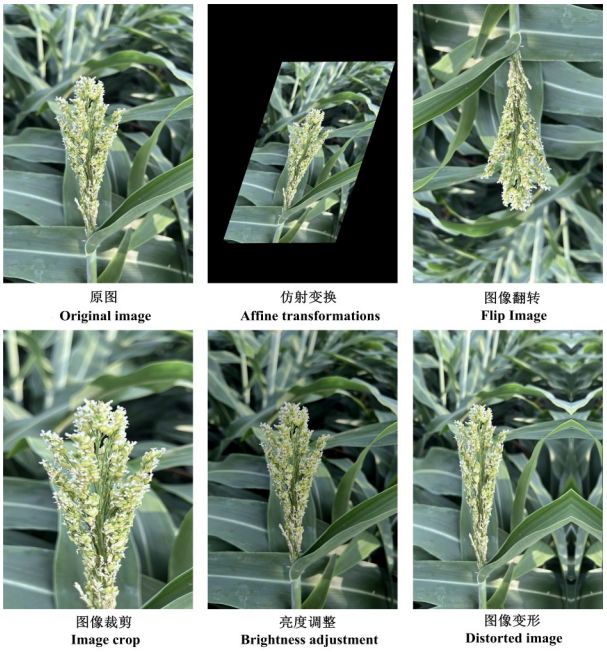


图2 数据增强方式

Fig.2 Data enhancement approach

1.3 Fert-YOLOv8的改进策略

鉴于田间条件背景复杂,且高粱可育植株与不可育植株间特征差异细微,为有效提升模型对高粱不同育性的检测能力,同时降低网络的复杂度、减少计算开销,本研究对YOLOv8n的网络架构进行了针对性改进,具体内容如下:

使用StarNet替换YOLOv8n的特征提取网络,在降低模型复杂度的同时,提升网络对高粱育性的特征提取能力;在特征融合部分,对C2F进行重设计,引入混合局部空间注意力机制(Mixed local channel attention,MLCA)注意力机制,增强网络对高粱育性有效特征的捕捉能力;在检测头部设计了轻量化共享卷积(Lightweight shared convolutional,LSCD)检测头,降低模型的复杂度。其最终的网络结构Fert-YOLO如图4所示。

1.3.1 StarNet

已有研究[15]证明逐元素乘法相较于传统元素相加更具优势,其能够在紧凑的网络结构中进行复杂的计算;其次,它通过将对应元素进行乘法运

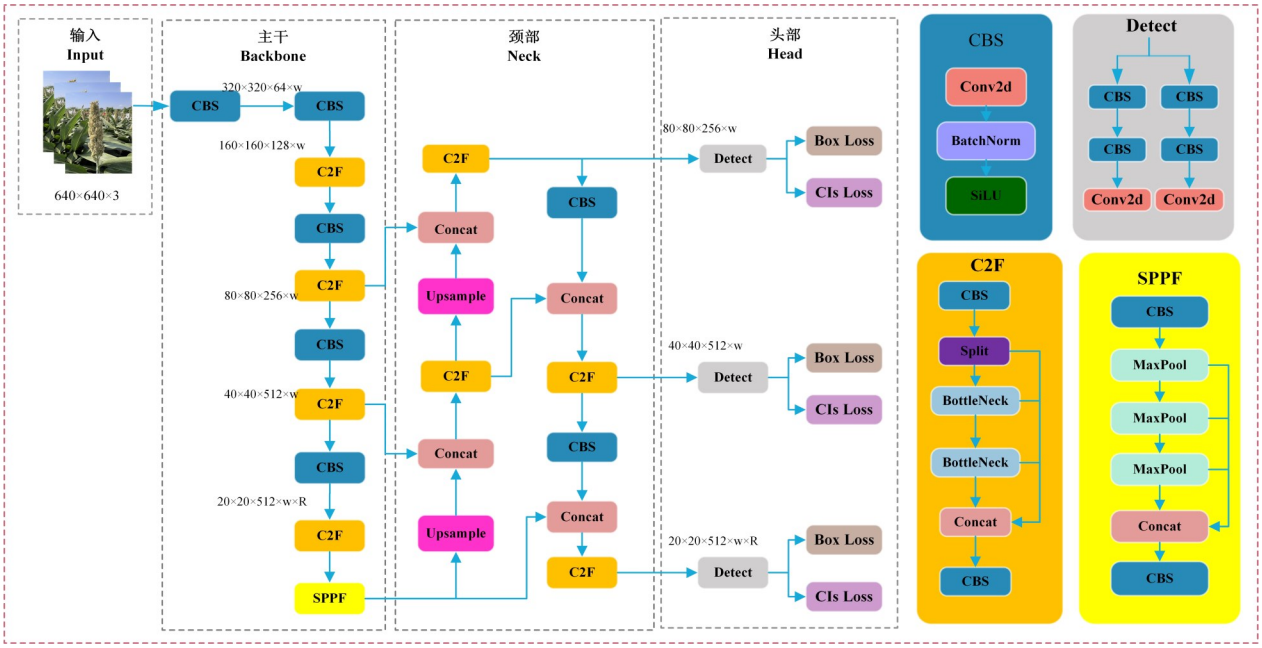


图3　YOLOv8网络结构

Fig.3　Structure of YOLOv8 network

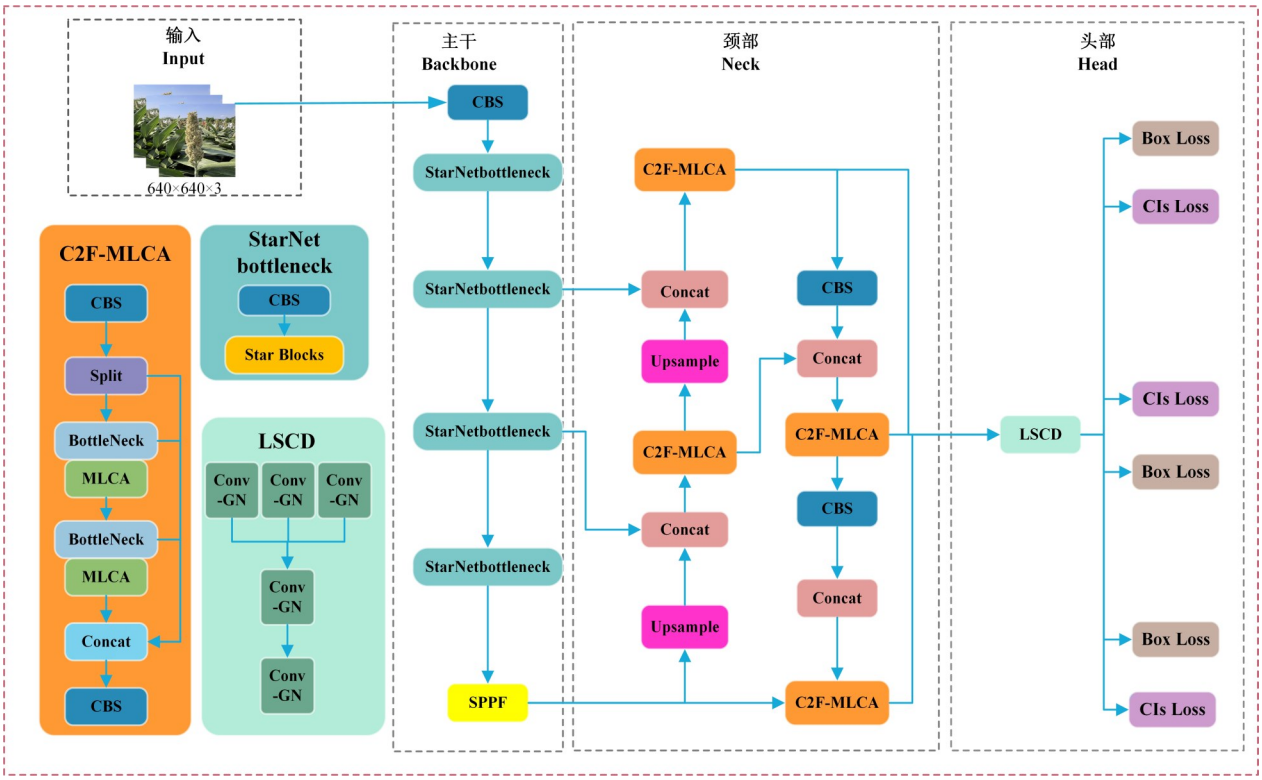


图4　Fert-YOLO的结构

Fig.4　Structure of Fert-YOLO

算,可以突出某些特征的重要性,强调数据中的非线性关系,从而更好地提取有效特征;最后,逐元素乘法整个过程中没有任何复杂的结构和精心选择的超参数。这使得模型的设计和训练更加简单和稳定,减少了因超参数调整不当而导致的模型性能下降的风险,也降低了模型开发的成本和难

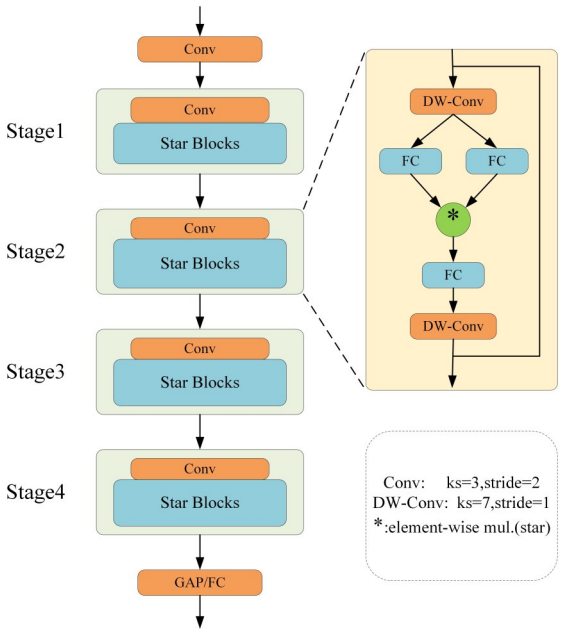


图5 StarNet的网络结构

Fig.5 Network architecture of StarNet

度。StarNet的网络结构便是基于逐元素乘法构建的特征提取网络,其结构如图5所示。StarNet遵循传统网络的4阶段分层结构,首先通过卷积层进行下采样,降低图像分辨率的同时,增加图像通道数,而后通过StarNetblock进行特征提取,StarNet-block的结构受MobileNeXt启发,首尾通过深度可分离卷积连接,以提升特征提取效率,而后使用批归一化替代层归一化,通过多个逐元素乘法相乘来提取有效特征,通道扩展因子始终设置为4,网络宽度在每个阶段加倍,使模型能够在不同阶段提取到更丰富的特征。

1.3.2 C2F-MLCA

在目标检测模型构建时,空间层面的注意力机制部署存在较高复杂度,受此限制,当前主流的注意力机制多聚焦于通道特征信息提取,这在一定程度上削弱了模型的特征提取能力。为有效平衡性能和计算复杂性,本研究在网络的颈部结构引入MLCA机制[16]。其结构如图6所示,MLCA机制的具体实现过程如下:首先对输入特征向量(C, W, H)采用局部平均池化处理(Local average pooling,LAP),将其转换为1*C*ks*ks的向量,以此实现局部空间信息的有效提取。随后进入分支处理阶段,其中一个分支使用全局平均池化(Global average pooling,GAP)将特征向量转换为1*1*C的向量,从而保留特征的全局信息。另一分支使用局部平均池化(LAP)将特征向量转换为1*1*C的向量,实现局部空间信息的进一步提炼。分支处理后,将2个分支的特征向量经过一维卷积,使其恢复到原始分辨率。最后,将2个分支的特征向量进行融合,生成最终的混合注意力特征图。通过上述操作将局部空间信息融入到通道注意力机制中,同时考虑通道信息、空间信息、局部信息和全局信息,从而提高网络的表达效果。此外,整个处理过程中并无大型卷积的操作,有效降低了模型的复杂度。本研究将MLCA机制嵌入C2F结构形成C2F-MLCA,结构见图7。

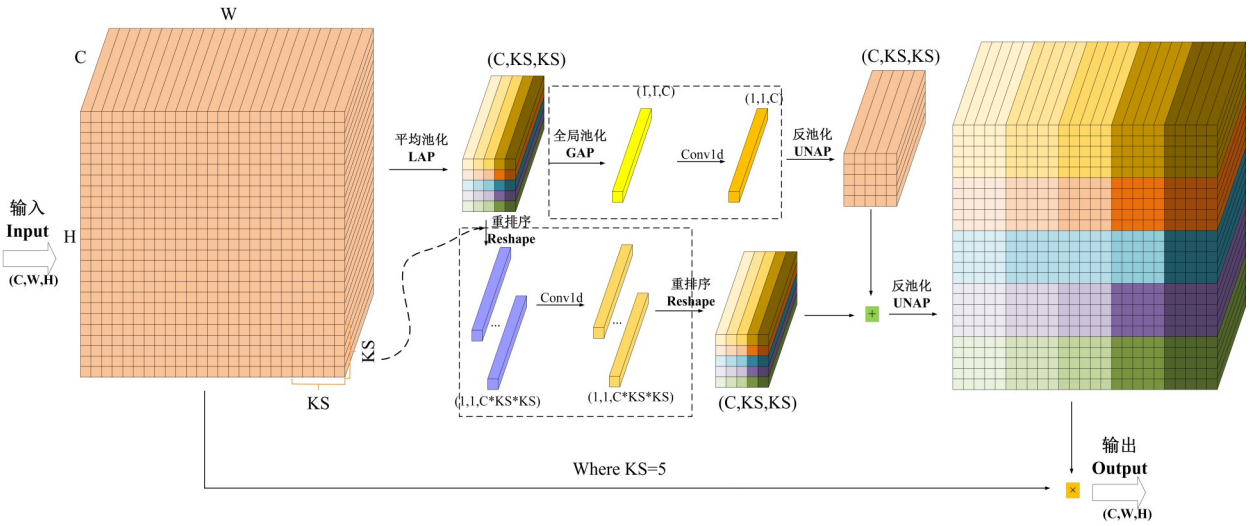


图6 MLCA的结构

Fig.6 Structure of the MLCA

1.3.3　LSCD检测头

在执行检测任务时,YOLOv8n在获取检测目标的锚框位置和类别信息过程中,依赖大量卷积操作来完成这一任务。从其检测头部结构(图8)来看,不同的检测尺度下存在大量相同的卷积核,这极大的增加了模型的复杂度。经统计检测头部的参数占据了整个模型参数总量的40%。因此,为了在维持网络检测精度的同时显著减少模型的参数和计算复杂度,本研究应用了LSCD检测头。LSCD是一种基于Group-Norm和共享卷积思想构建的轻量化检测头部,其主要结构如图9所示。LSCD的设计核心是利用共享卷积的思想,对原有结构进行重设计,它将3个输出端相同的卷积进行整合,使用共享卷积(图9中黄色的卷积)替代原有的多个独立卷积。通过这种方式,能够大幅减少模型的参数数目,但共享卷积的使用会导致每个检测头所适用的检测目标尺度不一致,为解决这一问题,引入了Scale层,对特征进行不同尺度的缩放,以满足各个检测头的实际需求。值得注意的是,共享卷积的大量使用会导致模型的检测能力下降,已有研究表明,Group Norm卷积可以提升检测头的分类和定位性能[17]。因此,我们在共享卷积前增加Group Norm卷积,来弥补模型精度的下降。

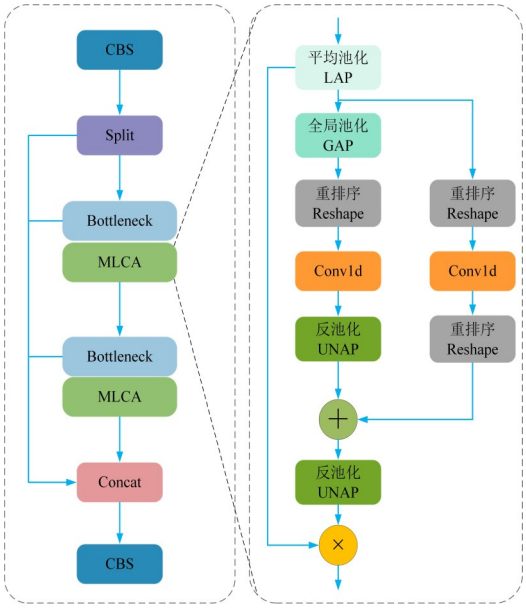


图7　C2F-MLCA

Fig.7　C2F-MLCA

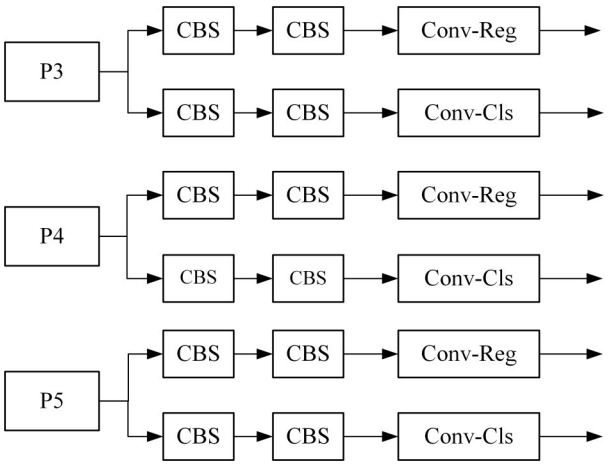


图8　YOLOv8n检测头的结构

Fig.8　Structure of YOLOv8n detection head

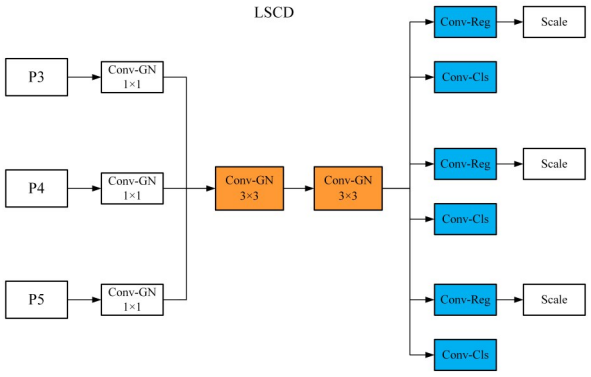


图9　LSCD的结构

Fig.9　Structure of the LSCD

1.4　试验配置

本试验采用如下计算环境:软件配置方面,操作系统:Windows 11 64位。编程语言:Python 3.8;深度学习框架:PyTorch 1.12.1(CUDA 11.6)。硬件配置方面,处理器:Intel Core i7-12700H(12代,主频2.30 GHz);图形显卡:NVIDIA GeForce RTX 3060。训练参数方面,超参数设置:保持框架默认配置;批处理尺寸:16;迭代周期:100 epochs。

1.5　模型评价

本研究采用多维评估指标对模型性能进行全面分析,精度指标选择精确率(Precision, P)、召回率(Recall, R)、F1分数、$Map_{0.5}$。计算效率参数选择浮点运算量(FLOPs, Floating-point operations per second)、模型参数量(Parameters)、每秒处理帧数(FPS, Frames per second)。各指标计算公式如下:

$$P=TP/(TP+FP) \tag{1}$$

$$R=TP/(TP+FN) \tag{2}$$

$$F1分数=2PR/(P+R) \tag{3}$$

$$AP=\int_0^1 Precision-Recall\ Curve\ dR \tag{4}$$

$$Map_{0.5}=\sum_{i=1}^{N} AP_i/N \tag{5}$$

$$浮点运算量=O\left(\sum_{i=1}^{n} k_i^2*C_{i-1}^2*C_i+\sum_{i=1}^{n} M^2*C_i\right) \tag{6}$$

$$参数量=O(\sum_{i=1}^{n} M_i^2*k_{i-1}^2.*C_{i-1}*C_i) \tag{7}$$

$$每秒处理帧数=1/Inference\ Latency \tag{8}$$

式中,P表示的是模型预测为正样本中实际为正样本的比例,即精确率;TP为正确检测的正样本数量;FP为错误检测为正样本的数量;R表示的是实际为正样本中被模型预测为正样本的比例,即召回率;FN为漏检的正样本数量;AP用于衡量模型在单个类别上的检测性能,即平均精度;Precision-Recall Curve为精度-召回率权衡曲线;i为检测类别;N为需要预测的目标数目;O为常数;K为卷积核空间维度;C为特征图通道数;M为输入图像分辨率;Inference Latency指单样本端到端处理时间,单位为毫秒(ms),基于NVIDIA RTX 3060 GPU实测。

2 结果分析

2.1 消融试验

经测试,Fert-YOLO模型的$Map_{0.5}$为97.7%,模型参数量为1.57 G,FLOPs为4.9 G,模型大小为3.45 Mb,每秒处理帧数为187帧/秒。与以原YOLOv8n模型为基础构建的高粱育性识别模型相比,$Map_{0.5}$相较于原YOLOv8n模型提升了1.5%,模型的FLOPs、参数量相较于原模型降低了40.0%和47.8%;模型的检测速度提升了25帧/秒。

为了清晰呈现本研究提出的Fert-YOLO的改进过程,开展了消融试验,结果如表1所示,表中显示了增加图像增强、StarNet、C2F-MLCA和LSCD-head各模块后模型性能之间的比较。试验数据表明,首先,通过离线数据增强策略构建的M1模型,其$Map_{0.5}$较基线模型提升0.2%(达到96.4%),验证了数据增强方法能够有效丰富训练样本特征多样性,进而提升模型泛化能力。其次,采用StarNet替换骨干特征提取网络的M2模型,在实现$Map_{0.5}$提升的同时,显著降低了模型参数量与计算复杂度,证明新型骨干网络在优化特征提取效率方面的有效性。再者,引入C2F-MLCA模块的M3模型,在不增加模型复杂度的前提下,使$Map_{0.5}$提升0.6%,验证了该模块对高粱育性特征感知能力的增强作用。最后,以LSCD替换检测头的M4模型,在维持检测精度的同时,大幅降低模型参数量与计算量,并提升检测速度。上述结果充分表明,本研究提出的多维度改进策略在优化模型性能方面具有显著成效,为目标检测算法的高效化设计提供了理论与实践依据。

为了呈现提出的Fert-YOLO的检测性能的优势,本研究将模型网络输出的特征图进行可视化分析,结果如图10所示,图中左侧显示了利用YOLOv8n对不同育性高粱检测输出的特征热力图,右侧则为利用Fert-YOLO对高粱不同育性检测输出的特征热力图。通过对比可以发现,相较于原YOLOv8n模型,Fert-YOLO能够更准确地定位目标区域,尤其在高粱穗部的捕捉上表现更为突出。该可视化结果进一步佐证,Fert-YOLO在高粱育性特征的提取能力显著高于未改进的YOLOv8模型,能够更有效地识别和表征目标关键信息。

2.2 对比试验

为验证Fert-YOLO模型的有效性,本研究将其与YOLOv4-tiny、YOLOX-tiny、YOLOv5s、YOLOv7-tiny、YOLOv8n这5个单阶段目标检测模型进行性能对比分析(表2)。试验结果表明,Fert-YOLO在检测精度、模型轻量化及推理速度方面均展现出显著优势。

在检测精度方面,Fert-YOLO的$Map_{0.5}$达到

表1　消融试验

Table 1　Ablation test

模型 Model	数据增强 Data augmentation	StarNet	C2f—MLCA	轻量化共享卷积 LSCD	平均精度均值 $Map_{0.5}$/%	参数量/Mb Parameters	浮点运算量/G FLOPs	模型大小/Mb Model size	每秒处理帧数/(帧/秒) FPS
YOLOv8n					96.2	3.01	8.1	5.93	162
M1	√				96.4	3.01	8.1	5.93	162
M2	√	√			97.1	2.21	6.5	4.41	180
M3	√		√		97.0	3.01	8.1	6.20	178
M4	√			√	96.5	2.37	6.6	4.90	190
M5	√	√	√		97.6	2.21	6.5	4.42	182
M6	√	√	√	√	97.7	1.57	4.9	3.45	187

97.7%,显著高于对比模型。与YOLOv4-tiny、YOLOX-tiny、YOLOv5s、YOLOv7-tiny和YOLOv8n相比,$Map_{0.5}$分别提升6.7%、6.5%、1.6%、0.8%和1.5%,体现出该模型在高粱育性识别任务中的卓越检测能力。

在模型轻量化方面,Fert-YOLO通过结构优化实现了高效参数利用。其参数量(Parameters)仅为1.57 Mb,较YOLOv4-tiny、YOLOX-tiny、YOLOv5s、YOLOv7-tiny和YOLOv8n分别降低73.5%、69.0%、10.8%、73.9%和47.7%;FLOPs为4.9 G,除略高于YOLOv5s(差值0.7 G)外,较其余对比模型分别降低29.8%、24.0%、62.3%和40.0%,表明该模型在计算资源消耗上具有显著优势。

在推理速度方面,Fert-YOLO每秒处理帧数达到187帧/秒,较YOLOv4-tiny、YOLOX-tiny、YOLOv5s、YOLOv7-tiny和YOLOv8n分别提升108、106、97、45和29帧/秒。同时,模型大小仅为3.45 Mb,在所有对比模型中最小,进一步验证了其在实际部署中的高效性与便捷性。模型对比结果如图11所示,其中圆圈半径表示FLOPs的大小,上述结果充分说明,Fert-YOLO模型在保持高检测精度的同时,实现了轻量化与快速推理的协同优化,为目标检测任务提供了更优解决方案。

2.3　模型评价

为系统评价Fert-YOLO模型在陌生场景下的泛化性能,对测试集开展了验证,结果如表3所示,Fert-YOLO模型在陌生环境中的检测性能表现优异,模型的P、R和F1评分分别为92.7%、90.7%和91.7%。进一步细分其类别发现,可育类型的P、R、F1分别为86.9%、94.0%、90.3%;不可育类型的P、R、F1分别为98.6%、87.4%和92.7%。上述结果表明,Fert-YOLO模型具备良好的环境适应性,能在复杂的大田环境中保持着良好的泛化能力和鲁棒性,可为高粱育性现场快速检测提供可靠的技术支撑。

3　讨论

在复杂的田间环境下,实现高粱育性的快速精准识别,是保障高粱品种纯度的关键技术环节。利用深度学习技术结合采集的图像能够有效实现高粱育性的检测,然而在高粱育性识别过程中,存

表2　不同模型间性能对比

Table 2　Performance comparison between different models

模型 Model	平均精度均值 $Map_{0.5}$/%	参数量/Mb Parameters	浮点运算量/G FLOPs	模型大小/Mb Model size	每秒处理帧数/(帧/秒) FPS
YOLOv4—tiny	91.0	5.94	6.98	21.90	79
YOLOX—tiny	91.2	5.06	6.45	19.10	81
YOLOv5s	96.1	1.76	4.20	3.70	90
YOLOv7—tiny	95.9	6.02	13.00	10.70	142
YOLOv8n	96.2	3.00	8.10	5.93	158
Fert—YOLO	97.7	1.57	4.90	3.45	187

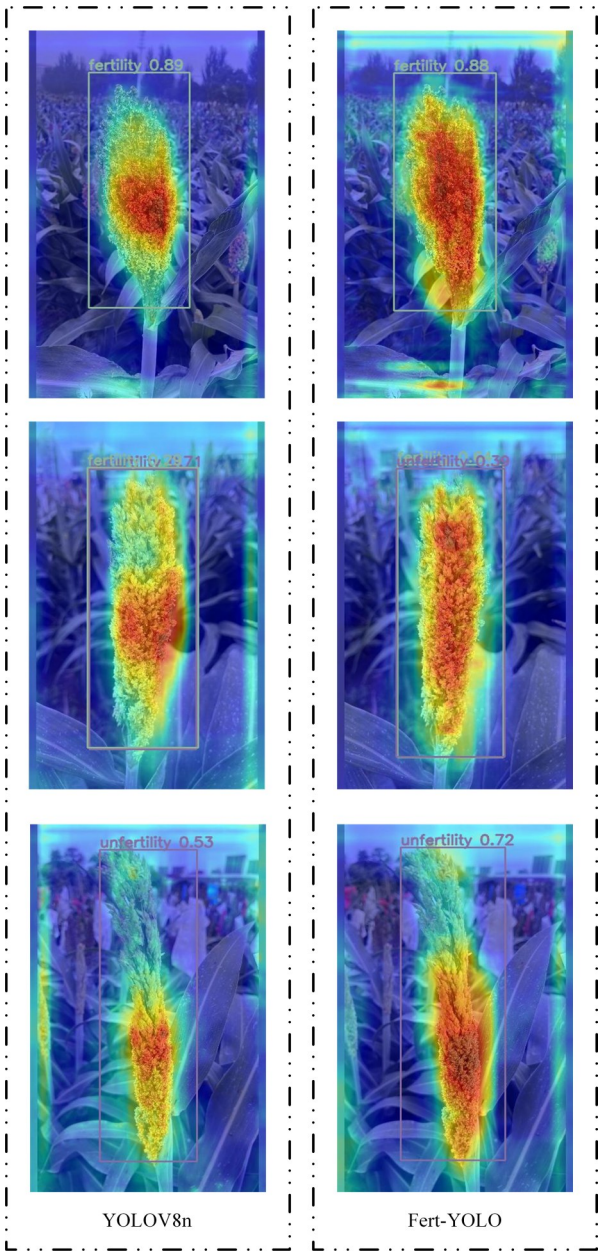


图10 YOLOv8n与Fert-YOLO特征热力图对比

Fig.10 Characteristic heat maps of YOLOv8n and Fert-YOLO

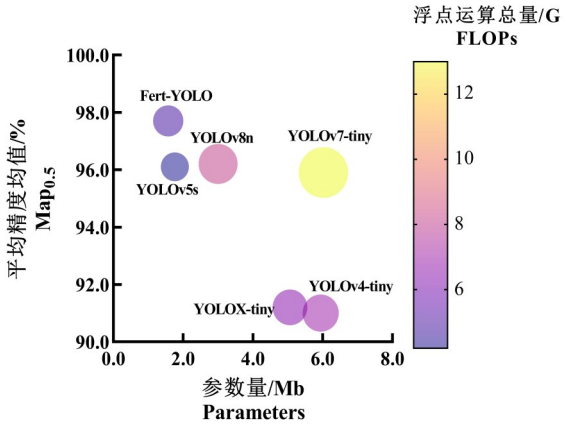


图11 模型对比结果

Fig.11 Model comparison results

表3 模型在测试集上的评价结果

Table 3 Evaluation results of the model on the test set

类别 Class	准确度/% P	召回率/% R	F1得分/% F1-score
全类 All	92.7	90.7	91.7
可育植株 Fertile plant	86.9	94.0	90.3
不可育植株 Unfertile plant	98.6	87.4	92.7

在的主要难题是高粱可育个体与不可育个体间特征并不显著。既往的研究证明,通过对算法的优化改进可以显著提升模型对目标对象的识别能力[18-19]。但上述的方法普遍存在模型参数冗余及计算复杂度攀升的问题,致使检测效率显著降低,与此同时,大型的模型架构也增加了在移动端部署的成本,进而限制了高粱育性识别技术的实际应用与推广。鉴于现有技术在实际应用中存在的局限性,本研究以手机拍摄的高粱可育及不可育的图像为数据集,对YOLOv8n模型进行了针对性优化。本研究引入基于逐元素运算的StarNet作为新型特征提取网络,相较于通过增加网络宽度提升性能的传统神经网络,StarNet利用逐元素运算实现不同通道间特征的成对相乘,通过少量层级的堆叠即可完成高维运算。该设计在有效降低模型参数规模与计算复杂度的同时,显著提升了特征提取效率。在特征融合环节,本研究采用轻量级C2F-MLCA模块替代原有的C2F模块。其中,MLCA机制通过整合局部与全局层面的通道注意力和空间注意力,显著增强了网络对高粱育性特征的感知与捕捉能力。此外,为进一步优化模型性能,本研究利用LSCD模块,该模块通过减少检测头部的冗余卷积操作,有效降低了模型计算复杂度,大幅提升了模型在复杂田间背景下的检测速度,实现了检测精度与效率的平衡优化。Fert-YOLO模型在模型精度方面$Map_{0.5}$达到了97.7%,相较于原YOLOv8n提升了1.5%,而且对比其它单阶段的检测模型,也有很大优势;在轻量化方向,Fert-YOLO模型参数为1.57 Mb,FLOPs为4.9 G,模型大小为3.45 Mb,与其它作物的轻

量化模型相比,也具有显著优势[20-22]。与此同时,轻量化的结果并未降低模型的检测速度,Fert-YOLO可以实现每秒检测187张图片。因此Fert-YOLO能够部署在计算量有限的移动端上,实现快速、准确的育性识别。

尽管本研究提出的Fert-YOLO模型在高粱田间育性检测领域展现出显著优势,但仍存在一定局限性。首先Fert-YOLO是基于计算机视觉的检测模型,虽能够实现快速田间检测,然而部分特殊育种材料仍需结合实验室分析手段,方能准确判定植株生殖性能。本研究数据集涵盖的雄性不育个体仅包含A1、A2、A4、A5、A6、9E这6类,未纳入A3雄性不育个体,由于A3雄性不育个体在田间表现为花药肥大,并可散出部分花粉,在外观上与其它可育个体无区别,单纯依赖视觉无法实现有效区分,所以本研究在数据采集时并未选择A3不育类型的高粱植株。此外本研究仅基于手机提供的高粱育性照片,并未涉及无人机等其它移动端设备的应用潜力,无法实现高通量的大田环境下的高粱育性检测。为进一步提升研究成果的实用性与应用价值,后续研究将聚焦于以下几个方面:其一,构建基于无人机搭载RGB的图像采集系统,开发适配模型以实现高通量的大田环境高粱育性检测。其二,扩充数据集,丰富样本类型,进一步增强模型的泛化能力与检测准确性,从而更好地满足高粱育种及生产实践的实际需求。

4　结论

本研究通过对YOLOv8n模型进行改进,提出了一种实时高效的检测方法。结果表明,本文提出的Fert-YOLO模型能够有效检测田间环境下的高粱育性,并在提升模型检测精度的同时,最大程度的简化网络。Fert-YOLO的$Map_{0.5}$达到97.7%,与原YOLOv8n检测模型相比,高出了1.5%。Fert-YOLO在轻量化方面,模型的参数量、FLOPs和模型大小仅为1.57 Mb、4.9 G和3.45 Mb,检测速度达到了187帧/秒,与其它单阶段检测模型相比,也具有显著优势。在测试集上进行评估,Fert-YOLO的准确度、召回率和F1得分分别为92.7%、90.7%和91.7%。因此Fert-YOLO模型能够实时、准确地检测出高粱的育性,可为大面积高粱育性检测提供技术支撑。

参　考　文　献

[1]邹剑秋.基于1961-2020年FAO数据的世界高粱产业分析[J].山西农业大学学报(自然科学版),2023,43(1):1-10.
Zou J Q. World sorghum industry analysis based on 1961-2020 FAO data[J].Journal of Shanxi Agricultural University(Natural Science Edition),2023,43(1):1-10.

[2]Zhang R, Lin G, Shang L, et al. Potential, economic and ecological benefits of sweet sorghum bio industry in China [J]. Biotechnology for Biofuels and Bioproducts, 2024, 17(1): 134.

[3]Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus: IEEE, 2014: 580-587.

[4]Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[5]He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision (ICCV), Venice: IEEE, 2017:2980-2988.

[6]Liu W, Anguelov D, Erhan D, et al. SSD: single shot Multibox detector [C]//Leibe B, Matas J, Sebe N, Welling M. Computer Vision-ECCV 2016, PT I, Cham: Springer, 2016: 21-37.

[7]Redmon J, Farhadi A. YOLOv3: an incremental improvement [EB/OL]. 2018:1-6(2018-04-08)[2025-06-24]. https://arxiv.org/pdf/1804.02767.

[8]Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. 2020: 1-17(2020-04-23)[2025-06-24]. https://arxiv.org/pdf/2004.10934.

[9]Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver: IEEE, 2023: 7464-7475.

[10]朱旭,马淏,姬江涛,等.基于Faster R-CNN的蓝莓冠层果实检测识别分析[J].南方农业学报,2020,51(6):1493-1501.
Zhu X, Ma H, Ji J T, et al. Detecting and identifying blueberry canopy fruits based on Faster R-CNN[J].Journal of Southern Agriculture ,2020, 51(6): 1493-1501.

[11]龙洁花,赵春江,林森,等.改进Mask R-CNN的温室环境下不同成熟度番茄果实分割方法[J].农业工程学报,2021,37(18):100-108.
Long J H, Zhao C J, Lin S, et al. Segmentation method of the tomato fruits with different maturities under greenhouse environment based on improved Mask R-CNN [J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(18): 100-108.

[12]田有文,覃上声,闫玉博,等.基于改进YOLOv8的田间复杂环境下蓝莓成熟度检测[J].农业工程学报,2024,40(16):153-162.
Tian Y W, Qin S S, Yan Y B, et al. Detecting blueberry

maturity under complex field conditions using improved YOLOv8 [J]. Transactions of the Chinese Society of Agricultural Engineering , 2024, 40(16): 153-162.

[13]董耿耿,陈小康,樊湘鹏,等.基于改进YOLOv5s的复杂环境下新梅检测方法[J].农业工程学报, 2024, 40(14): 118-125.
Dong G G, Chen X K, Fan X P, et al. Detecting Xinmei fruit under complex environments using improved YOlOv5s [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(14): 118-125.

[14]王金鹏,何萌,甄乾广,等.基于COF-YOLOv5s的油茶果识别定位[J].农业工程学报, 2024, 40(13): 179-188.
Wang J P, He M, Zhen Q G, et al. Camellia oleifera fruit harvesting in complex environment based on COF-YOLOv5s [J]. Transactions of the Chinese Society of Agricultural Engineering , 2024, 40(13): 179-188.

[15]Ma X, Dai X Y, Bai Y, et al. Rewrite the stars[C]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle: IEEE, 2024: 5694-5703.

[16]Wan D H, Lu R S, Shen S Y, et al. Mixed local channel attention for object detection [J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.

[17]Tian Z, Shen C H, Chen H, et al. FCOS: fully convolutional one-stage object detection[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV) , Seoul: IEEE, 2019: 9626-9635.

[18]张世豪, 董峦, 逄正钧,等. 基于改进YOLOv5的小麦穗目标检测模型[J].农业工程, 2023, 13(3): 50-56.
Zhang S H, Dong L, Pang Z J, et al. Wheat spike target detection model based on improved YOLOv5 [J]. Agricultural Engineering,2023,13(3):50-56.

[19]Ye X Q, Pan J, Liu G S, et al. Exploring the close-range detection of UAV-based images on pine wilt disease by an improved deep learning method [J]. Plant Phenomics, 2023, 5: 0129.

[20]Wu D H, Lü S C, Jiang M, et al. Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments [J]. Computers and Electronics in Agriculture, 2020, 178: 105742.

[21]Li J, Li J H, Zhao X, et al. Lightweight detection networks for tea bud on complex agricultural environment via improved YOLO v4 [J]. Computers and Electronics in Agriculture, 2023, 211: 107955.

[22]Zhao W Y, Liu S Y, Li X Y, et al. Fast and accurate wheat grain quality detection based on improved YOLOv5 [J]. Computers and Electronics in Agriculture, 2022, 202: 107426.

(编辑:韩志强)