

基于 RAPESEED – YOLO 的散铺油菜角果籽粒数检测方法研究

徐胜勇^{1,2} 许荣升^{1,2} 蒋明锡^{1,2} 廖庆喜^{1,2}

(1. 华中农业大学工学院, 武汉 430070; 2. 农业农村部长江中下游农业装备重点实验室, 武汉 430070)

摘要: 油菜角果平均籽粒数是评价产油量的核心指标。传统人工检测方法存在破坏性大、主观误差大、效率低等缺陷。为此,提出一种基于姿态信息的角果内含籽粒数统计方法,实现散铺油菜角果籽粒的自动化无损检测。引入 RAPESEED – YOLO 网络,加入轻量化 VanillaNet 主干网络、P2 小目标检测头及多尺度膨胀注意力机制(MSDA),增强小目标特征提取能力;设计动态检测头(Dynamic Head)与动态采样器(DySample),结合 C3k2_MDConv2 模块优化多尺度特征融合;提出 Shape – IoU 损失函数,提升小目标边界框回归精度,降低模型体积,提升运算速度,便于部署。实验结果表明,RAPESEED – YOLO 网络精度为 98.6%、召回率为 98.7%、平均精度均值为 98.9%,本统计方法在 15 组生产实验中平均精度为 95.6%,误差小于 10%,理想状态下可达到 3 株/h 的高通量。展现出在农业场景下高鲁棒性与低资源消耗特性,为油菜籽粒无损检测提供了精准、高效、轻量化的实用技术路径,对推动油菜测产具有重要应用价值。

关键词: 油菜测产; 中脊线提取; 籽粒计数; RAPESEED – YOLO; YOLO 11

中图分类号: S24

文献标识码: A

文章编号: 1000-1298(2026)11-0334-09

OSID:



Detection Algorithm of Scattered Rapeseed Pods Based on RAPESEED – YOLO

XU Shengyong^{1,2} XU Rongsheng^{1,2} JIANG Mingxi^{1,2} LIAO Qingxi^{1,2}

(1. School of Engineering, Huazhong Agricultural University, Wuhan 430070, China

2. Key Laboratory of Agricultural Equipment in the Middle and Lower Reaches of the Yangtze River, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China)

Abstract: Rapeseed is China's dominant oil crop and the mean seed number per silique is the key predictor of yield; however, manual dissection is destructive, subjective and labor-intensive. A pose-aware, non-destructive counting pipeline that integrated digital imaging with a customized YOLO detector named RAPESEED – YOLO was proposed. The network employed a lightweight VanillaNet backbone, a P2 micro-object head and multi-scale dilated attention (MSDA) to enhance tiny-seed features, while a Dynamic Head with DySample up-sampler and a C3k2_MDConv2 fusion module refined multi-scale context. Training was regularized by Shape – IoU loss to improve bounding-box regression for ellipsoidal seeds. Evaluated on 15 field plots (three cultivars, two densities), RAPESEED – YOLO achieved 98.6% precision, 98.7% recall and 98.9% mAP; the overall pipeline delivered 95.6% counting accuracy with less than 10% relative error across 6 800 siliques. Operating on a 15 W edge device, the system processed three plants per hour, demonstrating robustness to uneven illumination, occlusion and cultivar variation. Pose-specific multiplication factors (upright 1 ×, semi-lateral 2 × strong-side, full-lateral 2 × single-side) convert detected seeds into total silique counts without physical contact. With only 2.3×10^6 parameters and 5.1×10^9 FLOPs, the method offered a lightweight, accurate and deployable solution for high-throughput rapeseed yield estimation.

Key words: rapeseed measurement; skeleton extraction; seed counting; RAPESEED – YOLO; YOLO 11

收稿日期: 2025 – 09 – 16 修回日期: 2026 – 01 – 07

基金项目: 国家重点研发计划项目(2018YFD1000902)和中央高校基本科研业务费专项资金项目(2662022GXYJ001)

作者简介: 徐胜勇(1980—),男,副教授,博士,主要从事 AI 视觉检测技术研究,E-mail: xsy@mail.hzau.edu.cn

通信作者: 廖庆喜(1968—),男,教授,博士,主要从事现代农业装备与计算机测控研究,E-mail: liaoqx@mail.hzau.edu.cn

0 引言

油菜是食用植物油和植物蛋白的主要来源,也是我国种植面积最广、最重要的油料作物^[1]。油菜每角果粒数指每个角果中的油菜籽的数量,是油菜表型关键指标之一,直接反映油菜结实能力和产量潜力,对油菜测产意义重大^[2]。传统的每角果粒数是通过人工破荚获取籽粒后逐粒计数,存在效率低下、劳动强度大、破坏样本等固有缺陷^[3]。

当前,籽粒计数技术主要依靠传感器计数和计算机视觉技术,应用深度学习网络后计数更方便、快捷且精准。基于传感器计数方式可在较短时间内实现大量种子计数,可重复性好,在籽粒计数方面的研究和应用较为广泛^[4]。基于计算机视觉的计数方法具有速度快、效率高、精度高、成本低、无损等优点,更符合当前农业发展需求,近年来取得了长足的发展。根据是否将籽粒取出检测可以将现有籽粒检测方法分为脱粒计数方法^[5-11]与非脱粒计数方法^[12-20]。非脱粒计数方法可以实现无损检测且省去脱粒等工序,更具研究和应用价值,但研究难度较大。透射成像方式直接获取果荚内的籽粒信息,配合视觉算法可以达到较高的识别率。

针对当前油菜籽粒计数方法准确率低、效率低及受限于图像拍摄视角的问题,提出一种优化检测方法,该方法利用透射光源获取单视角散铺油菜角果图像,通过划分正置、全侧置和半侧置 3 种角果类型,结合图像形态分类处理算法,建立一种基于 RAPESEED - YOLO 网络的散铺角果籽粒检测系统并通过消融实验和验证实验检测系统性能。对角果图像分类处理后再输入改进网络的流程实现单视角下散铺油菜角果籽粒的准确检测,以期为油菜测产提供技术支撑。

1 材料与方法

1.1 实验材料与数据采集

2024 年 4—5 月和 2025 年 4—5 月,在湖北省武汉市华中农业大学油菜试验田间隔 1 m 点位随机采集了绿熟期的华油杂 62 号、中双 11 号 2 个品种油菜各 20 株,去除残破及营养不良的异形角果后,筛选得到 1 000 个包含果柄果喙的完整两室型油菜角果,选取 400 个角果用于算法训练,其余用于算法性能测试。图 1a 为自研背光图像采集装置,采用轻型不锈钢框架覆以黑色亚克力外壳,兼顾强度和轻量化同时隔绝外界光照干扰。背光光源采用 340 mm × 340 mm 定制 LED 背光板(色温 6 000 K)。使用计算机和海康威视 CMOS 工业相机(型号 MV -

CS200 - 10GM,分辨率 5 472 像素 × 3 648 像素)构成成像系统,相机垂直向下安装于支撑架,距 LED 光板高度约 50 cm。在 LED 光板上人工散铺角果,每组 25 ~ 45 个,使用配套的自研人机软件控制相机拍摄彩色图像。图 1b 为图像采集与处理软件,基于 PyQt5 界面库、使用 Python 语言设计,该软件界面集成了相机初始化、拍摄图像展示、检测图像、保存数据等功能,确保了操作的便捷性与数据的准确性。




图 1 图像采集平台

Fig. 1 Image of transmission imaging device

1. 黑色亚克力板外壳 2. 工业相机 3. 相机支撑架 4. 不锈钢框架 5. LED 光板

1.2 基于姿态信息的角果内含籽粒数统计方法

不同姿态的角果背光图像具有显著的差异。正置姿态角果近似于中脊线对称,中脊线两侧的油菜籽互不遮挡,内含籽粒数为网络识别结果。全侧置姿态角果检测不到中脊线,一侧的籽粒完全遮挡另一侧,内含籽粒数可以近似处理为网络识别结果的 2 倍。半侧置姿态角果可以检测到中脊线,但往往一侧的籽粒部分遮挡了另一侧,将籽粒完全暴露的一侧称之为强侧,被遮挡的一侧称之为弱侧,内含籽粒数可以近似处理为强侧网络识别结果的 2 倍。

散铺角果籽粒计数方法整体流程如图 2 所示,包括:①利用 YOLO 11 网络分割散铺角果图像中的单个角果同时检测其姿态。②半侧置角果强-弱侧检测与强侧图像分割。③使用 RAPESEED - YOLO 识别正置角果、全侧置角果和半侧置角果强侧中的油菜籽。④针对 3 种姿态分别进行数据处理得到角果的内含籽粒数,求和得到该批次角果的籽粒总数。

1.3 角果姿态识别与分割

使用 YOLO 11 网络进行角果分割和姿态识别。以正置、全侧置和半侧置 3 种姿态名称作为标签,使用 Labellmg 标注工具生成 txt 标签文件,构建 YOLO 数据集得到 400 个有效目标。全姿态散铺油菜角果图像数据集按照比例 8:1:1 划分训练集、验证集、测试集。经数据增强将数据集扩充到原来的 8 倍,得到扩充后的数据集共 3 200 幅图像,其中训练集 2 560 幅、验证集 320 幅、测试集 320 幅,以扩充后的数据集为模型输入数据集,进行训练、验证和测试。




Fig. 2 Flow chart of scattered pod seed counting method

1.4 半侧置姿态角果强-弱侧检测方法

将角果图像中分隔果荚两室的薄膜形成的线称为角果中脊线^[21]。在半侧置姿态下,中脊线的一侧面积远大于另一侧,被分别标识为强侧和弱侧。半侧置角果的强侧图像分割流程如图 3 所示。如




图 3 油菜角果中脊线提取流程图

Fig. 3 Flowchart of extraction of midline of pod

使用 n 阶多项式拟合骨架点集,得到的拟合中脊线如图 3e 所示,拟合中脊线映射到角果图像上与常规形态学骨架提取方法拟合得到的中脊线如图 3f、3g 所示。本方法提取的中脊线更符合果荚真实中脊线,常规方法更偏向形态学中心,经检验平均偏离 3 个像素。最后,根据正确拟合的中脊线分割角果区域,比较左右像素点数量确定弱侧。

1.5 角果背光图像籽粒检测网络 RAPESEED - YOLO

YOLO 11 于 2024 年发布,属于 YOLO 系列的最新迭代版本。该版本可更高效处理不同尺寸和复杂场景下的物体,并且在训练效率、精度和推理速度上都实现了显著提升。针对油菜角果籽粒检测任务中

图 3g 中红色标识所示,传统骨架提取方法无法准确提取出果荚主体中脊线,会误检出中脊线另一侧籽粒。因此提出基于二次图像腐蚀和骨架提取的中脊线提取算法。首先对油菜角果图像进行灰度化、二值化、形态学去噪等预处理后分离出角果与背景,如图 3a、3b 所示。针对角果姿态问题结合 Zhang - Suen 细化算法,提出二次腐蚀细化算法:首先对图像中所有点细化,初次腐蚀,如图 3c 所示,保留籽粒及中脊线部分信息,然后对初次腐蚀后图像二次细化后提取骨架,如图 3d 所示。二次细化能够保持原始图像的拓扑特征,确保骨架连通性和面对复杂形状时的高鲁棒性。对细化的骨架进行闭运算连接断裂,随后进行开运算,移除小分支,确保主骨架的连通性,计算式为

$$S_{\text{clean}}(x,y) = \text{RemoveSObj}(S(x,y), t_{\text{min}} = 50)$$

式中 x ——像素点横坐标
 y ——像素点纵坐标
 t_{min} ——最小保留阈值
 $S_{\text{clean}}(x,y)$ ——保留的像素点
 $\text{RemoveSObj}()$ ——像素点灰度阈值筛选
 $S(x,y)$ ——原像素点

目标尺寸微小、特征提取不充分等问题,提出 RAPESEED - YOLO 网络,改进后的网络架构如图 4 所示。

主要改进包括:①将主干网络卷积层替换为 VanillaNet 架构^[22],简化网络操作流程提升推理速度。②在 Backbone 浅层引入多尺度膨胀注意力模块 MSDA^[23],实现低成本跨层级特征融合,有效增强小目标(小于 20 像素)^[24]的特征表达能力。③在 P2 层构建小目标检测分支^[25],降低籽粒区域定位误差。④引入动态检测头 Dynamic Head^[26]替代传统探测模块,利用其多注意力机制提升小目标的特征表达能力。⑤采用动态上采样器 DySample^[27]替代标准双线性插值,实现特征图分辨率自适应调整




图 4 RAPESEED - YOLO 结构图

Fig. 4 Structure diagram of RAPESEED - YOLO

减少内存占用;融合可变形卷积 v2 与 C3k2 模块构建 C3k2_MDConv2 结构^[28],自适应调整卷积核感受野,提升模型对不同尺度籽粒的检测覆盖率。⑥引入 Shape - IoU 损失函数^[29],利用其尺度-形状联合惩罚机制缓解高密度场景下的重叠干扰问题。

1.5.1 VanillaNet 轻量化网络

原 YOLO 主干网络存在冗余计算,因此,构建轻量化且计算高效的主干特征提取网络成为提升检测系统部署能力的关键。采用 VanillaNet6 轻量化网络替换原网络主干结构,通过分层设计实现特征提取效率的优化^[30]。随后通过多个 VanillaBlock 层逐步完成从边缘特征到语义特征的多尺度表征。如图 5 所示,Stem 层采用快速下采样机制提取基础特征, VanillaNet6 通过 6 个卷积层逐层执行输入特征下采样与通道数递增策略,伴随采样进行通道数倍增,图像尺寸倍数下降。其摒弃复杂模块,仅通过标准卷积、池化与归一化操作构建特征提取路径,使网络具备极简结构的同时保持特征表达能力,实现了原始特征与高层语义特征的均衡提取。




图 5 VanillaNet 结构图

Fig. 5 Structure diagram of VanillaNet

1.5.2 MSDA 多尺度膨胀注意力

在白色 LED 背光透射成像条件下,油菜籽粒检测面临 2 个问题:①籽粒尺寸微小导致目标与背景尺度跨度显著, YOLO 网络的池化与下采样操作易

造成低层细节信息丢失。②果荚背景与籽粒色彩相近,易引发特征混淆,导致网络注意力分散降低检测鲁棒性。因此,引入多尺度膨胀注意力模块 MSDA (Multi - scale dilated attention),通过浅层特征增强实现多尺度特征的协同优化。MSDA 模块采用 3 分支并行结构,如图 6 所示,其核心机制包括多尺度膨胀注意力计算与注意力门控机制。在 YOLO 11 的 Backbone 前 2 个 VanillaBlock 卷积层之后,分别插入 MSDA 模块(标记为 MSDA - 1 和 MSDA - 2)。MSDA - 1 采用较小的膨胀率 $[1, 2, 3]$ 以捕获籽粒的精细边缘特征, MSDA - 2 采用较大的膨胀率 $[2, 4, 6]$ 以增强对籽粒整体形状的感知能力。在每分支使用不同膨胀率的 3×3 空洞卷积处理输入特征图,并行计算可同时捕获 1×1 的局部细节、 7×7 的中等尺度特征以及 11×11 的全局上下文信息,有效解决小目标尺度跨度大的问题。




图 6 MSDA 多尺度膨胀注意力结构图

Fig. 6 Structure diagram of multi-scale dilated attention

引入自适应门控单元 AGU (Adaptive gating unit),通过 Sigmoid 函数计算通道注意力权重,动态调节不同尺度特征的贡献度。可学习的膨胀率参数和注意力权重,使网络能够根据输入图像的复杂程度自适应调整感受野大小。在训练过程中,网络在果荚密集区域扩大感受野抑制背景干扰,在籽粒稀疏区域缩小感受野,精确定位目标边界。

1.5.3 P2 小目标检测头

YOLO 11 网络架构中默认采用 3 层 P3、P4、P5 进行由浅到深多尺度目标检测。最浅层 P3 特征图保留更多空间细节信息,但 2 次下采样后其分辨率仅为输入图像的 $1/4$,造成小尺寸籽粒特征信息丢失;P4、P5 深层特征图小目标的细节捕捉能力受限。针对原网络小目标检测头 P3 无法处理更微小籽粒的检测问题,引入更浅层 P2 检测头提升检测精度。P2 更浅层的特征提取分支,可保留更高分辨率的空间信息,其技术有效性已在多个领域得到验证^[31]。在保留 YOLO 11 原始 P3 ~ P5 检测头的基础上,于颈部网络融合阶段引入 P2 层。如图 7 所示,多尺度

特征金字塔结构实现小目标细节与全局语义的协同建模,显著提升了对密集分布角果籽粒的定位与识别能力。




图 7 优化后的检测头结构

Fig. 7 Structure diagram of optimized detection head

1.5.4 Dynamic Head 动态检测头

在油菜角果籽粒检测任务中,目标尺寸微小且在果荚图像中籽粒特征差异较大,这对检测头的尺度适应性与空间特征建模能力提出双重挑战。

如图 8 所示,引入 Dynamic Head 架构,通过多注意力机制的协同优化实现对小目标特征的精细捕捉与复杂背景干扰的抑制。该检测头仅增加少量参数,通过尺度注意力模块增强对微小籽粒的跨层特征关联,同时空间注意力机制强化局部细节与全局的动态平衡,并通过任务导向的通道权重分配优化特征表达的判别性。

1.5.5 DySample 上采样和 C3k2_MDConv2 模块

DySample(动态上采样器)具有轻量化且高效的设计,在密集预测任务中性能优秀,因此使用




图 8 Dynamic Head 检测头结构

Fig. 8 Structure diagram of Dynamic Head detection

DySample 模块替换原有的最近邻插值上采样器。部署位置为:①FPN(特征金字塔)模块中的 2 个上采样层。②PAN(路径聚合网络)模块中的特征融合前的上采样操作。采用 4×4 的动态卷积核,通过多层感知机生成上采样核参数。第 1 层多层感知机将输入通道数从 C 压缩至 $C/4$,第 2 层保持维度不变,第 3 层扩展至 $16C(4 \times 4 \times C)$ 。

传统网络固定尺寸、规则形状的卷积核均匀采样图像特征,导致感受野范围和采样位置固定(图 9a),使得网络难以有效捕捉目标物体在尺度、姿态及空间分布上的多样性特征。因此,基于 C3k2 基础模块提出 C3k2_MDConv2 调制可变形卷积模块,首先融合如图 9c、9d 所示可变形卷积网络(DCNv2)实现卷积核形状自适应调整,如图 9b 所示;再引入位置敏感权重机制,通过先验引导与预测偏移量的加权融合实现对检测置信度高的区域自动增加采样密度;最后,不同卷积核尺寸的模块多分支并行处理,每个分支设定不同膨胀率通过注意力机制融合不同尺度的特征响应。




图 9 标准卷积和可变形卷积采样点位置结构图

Fig. 9 Standard convolution and deformable convolution sampling point position structure diagram

1.5.6 基于 Shape - IoU 的边界框回归损失函数优化

传统交并比 (IoU) 损失函数依赖于交并比指标,易导致小目标定位偏差。为此,引入 Shape - IoU 损失函数,通过显式建模边界框自身尺度与形状差异,提升回归精度。如图 10 所示,该损失函数在传统 IoU 基础上,增加形状相似性约束项,使回归过程同时关注目标长宽比、尺度比例等几何特性。Shape - IoU 损失函数有效缓解小目标因形状畸变导致的定位偏差问题,可精准提取圆形目标的边界特征,同时

提升小目标定位鲁棒性,实现检测精度与模型稳定性的双重提升。

2 结果与分析

2.1 模型训练环境与评价指标

以 Pytorch 2.3.1 和 CUDA 12.1 作为深度学习框架,基于 Python3.9 实现对模型的训练。CPU 型号为 Intel Core i9 - 11980 (32 GB),GPU 型号为 Nvidia GeForce RTX 3080 (16 GB)。图像尺寸为 640 像素 $\times$ 640 像素,训练轮数为 500 轮,批处理




图 10 Shape-IoU 损失函数结构

Fig. 10 Structure diagram of Shape-IoU loss function

大小为 32,子进程数设置为 4,采用 Adam 优化器,设置学习率为 0.01。训练时调用早停机制避免过拟合,同时保证模型有较好的泛化性能。为了对模型性能进行客观评估,主要用于评估的评估指标为:mAP₅₀(IoU 阈值为 0.5 时的平均精度)、召回率 (Recall, R)、推理速度 (Frames per second, FPS)和精确率 (Precision, P)。

2.2 角果分割与姿态识别性能测试

角果姿态识别的整体精度为 98.1%,其中正置角果识别精度为 98.4%、半侧置角果识别精度为 97.6%、全侧置角果识别精度为 98.0%。散铺油菜角果图及分类检测结果如图 11 所示,抽样检查 100 例未发生错分问题,满足实验要求。




图 11 油菜角果果荚全姿态图像

Fig. 11 Images of entire posture of pods

2.3 RAPESEED – YOLO 网络测试结果

2.3.1 消融实验

为验证改进方法的有效性,在相同训练环境及参数配置下对 RAPESEED – YOLO 模型中的改进模块开展消融实验,共设置 12 组消融实验,结果如表 1 所示。基于表 1 实验结果,对 YOLO 11 网络优化后形成 RAPESEED – YOLO 算法模型,实现检测精度与推理效率的协同提升。首先,VanillaNet 替换原 CSPDarknet53 主干网络,mAP₅₀仅下降 0.6 个百分点,显著提升推理速度,验证其轻量化潜力;引入 MSDA 注意力机制使 mAP₅₀提升 3.7 个百分点,叠加 P2 检测头与 Dynamic Head 动态检测头,分别提升 1.3、0.8 个百分点,显著改善小目标检测性能及尺度-空间感知能力;采用 DySample 动态上采样与 C3k2_MDConv2 模块,在保持 mAP₅₀的前提下进一步提升推理速度;损失函数替换为 Shape-IoU,使 mAP₅₀再提升 0.5 个百分点,增强模型对角果籽粒形状与位置特征的敏感性。实验表明上述改进通过 Backbone 层轻量化设计、Neck 层多尺度特征增强、Head 层形状敏感损失函数等改进策略,使得 RAPESEED – YOLO 模型的 mAP₅₀较 YOLO 11 模型提升 5.6 个百分点,浮点运算量减少 3.18 × 10¹⁰,可有效解决角果籽粒小目标检测精度与效率的平衡难题。

2.3.2 不同算法模型结果对比

选取两阶段算法 Faster R – CNN 及单阶段算法 YOLO v8m、YOLO v9m、SSD 作为对照组,开展系统性对比实验。不同算法的性能对比结果如表 2 所示。RAPESEED – YOLO 模型 P 为 98.6%、R 为

表 1 YOLO 模型消融实验结果

Tab. 1 Ablation test results of YOLO model

VanillaNet	MSDA	P2	Dynamic Head	DySample	C3k2_MD Conv2	Shape-IoU	mAP ₅₀ / %	P/%	R/%	内存占用 量/MB	浮点 运算量
×	×	×	×	×	×	×	93.3	92.4	91.7	35.5	6.85 × 10 ¹⁰
✓	×	×	×	×	×	×	92.7	91.9	91.9	10.7	2.09 × 10 ¹⁰
×	✓	×	×	×	×	×	93.8	94.2	93.6	36.4	7.34 × 10 ¹⁰
×	×	✓	×	×	×	×	95.6	95.9	94.3	39.2	8.69 × 10 ¹⁰
×	×	×	✓	×	×	×	94.3	94.1	93.1	37.1	6.96 × 10 ¹⁰
×	×	×	×	✓	✓	×	93.4	94.3	94.6	34.7	6.43 × 10 ¹⁰
×	×	×	×	×	×	✓	94.6	94.9	94.1	35.1	6.84 × 10 ¹⁰
✓	✓	×	×	×	×	×	96.4	96.6	94.3	11.8	2.57 × 10 ¹⁰
✓	✓	✓	×	×	×	×	97.7	97.2	96.5	14.9	3.78 × 10 ¹⁰
✓	✓	✓	✓	×	×	×	98.5	98.7	97.3	15.3	3.83 × 10 ¹⁰
✓	✓	✓	✓	✓	✓	×	98.4	98.5	98.6	15.5	3.65 × 10 ¹⁰
✓	✓	✓	✓	✓	✓	✓	98.9	98.6	98.7	15.4	3.67 × 10 ¹⁰

注: × 表示不调用该改进方法,✓ 表示调用该改进方法。

表 2 不同模型检测性能对比

Tab.2 Comparison of detection performance with different models

模型	精确率/%	召回率/%	mAP ₅₀ /%	内存占用量/MB	浮点运算量
RAPESEED – YOLO	98.6	98.7	98.9	15.4	3.67×10^{10}
YOLO v8m	95.3	94.5	94.3	76.7	7.93×10^{10}
YOLO v9m	93.2	90.9	92.7	53.1	7.79×10^{10}
SSD	89.6	45.3	90.7	101.4	1.064×10^{11}
Faster R – CNN	85.9	71.2	88.5	228.3	2.372×10^{11}
2D 图像分析	97.2				

98.7%、mAP₅₀为 98.9%，相较于 YOLO v8m、YOLO v9m、SSD 及 Faster R – CNN，RAPESEED – YOLO 的 P 值分别提升 3.3、5.4、9.0、12.7 个百分点，R 值分别提升 4.2、7.8、53.4、27.5 个百分点，mAP₅₀ 分别提升 4.6、6.2、8.2、10.4 个百分点。同时，RAPESEED – YOLO 模型内存占用量仅 15.4 MB，训练时浮点运算量为 3.67×10^{10} ，相较 YOLO v8m 和 YOLO v9m 降低 50% 以上，较 SSD 降低 60%，较 Faster R – CNN 降低 84%；参数量仅为 SSD 的 14.5% 和 Faster R – CNN 的 6.5%。与基于 2D 图像的单个油菜籽粒无损检测计数方法相比较^[15]，精确率提升 1.4 个百分点，证明了 RAPESEED – YOLO 网络的优势。该模

型的低算力需求与较小内存占用量使其可部署于算力受限的移动端设备，显著降低硬件成本，兼具高效性与经济性。

2.3.3 改进网络鲁棒性分析

角果透射图像的籽粒识别面临如下问题：①图像过曝光、正常曝光及欠曝光状态。②因含水量差异及病虫害导致的果皮缺陷影响透光性。③角果不同姿态与不同形态。为验证 RAPESEED – YOLO 算法的鲁棒性，选取涵盖上述复杂场景的 50 幅图像进行测试，检测效果如图 12 所示，结果表明该模型在光照变化、形态畸变及密度干扰下仍能保持稳定检测性能，验证了其对农业复杂场景的适应能力。




图 12 不同类型角果图像的检测结果

Fig.12 Detection results of different types of rapeseed pod images

分别对 50 幅过曝光、欠曝光及籽粒粘连图像进行实验，记录 P、R 及 mAP50，如表 3 所示，常见干扰下模型 P 可达 96.5% 以上。定量分析结果再次验证 RAPESEED – YOLO 算法良好的鲁棒性。

表 3 不同场景下检测性能对比

Tab.3 Comparison of detection performance with different scenarios

场景	精确率	召回率	mAP ₅₀
正常曝光	98.6	98.7	98.9
过度曝光	97.8	98.0	98.2
欠曝光	97.5	97.6	97.9
粘连对象	96.5	97.0	90.7

2.4 批量角果籽粒数检测性能分析

随机选取华油杂 62 号、中双 2 个品种的油菜植株进行实测。共测试了 15 个批次、每批次 24 ~ 45 个角果，共 527 个角果。先使用本文方法无损检测每批次角果的籽粒数，再人工破开果荚进行计数。以检测值与实测值的比值为准确率绘制对比图，如图 13 所示。由图 13 可知，角果籽粒检测平均误差为 4.4%，最大误差为 9.1%、最小误差

为 0.8%。在某些批次中，检测值比实际值要大，主要原因是全侧置和半侧置角果的计数方法是一侧的倍增，但角果并非完全对称，导致计数值大于实际值。




图 13 散铺油菜角果籽粒数预测与实测对比图

Fig.13 Comparison chart of predicted and measured seed numbers in pods of scattered rapeseed

检测速度是另一个重要指标。以 300 个角果的一株典型油菜为例，本文方法涉及到几个耗时环节包括：人工摘除角果，约 600 s；人工平铺角果，约 400 s；操作计算机拍摄图像并自动检测，110 s；角果下料并清洁透光板，60 s。每株油菜需耗时为 1 170 s，即 3.1 株/h，是人工非破荚考种速度的 5.7 倍，同时工作强度显著下降。

3 结论

(1) 提出了一种结合几何特征提取与 RAPESEED – YOLO 网络的基于姿态信息的角果内含籽粒数统计方法。批量角果籽粒数检测实验表明,结合姿态信息的籽粒计数方法充分利用计算机视觉方式提取的单视角图像特征与 RAPESEED – YOLO 网络的轻量化和高精度特点,具有 90% 以上的高精度和约 3.1 株/h 的高通量。相较于人工考种保证准确率的同时效率提升 4.7 倍;相较于已有单角果半自动测产方法,精度仅降低 3 个百分点,效率大幅提升。能够满足油菜测产中高精度、高鲁棒性、高效率的要求,可为油菜测产提供技术支撑。

(2) YOLO 11 网络识别整盘角果姿态的整体精度为 98.1%,实测 100 例未错分。针对半侧置角果难以准确统计籽粒数的问题,提出基于二次图像腐蚀的细化骨架提取算法,精准提取非正置果荚图像中脊线,相对于传统形态学骨架提取方法修正了 3 个像素点以上的骨架提取误差,极大降低弱侧错分概率从而实现为下一步目标检测网络输送更为精确的果荚图像。

(3) 针对两室油菜角果籽粒受拍摄姿态影响

大、油菜角果籽粒尺度小、果荚作为背景对前景籽粒存在干扰、YOLO 11 原模型对于提取目标角果的形状和位置特征的能力有待提升等问题,提出了一种 YOLO 改进网络 RAPESEED – YOLO。在特征提取、检测部分及网络深度做出优化,系统性解决了传统 YOLO 系列模型在农业微小目标检测中的性能瓶颈。网络的 P 为 98.6%,R 为 98.7%,mAP50 为 98.9%,与常用单阶段和双阶段模型相比,P 分别提升了 4.4 个百分点以上,R 提升 5.3 个百分点以上,mAP50 提升 5.2 个百分点以上,模型内存占用量仅为 15.4 MB,浮点运算量为 3.67×10^{10} 。

(4) 油菜品种、成熟期不一致等会引起油菜角果形状的较大变化,这类角果称之为“异形角果”,体现在果体弯曲度异常大、角果尺寸异常小、籽粒成熟度异常低等,给视觉检测带来巨大的困难。本文提出的算法对于异形角果的检测准确性大幅下降,但“异形角果”大约占据角果总量的 5%,同时 RAPESEED – YOLO 网络对于正常角果的检测较为可靠准确,所以总体上对于一棵油菜的检测结果来说影响有限。针对异形角果,在实际测产工作中可以人工筛选之后单独计数,以保障整体正确率。此外,对于新型的油菜品种,为保证方法准确率应重新训练获取权重。

参 考 文 献

[1] 李勤,刘小焱,盛紫微,等. 我国油菜适合机械化收获关键农艺性状研究进展[J]. 中国油料作物学报, 2023, 45(5): 1053 – 1061.
LI Qin, LIU Xiaoyan, SHENG Ziwei, et al. Research progress on target agronomic traits for mechanized harvesting of rapeseed in China[J]. Chinese Journal of Oil Crop Sciences, 2023, 45(5): 1053 – 1061. (in Chinese)

[2] 陈苇, 俎峰, 罗延青, 等. 影响甘蓝型油菜每角粒数因素分析[J]. 中国油料作物学报, 2019, 41(3): 331 – 339.
CHEN Wei, ZU Feng, LUO Yanqing, et al. Factors affecting the number of single silique in *Brassica napus* [J]. Chinese Journal of Oil Crop Sciences, 2019, 41(3): 331 – 339. (in Chinese)

[3] 马丽娜, 魏俊逸, 黄小毛, 等. 油菜联合收获机割台振动对田间收获落粒影响分析[J]. 农业机械学报, 2020, 51(增刊 2): 134 – 138, 201.
MA Lina, WEI Junyi, HUANG Xiaomao, et al. Analysis of harvesting losses of rapeseed caused by vibration of combine harvester header during field operation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 134 – 138, 201. (in Chinese)

[4] 丁幼春, 王凯阳, 杜超群, 等. 高通量小粒径种子流检测装置设计与试验[J]. 农业工程学报, 2020, 36(13): 20 – 28.
DING Youchun, WANG Kaiyang, DU Chaoqun, et al. Design and experiment of high-flux small-size seed flow detection device [J]. Transactions of the CSAE, 2020, 36(13): 20 – 28. (in Chinese)

[5] 彭顺正, 岳延滨, 冯恩英, 等. 基于机器视觉的油菜籽计数系统开发与与设计[J]. 计算机应用, 2020, 40(增刊 2): 142 – 146.
PENG Shunzheng, YUE Yuanbin, FENG Enying, et al. Development and design of rapeseed counting system based on machine vision[J]. Journal of Computer Applications, 2020, 40(Supp. 2): 142 – 146. (in Chinese)

[6] WU D, CAI Z, HAN J, et al. Automatic kernel counting on maize ear using RGB images[J]. Plant Methods, 2020, 16(1): 79.

[7] PENG J, YANG Z, LV D, et al. A dynamic rice seed counting algorithm based on stack elimination[J]. Measurement, 2024, 227: 114275.

[8] CHEN Z, FAN W, LUO Z, et al. Soybean seed counting and broken seed recognition based on image sequence of falling seeds [J]. Computers and Electronics in Agriculture, 2022, 196: 106870.

[9] 王玲, 张旗, 冯天赐, 等. 基于 YOLO v7 – ST 模型的小麦籽粒计数方法研究[J]. 农业机械学报, 2023, 54(10): 188 – 197, 204.
WANG Ling, ZHANG Qi, FENG Tianci, et al. Wheat grain counting method based on YOLO v7 – ST model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 188 – 197, 204. (in Chinese)

- [10] 奚小波, 赵杰, 史扬杰, 等. 基于改进凹点分割的小麦播种籽粒落种分布在线检测方法[J]. 农业机械学报, 2024, 55(7): 75–82.
XI Xiaobo, ZHAO Jie, SHI Yangjie, et al. Online detection method for wheat seeding distribution based on improved concave point segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 75–82. (in Chinese)
- [11] MUSSADIQ Z, LASZLO B, HELYES L, et al. Evaluation and comparison of open source program solutions for automatic seed counting on digital images[J]. Computers and Electronics in Agriculture, 2015, 117: 194–199.
- [12] ZHAO Y, WU W, ZHOU Y, et al. A backlight and deep learning based method for calculating the number of seeds per silique[J]. Biosystems Engineering, 2022, 213: 182–194.
- [13] 陈威, 朱怡航, 顾清, 等. 基于机器视觉和 YOLOv5 的油菜角果表型参数分析[J]. 浙江农业学报, 2024, 36(6): 1379–1388.
CHEN Wei, ZHU Yihang, GU Qing, et al. Analysis of phenotypic parameters of rapeseed silique based on machine vision and YOLOv5[J]. Acta Agriculturae Zhejiangensis, 2024, 36(6): 1379–1388. (in Chinese)
- [14] 姚业浩, 李毅念, 陈玉仑, 等. 基于油菜角果长度图像识别的每角粒数测试方法[J]. 农业工程学报, 2021, 37(23): 153–160.
YAO Yehao, LI Yinian, CHEN Yulun, et al. Testing method for the seed number per silique of oilrape based on recognizing the silique length images[J]. Transactions of the CSAE, 2021, 37(23): 153–160. (in Chinese)
- [15] XU S, XU R, MA P, et al. Design of a non-destructive seed counting instrument for rapeseed pods based on transmission imaging[J]. Agriculture, 2024, 14(12): 2215.
- [16] KHAKI S, PHAM H, HAN Y, et al. Convolutional neural networks for image-based corn kernel detection and counting[J]. Sensors, 2020, 20(9): 2721.
- [17] UZAL L C, GRINBLAT G L, NAMÍAS R, et al. Seed-per-pod estimation for plant breeding using deep learning[J]. Computers and Electronics in Agriculture, 2018, 150: 196–204.
- [18] ZHAO J, KAGA A, YAMADA T, et al. Improved field-based soybean seed counting and localization with feature level considered[J]. Plant Phenomics, 2023, 5: 0026.
- [19] SUN J, ZHANG Y, ZHU X, et al. Deep learning optimization method for counting overlapping rice seeds[J]. Journal of Food Process Engineering, 2021, 44(9): e13787.
- [20] 宋怀波, 王云飞, 段援朝, 等. 基于 YOLO v5 – MDC 的重度粘连小麦籽粒检测方法[J]. 农业机械学报, 2022, 53(4): 245–253.
SONG Huaibo, WANG Yunfei, DUAN Yuanchao, et al. Detection method of severe adhesive wheat grain based on YOLO v5 – MDC model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 245–253. (in Chinese)
- [21] 吕泽文, 徐平, 张向向, 等. 芥菜型油菜多室角果的解剖特征及遗传分析[J]. 中国油料作物学报, 2012, 34(5): 461–466.
LÜ Zewen, XU Ping, ZHANG Xiangxiang, et al. Primary study on anatomic and genetic characteristics of multi-loculus in *Brassica juncea*[J]. Chinese Journal of Oil Crops, 2012, 34(5): 461–466. (in Chinese)
- [22] CHEN H, WANG Y, GUO J, et al. Vanillanet: the power of minimalism in deep learning[J]. Advances in Neural Information Processing Systems, 2023, 36: 7050–7064.
- [23] JIAO J, TANG Y M, LIN K Y, et al. Dilateformer: multi-scale dilated transformer for visual recognition[J]. IEEE Transactions on Multimedia, 2023, 25: 8906–8919.
- [24] LIN T-Y, MAIRE M, BELONGIE S, et al. Microsoft coco: common objects in context[C] // Proceedings of the European Conference on Computer Vision, F, 2014.
- [25] 李彬, 李生林. 改进 YOLOv11n 的无人机小目标检测算法[J]. 计算机工程与应用, 2025, 61(7): 1–11.
LI Bin, LI Shenglin. Improved YOLOv11n small object detection algorithm in UAV view[J]. Computer Engineering and Applications, 2025, 61(7): 1–11. (in Chinese)
- [26] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection heads with attentions[C] // Proceedings of the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, F, 2021.
- [27] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C] // Proceedings of the Proceedings of the IEEE/CVF International Conference on Computer Vision, F, 2023.
- [28] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C] // Proceedings of the Proceedings of the IEEE International Conference on Computer Vision, F, 2017.
- [29] 陈兆凡, 赵春阳, 李博. 一种改进 IoU 损失的边框回归损失函数[J]. 计算机应用研究, 2020, 37(增刊 2): 293–296.
CHEN Zhaofan, ZHAO Chunyang, LI Bo. An improved IoU loss-based boundary regression loss function[J]. Computer Application Research, 2020, 37(Supp. 2): 293–296. (in Chinese)
- [30] 张新月, 胡广锐, 李浦航, 等. 基于改进 YOLOv8n 的轻量化红花识别方法[J]. 农业工程学报, 2024, 40(13): 163–170.
ZHANG Xinyue, HU Guangrui, LI Puhang, et al. Recognizing safflower using improved lightweight YOLOv8n[J]. Transactions of the CSAE, 2024, 40(13): 163–170. (in Chinese)
- [31] 李尚平, 郑创锐, 文春明, 等. 基于无人机 RGB 图像与改进 YOLO v5s 的宿根蔗缺苗定位方法[J]. 农业机械学报, 2024, 55(12): 57–70.
LI Shangping, ZHENG Chuangrui, WEN Chunming, et al. Method for locating missing seedlings of perennial sugarcane based on RGB images of unmanned aerial vehicles and improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 57–70. (in Chinese)