

改进 YOLOv8 的轻量化烟叶计数检测算法^{*}

肖恒树¹ 李军营² 梁虹¹ 马二登² 张宏²

(1. 云南大学信息学院 昆明 650504; 2. 云南省烟草农业科学研究院 昆明 650021)

摘要: 烟叶产量的预估是一项非常重要的任务, 叶片数量与产量直接相关。传统人工统计效率低、成本高, 为解决这些问题, 研究提出一种轻量化 YOLOv8-SLSS 烟叶计数检测算法, 该算法针对 YOLOv8n 检测精度不足、计算复杂度高以及烟叶遮挡场景导致的漏检问题进行改进。算法采用改进后的 ShuffleNetV2light 网络结构替代原模型的骨干网络, 缩减模型参数和计算负荷; 引入设计的 LHCN 模块到颈部网络的 C2f 中, 扩大模型的感受视野, 提高模型检测精度的同时减少计算量; 引入 SEAMDetect 检测头模块, 增强了烟叶遮挡场景下的检测能力; 最后, 引入 SPPELAN 模块, 增强模型多尺度特征提取能力和计算效率。实验结果表明, 改进后的模型参数量和浮点运算量分别减少了 63.3% 和 61.7%, 算法的检测平均精度 AP@0.5 由原算法的 92% 提高到 93.1%, 实时检测速度达到 83 fps, 相比原 YOLOv8n 模型提高 5.1%。改进后的算法提高了传统 YOLO 模型在烟叶遮挡场景下的检测能力, 实现了较高精度、轻量化、实时检测性能的平衡, 为烟草农业数字化提供有效地技术支持。

关键词: 目标检测; YOLO; 烟叶; 烟叶计数; 轻量化

中图分类号: TN911.73; TP391.41 文献标识码: A 国家标准学科分类代码: 520.6

Improved YOLOv8 lightweight tobacco leaf count detection algorithm

Xiao Hengshu¹ Li Junying² Liang Hong¹ Ma Erdeng² Zhang Hong²

(1. School of Information Science and Technology, Yunnan University, Kunming 650504, China;

2. Yunnan Academy of Tobacco Agriculture Science, Kunming 650021, China)

Abstract: The estimation of tobacco leaf yield is a crucial task, as the number of leaves directly impacts the yield. Traditional manual statistics are inefficient and costly, in order to solve these problems, this research proposes a lightweight YOLOv8-SLSS tobacco leaf counting detection algorithm, which improves on the YOLOv8n methods for the lack of detection accuracy, high computational complexity, and missed detections caused by overlapping tobacco leaves. The algorithm replaces the original model's backbone network with an enhanced ShuffleNetV2light architecture, reducing model parameters and computational load. Integrate the LHCN module into the neck network's C2f module to expand the model's receptive field, enhances detection capabilities and reduces computational load. The introduction of the SEAMDetect module has enhanced the detection capabilities in scenarios involving occlusion by tobacco leaves. Finally, the SPPELAN module is introduced to enhance the model multi-scale feature extraction capability and computational efficiency. Experimental results demonstrate that the modified model significantly reduces model parameters and floating-point operations by 63.3% and 61.7% respectively. The algorithm's average precision improves from 91.8% to 93.1%, achieving a real-time detection speed of 83 fps, marking a 5.1% enhancement over the original algorithm, meeting real-time detection demands. The improved algorithm enhances the detection ability of the traditional YOLO model in tobacco leaf occlusion scenarios, realizes the balance of high accuracy, lightweight design, and real-time detection performance, thus providing effective technical support for the digitization of tobacco agriculture.

Keywords: target detection; YOLO; tobacco leaf; tobacco leaf count; lightweight

0 引言

烟草植株因其生产成本低、经济价值高而被认为是重

要的作物。植物表型参数的测量和分析可以有效地调控育种过程, 并最终影响植物的生长发育和作物产量^[1]。烟草植株表型的特征主要包括株高、叶片数和叶面积。叶片数

量对于作物产量的估计至关重要,对烟草植株叶片的准确统计为科研人员的产量预估和有效育种工作提供了重要的数据支持。

传统的统计烟叶方法需要大量的人力和时间,在实时监测和精确评估方面缺乏有效性。近年来,无人机(unmanned aerial vehicle, UAV)技术的进步为快速获取高通量物图像数据提供了手段,使海量植物生长过程的智能监控成为可能^[2]。研究人员通过无人机搭载传感器采集株高、叶片数、叶面积等数据,实现对作物生长发育的实时监控和作物产量的预估^[3-5]。Syazwani 等^[6]提出配备数码相机的无人机检测和计数菠萝冠,准确率高达 94.4%。卷积神经网络在目标检测、语义分割等领域获得广泛应用,目标检测算法在精准农业领域也取得了很大的突破。Marzan 等^[7]提出了一种基于 Haar 级联分类器与图像处理技术的烟叶检测方法,在应用图像处理技术后对于单片及多片烟叶检测精确率达 100%,平均检测时间 62 ms。Harjoko 等^[8]提出一种使用图像处理技术包括图像阈值、形态学操作、斑点检测等按颜色和质量对烟叶分级的方法,涵盖质量检测与缺陷分类,实验显示该方法能够检测出叶片缺陷,分类烟叶的准确率达到了 91.67%。Wu 等^[9]提出了一种深度学习模型 TobaccoNet,以 ResNet-34 为主干网络,采用随机拼图生成器对预处理后的烟叶图像数据进行均匀分割和重组,实现了烟叶成熟度的准确识别,分类准确率达 90% 以上。Wang 等^[10]提出了一种基于改进的 Faster R-CNN 的密集 Sweet potato 叶子检测方案,融合了视觉注意机制和 DIoU-NMS,检测精度达到了 95.7%,在检测密集叶子或遮挡叶子方面取得了良好的性能。Xu 等^[11]提出了基于 Noisy Student 半监督学习框架,使用 SOLOv2 模型先分割完整的玉米幼苗并生成去除背景的前景图像,再采用 YOLOv5x 实现检测和计数玉米叶片,叶片检测平均准确率到了 89.6%。Niu 等^[12]提出了一种利用无人机图像和改进 YOLOv8s 的玉米早期干旱检测方法,主干部分使用 C2F-PConv 模块降低了参数和成本,颈部利用双向特征金字塔(bidirectional feature pyramid network, BiFPN)融合架构和坐标注意力(coordinate attention, CA)机制来增强模型识别小目标和隐蔽目标的能力。Ma 等^[13]提出一种轻量级苹果果实检测模型,采用 ShuffleNet v2 和 C2fGhost 模块重构网络结构,平均精度为 91.4%,具有模型规模小、检测速度快的特点。受上述研究启发,对于烟叶计数检测,首先基于无人机拍摄的烟草植株影像,利用 YOLOv8n 算法构建出烟叶检测图像数据集,然后在对比了当前部分经典检测算法及其轻量化改进模型在烟叶图像数据集上的性能试验后,首次提出了一种基于 YOLOv8n 的烟叶计数检测算法 YOLOv8-SLSS,主要贡献为:

1) 引入改进后的 ShuffleNetV2light 模块的结构替代原模型的骨干网络,压缩模型大小和计算量,提升检测速度^[14]。

2) 设计了轻量化混合卷积块(lightweight hybrid convolution block, LHCB),引入到 YOLOv8 颈部的 C2f 模块中,融合轻量卷积和大核卷积的优势,捕捉不同尺度特征,扩大模型的感受视野,使模型能够在复杂背景下获得较高的检测精度。

3) SEAMDetect 模块:结合分离增强注意力模块(separated and enhancement attention module, SEAM)能够整合通道上下文信息的能力,改进 Detect 检测头,增强模型对遮挡烟叶的检测能力。

4) 空间金字塔池化高效层聚合网络(spatial pyramid pooling-efficient layer aggregation network, SPPELAN)模块:采用多个最大池化模块串联进行特征提取,每个最大池化模块提取不同尺度的特征并在通道维度上进行拼接,丰富了特征图的表达能力,提高检测精度^[15]。

1 材料和方法

1.1 数据集构建

实验地点位于云南省玉溪市的世界烟草品种园,设备采用大疆 PHANTOM 4 PRO 无人机,配备有效像素为 2 000 万的相机。考虑到地理环境背景信息复杂及成熟期烟草遮挡较为严重,采集过程中选择了不同的高度和不同天气条件下拍摄大田烟草植株垂直正射影像,进一步增加目标数据多样性和模型泛化能力,共计采集了世界烟草品种园两块大田约 500 张三原色(red-green-blue, RGB)图像数据。图 1 所示为部分拍摄的烟株图像。

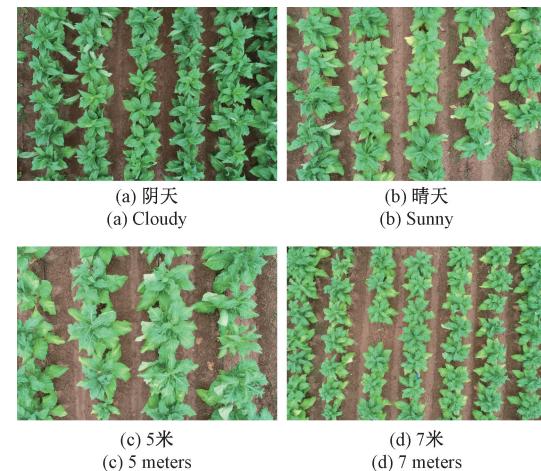


图 1 部分大田烟株图像

Fig. 1 Partial image of tobacco plants in the field

无人机获取得到大田烟株的影像后,直接进行烟叶计数检测非常困难,检测任务量大,检测精度低,因此还需构建适合烟叶检测的图像数据集。如图 2 所示,研究提出选用 YOLOv8n 模型通过检测分割的方法来构建烟叶数据集,首先对烟株图像进行数据标注,然后利用 YOLOv8n 模型训练后,检测分割即可得到单株烟叶检测图像,可供完成烟叶计数检测。

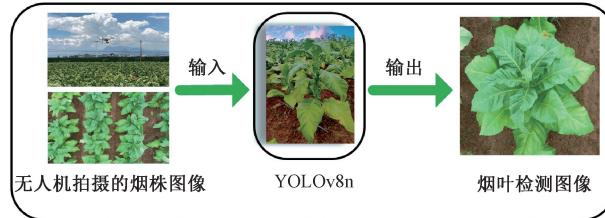


图 2 烟叶检测数据集构建

Fig. 2 Tobacco leaf detection dataset construction

最终得到了约 5 000 张烟叶计数检测图像数据集,如图 3 所示。



图 3 烟叶计数检测图像

Fig. 3 Tobacco leaf counting detection images

1.2 数据标注与增强

研究用于神经网络训练的数据集采用 Pascal VOC 的格式,使用 LabelImg 工具进行烟叶的标注,标注标签为“leaf”,标签文件以 XML 格式保存,该文件包含烟叶检测图像中目标烟叶的像素坐标及标签。将数据集进行划分,将其分为训练集、验证集和测试集,其中训练集占 80%,而验证集和测试集各占 10%。

YOLOv8 的数据增强方法包括马赛克(Mosaic)、自适应目标缩放和自适应锚框计算。马赛克数据增强是将 4 张目标图片按照随机的比例和位置拼接成一张新的图片,可以有效地扩充数据集,提高网络训练效率,减少模型内存消耗。

1.3 YOLOv8 算法介绍

YOLO 系列的算法通常具备高效的实时性和良好的检测性能,而其最新的版本 YOLOv8 延续了这一优势,具有着更快、更高的检测性能。网络由 3 部分组成:骨干(Backbone)、颈部(Neck)和检测头(Detect)。Backbone 由 CBS 模块、C2f 模块和快速-空间金字塔池化(spatial pyramid pooling-fast, SPPF)模块组成。SPPF 模块能融合不同感受视野的特征图,进一步提高了运行速度。YOLOv8 根据网络的深度和宽度可分为 4 个版本, YOLOv8n 是参数最少、权重最轻的网络模型。

2 算法改进

2.1 引入改进 ShuffleNetV2light 模块

ShuffleNet 作为一种轻量级神经网络,以其高效、准确和轻量的特点,在移动计算和嵌入式视觉应用中显示出显

著的优势。ShuffleNet v2 基本模块包含 2 种不同结构,如图 4 所示。

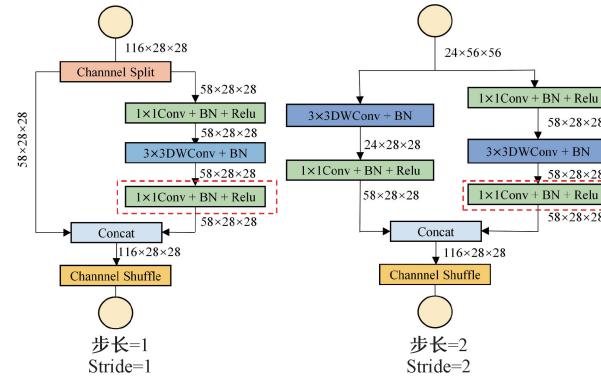


图 4 ShuffleNet v2 基本单元

Fig. 4 ShuffleNet v2 basic blocks

ShuffleNet 的核心在于其独特的网络结构设计,具有包括逐点分组卷积和通道混洗(channel shuffle)两种关键技术。逐点分组卷积通过将卷积操作分组,降低了计算量。而通道混洗则通过打乱通道顺序,确保不同组之间的信息流通,避免了信息的丢失,实现信息在特征通道之间流动^[16]。

研究发现 ShuffleNet v2 中的 block,在右侧的分支均采用了 2 个 1×1 Conv,由图 4 stride=2 可知,第一个 1×1 Conv 的作用是融合输入通道信息,使得输入通道从 24 变成 58 通道,然后采用深度卷积(depthwise convolution, DWConv)融合特征图的空间信息,大幅减少计算量,随后又连接了一个 1×1 Conv 模块进行去融合 DWConv 的输出,得到图像的输出尺寸仍然是 $58 \times 58 \times 28$,并没有进行任何升维或降维操作。在轻量级模型设计中,元素级操作例如(ReLU)尽管具有较小的 FLOPs,但在 GPU 上占据了相当大的计算时间,因为这些操作尽管计算量不大,但其乘加运算内存占比较高,在实际硬件上可能成为计算瓶颈,实验发现,去除这些操作可以显著加速推理时间^[16]。

故本研究将图 4 中的红色虚线框中的 1×1 Conv 删除,减少不必要的计算开销,然后采用改进后的 ShuffleNet v2 基本单元和降采样单元,用交替连接取代了 YOLOv8 的 Backbone 部分。由基本单元和下采样单元组成的 Backbone 主干网络大大减少了网络参数的数量,降低了网络复杂性,提升目标检测速度。

2.2 LHCN 模块

YOLOv8 中的 Bottleneck 模块可以实现不同尺度特征的提取及融合,提高特征图的表示能力,但由于 YOLOv8 中含有大量 Bottleneck 结构,会带来较大的计算开销。YOLOv10 论文阐述了在深阶段和使用大型模型容易表现出更多的冗余问题,提出一种紧凑的反向块(compact inverted block, CIB)结构,结构如图 5(a)所示,它采用 3×3 深度卷积(depthwise convolution, DWConv)进

行空间混合, 1×1 逐点卷积(pointwise convolution, PWConv)进行通道混合, 采用大核深度卷积即在深度阶段将 3×3 DWConv 的核大小增加到 7×7 , 以扩大感受野和增强模型检测能力, 在不影响性能的情况下实现更高的效率^[17]。

深度可分离卷积(depthwise separable convolution, DSConv)是由 DWConv 和 PWConv 组成, 通过对比 CIB 模块的组成, 由图 5(a)可知其结构可以近似等价于 3×3 DSConv+ 3×3 DWConv+ 3×3 DSConv 的组合。DSConv 简化了标准卷积操作, 能够比使用的标准卷积减少约 8 倍计算成本, 但是在 DSConv 的 feature map 中仍然存在大量相似的 feature map, 针对此问题 GhostConv 可以较好地解决, GhostConv 模块在进行卷积时, 首先通过标准卷积生成内在特征图, 再通过对内在特征图进行线性运算生成幽灵特征图, 从而降低计算成本, 与标准卷积相比, GhostConv 的参数量和 FLOPs 数量至少减少一半^[18]。具体分析, 若卷积核大小为 $k \times k$, m 为输入通道数量、 n 为输出通道数量, DSConv 的总参数量如式(1)~(3)所示。

DWConv 的参数数量 $Params_{dw}$ 为:

$$Params_{dw} = k \times k \times m \quad (1)$$

PWConv 的参数数量 $Params_{pw}$ 为(卷积核大小为 1×1):

$$Params_{pw} = 1 \times 1 \times m \times n \quad (2)$$

DSConv 的总参数数量 $Params_{ds}$ 为 DWConv 和 PWConv 的总和为:

$$Params_{ds} = k \times k \times m + m \times n \quad (3)$$

假设生成的特征图比例为 r , GhostConv 的总参数量如式(4)~(6)所示。

标准卷积部分的参数量 $Params_{conv}$ 为:

$$Params_{conv} = k \times k \times m \times \frac{n}{r} \quad (4)$$

简单操作部分的参数量 $Params_{simple}$ 为(卷积核大小为 1×1):

$$Params_{simple} = 1 \times 1 \times \left(n - \frac{n}{r}\right) \times m \quad (5)$$

GhsotConv 的总参数数量 $Params_{ghost}$ 为标准卷积核简单操作部分的和。

$$Params_{ghost} = (k^2 - 1) \times m \times \frac{n}{r} + m \times n \quad (6)$$

与标准卷积对比, DSConv 的参数量减少了约 $\frac{1}{k \times k}$,

$GhostConv$ 减少了约 $\frac{1}{r}$, 根据实际 CIB 模块卷积核大小为 3×3 , 故 DSConv 减少了的参数量约为 $1/9$, 而 $GhostConv$ 相对减少的参数量与 r 的值有关, r 的值越大, 则代表更多的特征图通过简单地线性运算生成, 计算的成本和参数量更低, 故当设置 $r=2$, 此时 $GhostConv$ 相对减少的参数量为 $1/2$, 轻量化的效果优于 DSConv, $GhostConv$ 在保持模型性能的前提下, 获取更多的特征映射, 具有更佳的效果。

因此在研究轻量化烟叶检测算法的任务中, 对 CIB 模块进行优化设计, 融合 GhostConv 轻量化和大核卷积的优势, 提出了 LHCB 模块, 其结构如图 5(b)所示。LHCB 能够在减小计算量的前提下扩展感受野, 捕捉不同尺度特征, 使模型能够在复杂背景下获得较高的检测精度, 同时减少了漏检情况。

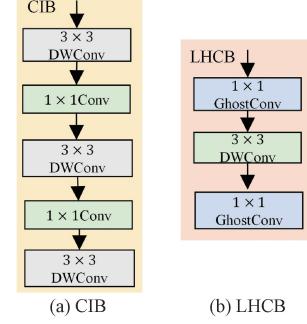


图 5 CIB 和 LHCN

Fig. 5 CIB and LHCN

2.3 SEAMDetect 模块

SEAM 是一种用于改进卷积神经网络特征提取和表征能力的模块。SEAM 通过分离和增强来提高模型对特征的注意力, 使其在处理复杂图像任务时表现更加优越。具体来说, SEAM 模块能够通过结合上下文信息, 利用空间和通道注意力分离计算方式来增强模型对重叠叶片的注意力。此外, SEAM 模块采用滑动加权函数, 能够根据样本的难度调整权重, 确保模型既能学习简单样本的特征, 又能有效识别难样本, 提高模型的鲁棒性^[19]。

在本研究中, 引入了 SEAM 模块改进原始 YOLOv8n 模型的 Detect, 使模型更加强调图像中的烟叶区域, 减少因烟叶相互遮挡而导致的漏检现象。如图 6 所示为 SEAM 的结构。融合后的特征图被用作 SEAM 结构的输入, 并根据 6、7 和 8 进行分割以提取特征图中的 patches, 接下来通过通道与空间融合模块(channel and space fusion module, CSMM)整合单个深度卷积的结果来恢复和利用通道间信息。随后, 采用两层全连接网络来有效融合各通道的信息。这一策略增强了跨所有通道的信息整合。最后, SEAM 模块的输出作为注意力权重与原始特征相乘, 这个过程使模型能够结合上下文信息, 有效应对烟叶部分被遮挡的场景, 提高模型整体检测性能^[20]。

2.4 SPPELAN 模块

空间金字塔池化(spatial pyramid pooling, SPP)是在目标检测网络中使用的一种池化方法, 通过在不同的尺度上进行池化来捕捉不同尺度的信息, 从而使网络能够处理任意尺寸的输入图像。SPPELAN 结合了 SPP 和高效层聚合网络(efficient layer aggregation network, ELAN)的优势, 旨在增强特征提取能力并提高深度学习模型的计算效率。这种架构在需要精确目标检测和分类的任务中表现尤为出色, 在 YOLOv9 中得到了应用, 通过有效的层聚合策略和

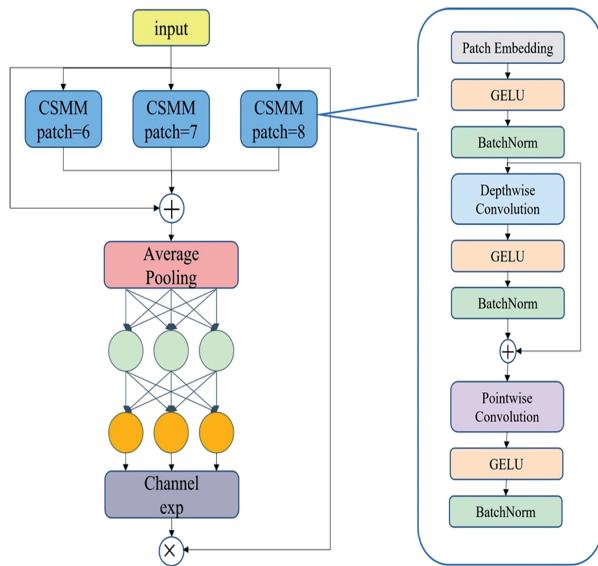


图 6 SEAM 注意力机制结构

Fig. 6 SEAM attention mechanism structure

改进的 SPP 池化层,使得网络在计算效率和检测精度方面都有显著提升,其结构如图 7 所示^[21]。

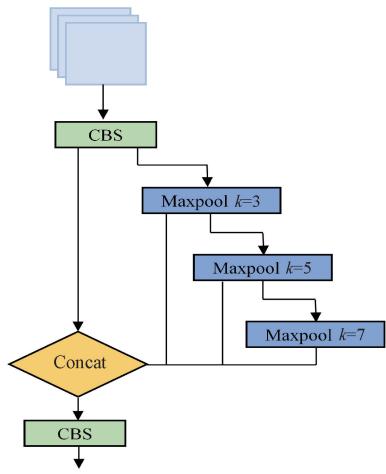


图 7 SPPELAN 模块

Fig. 7 SPPELAN module

本研究改进是在网络中使用 SPPELAN 模块替换原有的 SPPF 模块,通过 SPPELAN 的多尺度特征提取确保了即使是小的或部分被遮挡的叶片也能被准确检测到,同时通过 ELAN 增强特征聚合能力帮助模型区分烟草叶片和复杂背景,提高检测可靠性。

2.5 YOLOv8-SLSS 网络结构

YOLOv8-SLSS 是一个轻量化的烟叶计数检测网络结构,旨在实现模型大小与检测精度的均衡,在应对烟叶计数检测任务时有较好的优化效果。总体改进后的 YOLOv8-SLSS 网络结构如图 8 所示,主干网络采用的改进后的 ShuffleNetV2light 的下采样单元和基本单元交替连接组成,有效地减少网络的大小和计算量,提升实时检测效率。

特征提取网络引入 SPPELAN 模块,通过对多尺度特征的提取,丰富特征图的表达能力。颈部网络中,将设计的 LHCB 模块引入到 C2f 中,创建的模块名为 C2f-LHCB,增强了模型的检测精度,对复杂背景的适应性。最后在检测头采用了引入 SEAM 模块后重新设计的 SEAMDetect 模块,提高了模型对于遮挡叶片目标的检测能力。

3 实验结果与分析

3.1 实验环境

实验模型主要开发语言为 Python, 使用开源的深度学习框架 Pytorch, Python 版本为 3.9.18, 采用 CUDA11.8 对训练进行加速。目标检测模型训练使用的硬件 CPU 为 13th Gen Intel (R) Core (TM) i5-13600KF, GPU 为 NVIDIA GeForce RTX 3060Ti, 8 GB 显存。训练时, 将输入图像设置为 $640 \times 640 \times 3$, 模型训练周期 epoch 为 300, 优化器使用 AdamW 对模型进行训练, 动量 momentum 为 0.9, 权值衰减 weight_decay 为 0.0005, batch_size 为 16, 初始学习速率为 0.002。

3.2 模型评价指标

本次实验采用的评价指标包含准确率(precision, P), 表示模型预测结果为正样本的结果中, 预测正确的概率。召回率(recall, R), 表示算法检测正确结果占比图表中所有目标的比例。F1 分数(f1-score, F1), 同时考虑了 P 和 R, 更加能够反应模型的性能。平均精度(average precision, AP), 由 P 与 R 决定, 可以直观反应每一个单类别的检测性能结果。计算如式(7)~(10)所示。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (7)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (8)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (9)$$

$$AP = \int_0^1 p(r) dr \quad (10)$$

式中: TP 表示真实为正样本中检测结果正确地判定为正样本的数量, FN 表示真实为正样本中检测结果错误地判定为负样本的数量。FP 表示真实为负样本中检测结果错误地判定为正样本的数量。AP 是对 P-R 曲线的积分, 即曲线与横纵坐标所围成的面积。而 mAP 为各类预测对象精度的均值, AP@0.5 是 IoU 阈值为 0.5 时的 AP。

同时为了衡量网络的轻量化指标, 需要综合考虑的参数量(number of parameters, Params)、浮点运算量(floating-point operations, FLOPs)及对图片的检测速度帧每秒(frames per second, FPS)。Params 表征模型大小的参数, 对于评价模型轻量化程度具有重要意义。FLOPs 衡量模型的计算资源消耗, 较少的计算需求有助于适配内存和计算能力受限的设备或环境。FPS 用来评估目标检测的速度。其计算如式(11)所示。

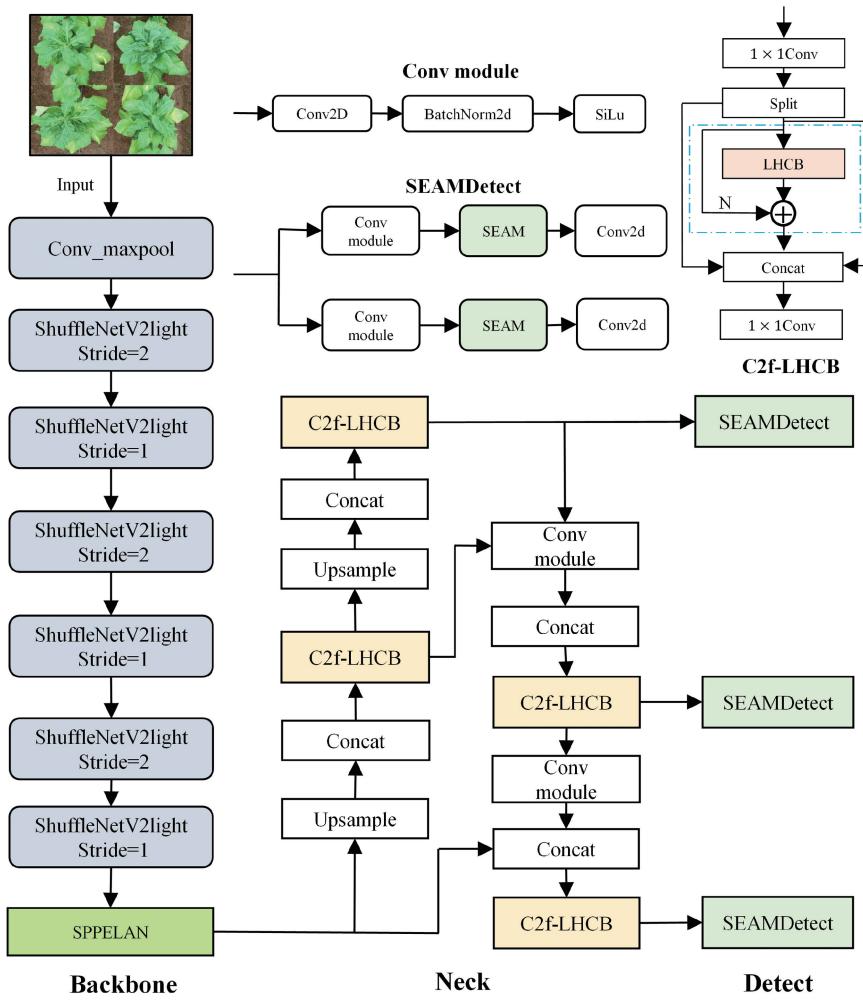


图 8 YOLOv8-SLSS 的网络结构

Fig. 8 YOLOv8-SLSS's network structure

$$FPS = \frac{1000}{T_{pre} + T_{infer} + T_{pos}} \quad (11)$$

其中, T_{pre} 为图片预处理时间, T_{infer} 为网络推理时间, T_{pos} 为后处理时间, 单位均为 ms。

3.3 实验结果分析

1) 主干网络轻量化改进对比实验

对 YOLOv8n 模型的轻量化改进, 对比了分别采用主流轻量化特征提取网络 GhostNet、MobileNet v3^[22]、ShuffleNet v2 以及改进后的 ShuffleNetV2light 对 Backbone 网络直接替换进行实验, 实验结果如表 1 所示。

从表 1 可知, 方案 3 使用 ShuffleNet v2 的方法在仅牺牲少量检测精度的同时, 模型的参数和浮点计算量分别减小了 42.7% 和 39.5%, 比方案 1 和方案 2 的表现更佳, 模型检测速度提升了 18%, 而方案 4 改进后的 ShuffleNetV2light 模块在检测精度和速度都比原始的 ShuffleNet v2 高, 检测速度相比原始 YOLOv8n 模型提高了 21.5%, 模型的参数量减小了 43.3%。综合实验改进效果对比, 采用 ShuffleNetV2light 结构来替换 YOLOv8 的

Backbone, 在仅牺牲少量检测精度的条件下, 更大程度减少模型的参数和计算量, 提高了检测速度, 具有更优的效果。

表 1 轻量化改进实验对比

Table 1 Comparison of lightweight improvement experiments

模型	AP@0.5/%	Params/M	FLOPs/G	FPS
YOLOv8n	92	3.0	8.1	79
方案 1	91.8	2.6	7.0	89
方案 2	91.3	2.4	5.7	81
方案 3	91.6	1.72	4.9	93
方案 4	91.8	1.70	4.9	96

注: 方案 1 表示用 GhostBottleneck 来替换 YOLOv8 Backbone 网络中 C2f 模块的 Bottleneck。方案 2 表示用 MobileNet v3 主干结构来替换 YOLOv8 的 Backbone。方案 3 表示用 ShuffleNet v2 结构来替换 YOLOv8 的 Backbone。方案 4 表示用改进 ShuffleNet v2 结构来替换 YOLOv8 的 Backbone。

2) LHCB 和 SEAMDetect 模块改进前后对比

为验证本研究提出的 LHCB 和 SEAMDetect 模块在烟叶检测的有效性,分别设计了如下对比试验。首先,将 CIB 和 LHCB 替换 C2f 中的 Bottleneck 后替换 YOLOv8 网络的 Neck 部分的 C2f 模块,实验的结果如表 2 所示。

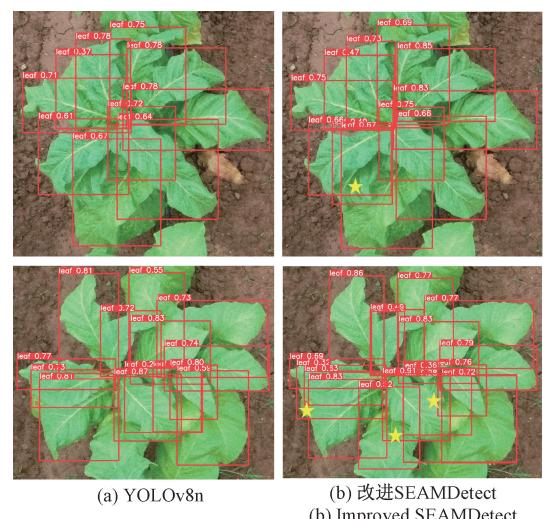
表 2 CIB 和 LHCB 实验结果对比

Table 2 Comparison of CIB and LHCB experimental results

模型	AP@0.5%	Params/M	FLOPs/G	FPS
YOLOv8n	92	3.00	8.1	79
+ CIB	92.5	2.66	7.5	80
+ LHCB	93.1	2.61	7.4	81

由表 2 可知,本研究设计的 LHCB 模块相比于 CIB 模块对于 YOLOv8n 模型检测精度的提升更高,提升了 1.2%,而且模型的计算量和参数量更少,检测速度也略微提高。

其次,对比了 SEAMDetect 模块改进前后的检测效果对比,结果如图 9 所示,五角星标记的是改进 SEAMDetect 模块后模型能够识别到的没有被原模型检测到的遮挡烟叶,改进前后的效果对比展示了添加 SEAMDetect 模块能够增强模型对遮挡目标的检测能力。



(a) YOLOv8n
(b) 改进SEAMDetect
(b) Improved SEAMDetect

图 9 SEAMDetect 改进结果对比

Fig. 9 Comparison of SEAMDetect improvement results

3) 消融实验

本研究将 ShufflneV2light、LHCB、SEAMDetect、SPPELAN 模块逐一加入 YOLOv8n 作为模型改进,设计了 8 组实验,实验以 F1 和 AP@0.5、Params 和 FLOPs 作为评价指标,结果如表 3 所示。模型改进前后检测精度对比如图 10 所示。

表 3 消融实验结果

Table 3 Ablation experiment results

ShufflneV2light	LHCB	SEAMDetect	SPPELAN	F1/%	AP@0.5/%	Params/M	FLOPs/G
×	×	×	×	87.5	92.0	3.00	8.1
√	×	×	×	86.8	91.8	1.70	4.9
×	√	×	×	87.6	93.1	2.61	7.4
×	×	√	×	88.2	93.0	2.82	7.1
×	×	×	√	87.0	92.6	2.85	8.0
√	×	×	√	86.2	92.5	1.27	4.1
×	√	√	×	88.0	93.5	2.43	6.3
√	√	×	√	87.2	92.6	1.29	4.1
√	√	√	√	87.4	93.1	1.10	3.1

注:“×”为未加入此模块;“√”为加入了此模块。

由表 3 可知,ShufflneV2light 模块的引入使模型轻量化的同时造成了检测精度的损失,因此为实现模型各方面性能的平衡,在轻量化网络的基础上对模型进行优化。LHCB、SEAMDetect 和 SPPELAN 模块的单独引入都能够提升模型的检测性能。最终改进的 YOLOv8-SLSS 模型与 YOLOv8n 模型相比,检测精度 AP@0.5 上提高了 1.2%,而模型的参数量和浮点计算量分别减少了 63.3% 和 61.7%。改进后的模型在轻量化网络模型,缩减模型计算负担的同时,还少量提高了检测精度和检测速度。

4) 不同检测算法结果比较

为了进一步验证改进方案的有效性,将经典目标检测算法及其改进后的轻量化模型和本文提出的改进方案在自制的烟叶检测数据集上进行实验。文献[12]为对 YOLOv8s 轻量化改进方案,文献[13]、文献[23]、文献[24]为对 YOLOv8n 提出的轻量化改进方案,实验结果如表 4 所示。

Faster-RCNN、CenterNet、YOLOv3-tiny、YOLOv5s 模型的检测精度均低于 YOLOv8n 基础模型,而且模型的

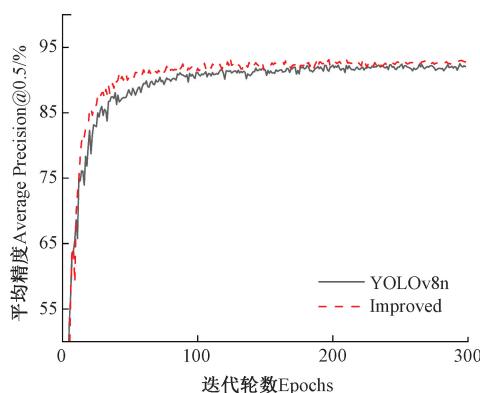


图 10 模型检测精度结果对比

Fig. 10 Comparison of model detection accuracy results

大小和浮点计算量也更大,其中 YOLOv3-tiny 对比 YOLOv8n,虽然检测速度提高了 40%,但是模型大小和浮点计算量分别是 YOLOv8n 的 4 倍和 2.3 倍。YOLOv8s 和文献[12],在检测平均精度上对比 YOLOv8n 分别提升了 0.1% 和 1.4%,但是模型的参数量和计算量显然高于 YOLOv8n,而且在检测速度方面相较 YOLOv8n 也分别降低了 6 FPS 和 20 FPS。文献[13]提出的方案,在模型大小和浮点计算量方面对比 YOLOv8n 模型分别减少了 56.7% 和 51.9%,检测速度也提升了 2.5%,但是检测平均精度比本文的方法降低了 2%,检测速度降低了 2 FPS;文献[23]、文献[24]提出的方案,对比 YOLOv8n 模型,检测精度分别提升了 0.8% 和下降了 0.1%,模型大小分别减少了 10% 和 5%,浮点计算量减少了 9.9% 和 7.4%,但是检测速度下降了很多。

表 4 不同检测算法结果

Table 4 Different detection algorithm results

算法	P/%	R/%	AP@0.5/%	Params/M	FLOPs/G	模型大小/MB	FPS
Faster R-CNN	83.6	82.5	85.5	137.1	370.2	108.0	—
CenterNet	89.2	84.7	82.4	14.4	19.3	124.0	—
YOLOv3-tiny	86.8	84.3	90.6	12.1	18.9	24.4	109
YOLOv5n	88.9	85.9	91.3	2.5	7.1	5.0	71
YOLOv5s	88.3	85.4	91.1	9.1	23.8	17.6	57
YOLOv8n	89.4	86.5	92.0	3.0	8.1	6.0	79
YOLOv8s	88.7	86.7	92.1	11.1	28.4	21.4	73
YOLOv10n	88.0	84.0	91.0	2.71	8.4	5.5	76
文献[12]	89.6	87.2	93.3	8.1	30.2	16.0	53
文献[13]	87.4	85.8	91.3	1.2	3.9	2.6	81
文献[23]	90.4	86.7	92.7	2.7	7.3	5.4	69
文献[24]	89.9	85.6	91.9	2.8	7.5	5.7	65
YOLOv8-SLSS(本文)	87.1	87.8	93.1	1.1	3.1	2.4	83

YOLOv8-SLSS 在检测精度上达到了 93.1%,与文献[12](93.3%)相近,高于文献[13](91.3%)、文献[23](92.7%)和文献[24](91.9%)。模型计算量仅为 3.1 GFLOPs,相比文献[12](30.2 GFLOPs)和文献[13](3.9 GFLOPs),计算量显著降低,较文献[23]和文献[24]的 7.3 GFLOPs、7.5 GFLOPs 减少了接近 50%,检测速度达到了 83 FPS,远高于文献[12](53 FPS)、文献[23](69 FPS)和文献[24](65 FPS),相比文献[13]的 81 FPS 也略

有提升。综上所述,本研究提出的改进方案 YOLOv8-SLSS 以最小的模型体积、更小的计算量实现了较高的检测精度,后期部署在移动设备时成本更低,具有高效性和优越性。

5) 模型改进前后实际预估结果对比

为验证改进前后的模型在实际应用中的性能,实验使用 YOLOv8n 模型和改进后的 YOLO-SLSS 模型分别对大田 A 和大田 B 的烟叶数进行统计。实验结果如表 5 所示。

表 5 烟叶数统计结果

Table 5 Tobacco counting results

方法	大田 A		大田 B		预测平均 每张图片耗时
	预测值	精确度	预测值	精确度	
YOLOv8n	11 249 片	92.3%	10 633 片	87%	7.6 ms
YOLOv8-SLSS	11 732 片	96.3%	11 308 片	92.5%	8.4 ms
人工预估值	12 180 片		12 225 片		8 s

由表 5 可知,对于大田 A 和大田 B,改进后的模型预测烟叶片数和人工预估值的精确度分别达到了 96.3% 和 92.5%,比原始的 YOLOv8n 模型更高,误差控制在了 5% 左右。虽然改进后模型平均每张图片完成检测的耗时增加了约 10.5% 左右,但从实际应用角度看,这一耗时增长是可以接受的,且并未显著影响模型的实时检测能力。耗时的适度增加换来了检测精度和模型性能的大幅提升,特别是在遮挡、复杂背景等复杂场景下,YOLOv8-SLSS 模型显著优于原始模型,能够适应大面积田间监控的应用需求。实际预估结果表明,改进后的模型可以更好的完成烟叶数预估的任务。

如图 11(a) 和 (b) 所示为 YOLOv8n 模型改进前后烟叶检测的效果。图 11(a) 中五角星标记的是 YOLOv8n 模型误检的烟叶,图 11(b) 中五角星标记的是 YOLOv8-SLSS 模型检测到而 YOLOv8n 没有检测到的遮挡烟叶。通过对比结果可以得出,原 YOLOv8n 模型存在误检漏检的现象,而改进后的模型对于烟株的检测更加地精确,在一定程度上改善了此类问题,并且改进后的模型检测框的置信度分数也有所提升。

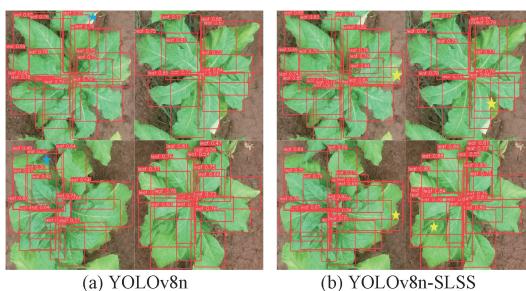


图 11 模型改进前后对比

Fig. 11 Effects before and after model improvement

4 结 论

本研究首先基于无人机拍摄大田的烟草植株图像,利用训练后的 YOLOv8n 模型来构建烟叶图像数据集,降低在数据收集上的成本,再进行烟叶数目统计,提出了一种基于 YOLOv8n 改进的轻量化烟叶计数检测算法 YOLOv8-SLSS,解决了原始 YOLOv8n 模型在应用于烟叶检测时存在的检测精度不足、计算复杂度高以及烟叶遮挡场景导致的漏检问题。本研究引入的 ShuffleNetV2light 模块,缩减了模型大小和计算量,设计的 LHCB 模块扩大了模型的感受视野,提高了模型检测精度。SEAMDetect 模块的引入有效增强了密集遮挡目标的检测能力。引入的 SPPELAN 模块,能够提取图像不同尺度的特征信息,丰富特征图的表达能力。实验结果表明,YOLOv8-SLSS 具有参数量更少、计算量更低、检测精度更高等优点。模型大小压缩到仅有 2.4 MB,参数量为 1.1 M,减少了 63.3%,模型计算量为 3.1 GFLOPs,减小了 61.7%,检测

速度为 83 FPS,提高了 5.1%,满足实时性要求,能够实现烟叶的智能化、快速统计。在实际预估中检测精度达到了 90% 以上,比人工预估效率提升了约 1000 倍,对于烟叶产量的预估估算、现代化智慧烟草农业的推进具有一定的意义。但仍存在一些局限性,例如通过检测模型分割的图像存在一定程度的倾斜和包含部分相邻植株叶片信息,影响算法检测精度,本研究方法需要进行适当的调整和优化,未来将继续在模型优化、模型移动端部署、等方向深入研究,为植物叶片计数提供更加准确、高效和实用的解决方案。

参 考 文 献

- [1] KOLHAR S, JAGTAP J. Plant trait estimation and classification studies in plant phenotyping using machine vision-A review[J]. Information Processing in Agriculture, 2023, 10(1): 114-135.
- [2] DU L P, YANG H, SONG X, et al. Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods[J]. Scientific Reports, 2022, 12(1): 15937.
- [3] WU S X, SU H, GAO F Y, et al. An insight into the prevention and control methods for bacterial wilt disease in tomato plants [J]. Agronomy, 2023, 13(12): 3025.
- [4] JI Y SH, CHEN ZH, CHENG Q, et al. Estimation of plant height and yield based on UAV imagery in faba bean(*Vicia faba* L.)[J]. Plant Methods, 2022, 18(1): 26.
- [5] LI Y L, ZHAN X H, LIU SH Y, et al. Self-supervised plant phenotyping by combining domain adaptation with 3D plant model simulations: Application to wheat leaf counting at seedling stage[J]. Plant Phenomics, 2023, 5: 0041.
- [6] SYAZWANI R W N, ASRAF H M, AMIN M A M S, et al. Automated image identification, detection and fruit counting of top-view pineapple crown using machine learning[J]. Alexandria Engineering Journal, 2022, 61(2): 1265-1276.
- [7] MARZAN C S, MARCOS N. Towards tobacco leaf detection using Haar cascade classifier and image processing techniques [C]. 2nd International Conference on Graphics and Signal Processing, 2018: 63-68.
- [8] HARJOKO A, PRAHARA A, SUPARDI T W, et al. Image processing approach for grading tobacco leaf based on color and quality[J]. International Journal on Smart Sensing and Intelligent Systems, 2019, 12(1): 1-10.
- [9] WU Y, HUANG J G, YANG CH L, et al.

- TobaccoNet: A deep learning approach for tobacco leaves maturity identification[J]. Expert Systems with Applications, 2024, 255: 124675.
- [10] WANG M, FU B, FAN J, et al. Sweet potato leaf detection in a natural scene based on faster R-CNN with a visual attention mechanism and DIoU-NMS[J]. Ecological Informatics, 2023, 73: 101931.
- [11] XU X M, WANG L, LIANG X W, et al. Maize seedling leave counting based on semi-supervised learning and UAV RGB images [J]. Sustainability, 2023, 15(12): 9583.
- [12] NIU SH W, NIE ZH G, LI G, et al. Early drought detection in maize using UAV images and YOLOv8+[J]. Drones, 2024, 8(5): 170.
- [13] MA B L, HUA ZH X, WEN Y CH, et al. Using an improved lightweight YOLOv8 model for real-time detection of multi-stage apple fruit in complex orchard environments [J]. Artificial Intelligence in Agriculture, 2024, 11:70-82.
- [14] 胡峻峰,李柏聪,朱昊,等.改进YOLOv8的轻量化无人机目标检测算法[J].计算机工程与应用,2024,60(8):182-191.
- HU J F, LI B C, ZHU H, et al. Improved YOLOv8 lightweight UAV target detection algorithm [J]. Computer Engineering and Applications, 2024, 60(8): 182-191.
- [15] WANG C Y, YEH I H, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. European Conference on Computer Vision. Springer, Cham, 2025: 1-21.
- [16] 林恩惠,王凡,谭晓玲.结合超轻量级双注意力模块的ShuffleNetV2面部表情识别[J].电子测量技术,2024,47(10):168-174.
- LIN EN H, WANG F, TAN X L. Facial expression recognition of ShuffleNetV2 combined with ultra-lightweight dual attention modules [J]. Electronic Measurement Technology, 2024, 47(10): 168-174.
- [17] WANG AO, CHEN H, LIU L H, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [18] WANG T, ZHANG SH Q. DSC-Ghost-Conv: A compact convolution module for building efficient neural network architectures [J]. Multimedia Tools and Applications, 2024, 83(12): 36767-36795.
- [19] GUI J SH, WU J C, WU D W, et al. A lightweight tea buds detection model with occlusion handling [J]. Journal of Food Measurement and Characterization, 2024, 18(9): 7533-7549.
- [20] YU Z P, HUANG H B, CHEN W J, et al. YOLO-facev2: A scale and occlusion aware face detector [J]. Pattern Recognition, 2024, 155: 110714.
- [21] CAO M T. Drone-assisted segmentation of tile peeling on building façades using a deep learning model [J]. Journal of Building Engineering, 2023, 80: 108063.
- [22] 梁秀满,安金铭,曹晓华,等.基于改进MobileNetV3烧结断面火焰图像识别[J].电子测量技术,2024,46(14):182-187.
- LIANG X M, AN J M, CAO X H, et al. Flame image recognition of sintering section based on improved MobileNetV3 [J]. Electronic Measurement Technology, 2024, 46(14): 182-187.
- [23] 李茂,肖洋轶,宗望远,等.基于改进YOLOv8模型的轻量化板栗果实识别方法[J].农业工程学报,2024,40(1):201-209.
- LI M, XIAO Y Y, ZONG W Y, et al. Detecting chestnuts using improved lightweight YOLOv8 [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(1): 201-209.
- [24] 李松,史涛,井方科.改进YOLOv8的道路损伤检测算法[J].计算机工程与应用,2023,59(23):165-174.
- LI S, SHI T, JING F K. Improved road damage detection algorithm of YOLOv8 [J]. Computer Engineering and Applications, 2023, 59 (23): 165-174.

作者简介

- 肖恒树**,硕士研究生,主要研究方向为计算机视觉、移动开发、图像识别及分类相关应用。
E-mail: hengshu_xiao@mail.ynu.edu.cn
- 李军营**(通信作者),博士,研究员,主要研究方向为烟草栽培技术、土壤保育等。
E-mail: ljjy1250@163.com
- 梁虹**,硕士,教授,主要研究方向为深度学习和信号处理。
E-mail: liangh@ynu.edu.cn
- 马二登**,博士,副研究员,主要研究方向为烟草栽培。
E-mail: erdengma@163.com
- 张宏**,本科,农艺师,主要研究方向为烟草学。
E-mail: 83754331@qq.com