

钟海敏, 马旭, 李泽华, 等. 基于 YOLOv5 改进模型的杂交稻芽种快速分级检测 [J]. 华南农业大学学报, 2023, 44(6): 960-967.  
ZHONG Haimin, MA Xu, LI Zehua, et al. Rapid grading detection on hybrid rice bud seeds based on improved YOLOv5 model[J]. Journal of South China Agricultural University, 2023, 44(6): 960-967.

# 基于 YOLOv5 改进模型的杂交稻芽种快速分级检测

钟海敏<sup>1</sup>, 马旭<sup>2</sup>, 李泽华<sup>1,3</sup>, 王曦成<sup>2</sup>, 刘赛赛<sup>2</sup>, 刘伟文<sup>2</sup>, 王承恩<sup>2</sup>, 林泳达<sup>4</sup>

(1 华南农业大学 数学与信息学院, 广东 广州 510642; 2 华南农业大学 工程学院, 广东 广州 510642; 3 农业农村部华南热带智慧农业技术重点实验室, 广东 广州 510642; 4 华南农业大学 电子工程学院, 广东 广州 510642)

**摘要:**【目的】提高杂交稻种子活力分级检测精度和速度。【方法】提出了一种基于 YOLOv5 改进模型 (YOLOv5-I) 的杂交稻芽种快速分级检测方法, 该方法引入 SE (Squeeze-and-excitation) 注意力机制模块以提高目标通道的特征提取能力, 并采用 CIoU 损失函数策略以提高模型的收敛速度。【结果】YOLOv5-I 算法能有效实现杂交稻芽种快速分级检测, 检测精度和准确率高, 检测速度快。在测试集上, YOLOv5-I 算法目标检测的平均精度为 97.52%, 平均检测时间为 3.745 ms, 模型占用内存空间小, 仅为 13.7 MB; YOLOv5-I 算法的检测精度和速度均优于 YOLOv5s、Faster-RCNN、YOLOv4 和 SSD 模型。【结论】YOLOv5-I 算法优于现有的算法, 提升了检测精度和速度, 能够满足杂交稻芽种分级检测的实用要求。

**关键词:** 深度学习; YOLOv5s; 分级检测; 注意力机制; 杂交稻; 种子活力

中图分类号: TP301.6; S511

文献标志码: A

文章编号: 1001-411X(2023)06-0960-08

## Rapid grading detection on hybrid rice bud seeds based on improved YOLOv5 model

ZHONG Haimin<sup>1</sup>, MA Xu<sup>2</sup>, LI Zehua<sup>1,3</sup>, WANG Xicheng<sup>2</sup>, LIU Saisai<sup>2</sup>, LIU Weiwen<sup>2</sup>, WANG Cheng'en<sup>2</sup>, LIN Yongda<sup>4</sup>

(1 College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China; 2 College of Engineering, South China Agricultural University, Guangzhou 510642, China; 3 Key Laboratory of Smart Agricultural Technology in Tropical South China, Ministry of Agriculture and Rural Affairs, P. R. China, Guangzhou 510642, China; 4 College of Electronic Engineering, South China Agricultural University, Guangzhou 510642, China)

**Abstract:** 【Objective】In order to improve the grading detection accuracy and speed of hybrid rice seed vigor. 【Method】A rapid grading detection method for hybrid rice bud seeds named YOLOv5-I model, which was an improved model based on YOLOv5, was proposed. The feature extraction ability of the target channel of YOLOv5-I model was improved by introducing the SE (Squeeze-and-excitation) attention mechanism module, and a CIoU loss function strategy was adopted to improve the convergence speed of this model. 【Result】The YOLOv5-I algorithm effectively achieved the rapid grading detection of hybrid rice bud seeds, with high detection accuracy and speed. In the test set, the average accuracy of the YOLOv5-I model was 97.52%, the average detection time of each image was 3.745 ms, and the memory space occupied by the YOLOv5-I model was small with 13.7 MB. The detection accuracy and speed of YOLOv5-I model was better

收稿日期: 2022-09-12 网络首发时间: 2023-06-15 13:55:27

首发网址: <https://kns.cnki.net/kcms2/detail/44.1110.S.20230614.1659.002.html>

作者简介: 钟海敏, 硕士研究生, 主要从事机器视觉研究, E-mail: 18942434778@163.com; 通信作者: 李泽华, 副教授, 博士, 主要从事现代农业装备智能化研究, E-mail: lzhlj@scau.edu.cn

基金项目: 国家自然科学基金 (52175226); 岭南现代农业实验室科研项目 (NT2021009); 广东省科技厅项目 (KTP20210196); 现代农业产业技术体系建设专项 (CARS-01-47)

than those of YOLOv5s, Faster-RCNN, YOLOv4 and SSD models. 【Conclusion】 The YOLOv5-I algorithm is better than existing algorithms, improves detection accuracy and speed, and can meet the practical requirement for grading detection of hybrid rice bud seeds.

**Key words:** Deep learning; YOLOv5s; Grading detection; Attention mechanism; Hybrid rice; Seed vigor

杂交稻种子活力是杂交稻育种和育秧中的重要指标。育种中,选用高活力的水稻种子进行杂交,有利于选育出高品质的新品种<sup>[1]</sup>。机械化育秧中,种子出芽率和出芽整齐性是影响机械化育秧播种量调节和播种质量的重要参数指标<sup>[2]</sup>。出芽率高且出芽整齐的种子有利于培育高质量的秧苗,而杂交稻种子的出芽率和出芽整齐性与种子的活力息息相关。因此,快速评估杂交稻种子活力具有非常重要的实际意义。传统的种子活力检测方法主要是采用标准的种子发芽试验法,即在一定的条件下,对被检测的种子进行发芽试验并统计发芽率<sup>[3]</sup>。该方法仅将催芽种子分为发芽和未发芽两类,并未进行种子活力细化分级,分类相对粗糙;对出芽整齐性的评估也主要是通过评价者主观评价,没有统一的标准。种子发芽试验法是一种有损检测方法,且检测过程复杂。种子活力无损检测方法主要有X光、近红外光谱、高光谱、多光谱、可调谐半导体激光吸收光谱和色选技术等光学检测方法,检测对象为未催芽的种子,但这些技术目前基本上还处于实验室研究阶段,尚未形成可商用的种子活力光学检测装备。在育种和机械播种等实际工作中需要知道种子发芽后的发芽率和发芽势,对经过光学技术检测后的种子仍需进行催芽后的分级分选<sup>[4]</sup>。随着杂交稻育种技术和机械化育秧技术的快速发展,对大规模种子活力的精细判别提出了新的要求,例如,杂交稻机械化精量播种中,要求每穴播1~2粒芽种且芽长不超过3 mm,因此,迫切需要对发芽后的水稻种子活力进行多级别精细化检测,加强对种子质量和幼苗强壮程度的预判,以适应育种和机械化育秧技术发展的需求。


传统的图像处理方法和机器视觉技术结合不同硬件实现了特定任务的检测及分级<sup>[5-6]</sup>。将深度学习算法与现有的光学成像和检测技术结合,已成为探索种子活力检测的重要途径。基于近红外光谱图像和光谱信息, Yang等<sup>[7]</sup>结合迁移学习构建深度学习模型,对水稻种子活力进行评估,最高识别准确率达99.50%; Ma等<sup>[8]</sup>采用卷积神经网络深度学习方法对日本芥菜种子活力检测的准确率达90%左右; Nie等<sup>[9]</sup>利用深度卷积神经网络对杂交秋葵种

子和丝瓜种子的品种进行鉴别,分类准确率大于95%。基于高光谱和卷积神经网络, Pang等<sup>[10]</sup>对玉米种子活力进行检测,模型的识别准确率可达99.96%。目前,图像分级检测存在各具特色的目标检测网络,如Faster RCNN、YOLO系列和SSD-MobileNet等,其中,YOLO系列的卷积神经网络具有检测准确率高、模型占用内存小和模型易于移植手机端等特点,已成功应用于各种目标检测和分级研究。例如,张秀花等<sup>[11]</sup>提出了一种基于改进的YOLOv3-Tiny番茄穴盘苗分级检测方法,为番茄穴盘苗的自动化检测和分选提供参考。王立舒等<sup>[12]</sup>对YOLOv4-Tiny网络结构进行改进,提出一种含有注意力模块的目标检测网络,实现自然环境下蓝莓果实成熟度的精确快速识别,为蓝莓采摘机器人和早期产量预估提供快速精准的目标识别。宋怀波等<sup>[13]</sup>设计了一种YOLOv5-MD轻量型网络用于重度粘连的小麦籽粒检测,可为小麦籽粒检测嵌入式设备研发提供必要的技术支持。骆润玫等<sup>[14]</sup>提出一种基于YOLOv5-C的复杂背景下广佛手病虫害的识别方法,能快速准确地识别目标。殷献博等<sup>[15]</sup>提出一种基于多注意力机制改进的YOLOX-Nano智能识别模型,实现了柑橘梢期长势的智能识别,为果园实时感知和智能监测提供了可行的数据和技术方案。YOLO算法在目标检测中表现出旺盛的生命力,其算法也在不断完善<sup>[16]</sup>。Yang等<sup>[7]</sup>基于近红外光谱图像和深度学习模型对水稻种子活力进行检测,获得较好的识别准确率,但相对于可见光成像的RGB图像,其图像获取更复杂、成本也更高;此外,YOLOv5应用于杂交稻芽种分级检测中,虽然检测速度相对较快,但检测精度相对较低,速度仍可提升。为提高杂交稻芽种快速分级检测的精度和速度,基于可见光成像,本文提出了一种基于YOLOv5改进模型的杂交稻芽种快速分级检测方法,以为水稻育种和机械化育秧技术装备研发提供智能化技术支持。

## 1 图像采集与数据集制作

杂交稻芽种图像数据于2022年3月中旬在华南农业大学工程学院北楼105实验室采集,杂交稻

品种为‘五优 1179’。种子催芽成功后,芽长变化是一个连续的过程。为了对发芽后的种子活力进行分级,本文根据机械化播种对芽长的要求将芽种分为 4 级(图 1):未发芽、破胸露白、发芽(芽长小于 3 mm)和长芽(芽长大于 3 mm),破胸露白和发芽的种子适合机械化精量播种育秧,未发芽和长芽种子不适合机械化播种育秧。考虑到不同等级的图像采集数量多、时间长,种子催芽成功后,为了控制种子生长速度,采用低温调控,以确保获取足够多的样本。试验期间,使用分辨率为 8 168×4 592 像素的安东星工业相机采集水稻芽种图像,相机安装在高度可调的台架上,为减少光线变化对成像的影响,台架上配备了补光设备;考虑到人工识别水稻种子发芽及芽长等级是逐粒进行的,为简化模型的复杂度,将芽种尽可能不重叠地平放在试验台架上;获



a: 未发芽种子; b: 破胸露白种子; c: 发芽种子; d: 长芽种子

a: Ungerminated seed; b: Pre-germinated seed; c: Germinated seed; d: Long bud seed

图 1 杂交稻芽种分级

Fig. 1 Classification of hybrid rice bud seeds

取的图像保存为.jpg 格式。共获得杂交稻芽种图像 3 700 幅[包含单粒、多粒(2~7 粒)及混合],其中,未发芽、破胸、发芽和长芽图像分别为 900、980、1 180 和 640 幅。为增加图像信息和扩充数据集,对采集到的图片进行数据增强,同时使用平移、旋转、添加噪声、剪裁和 HSV 色域转换方法生成包含 5 550 幅图像的数据集,数据集划分如表 1 所示。

表 1 杂交稻芽种图像数据集的样本数量

Table 1 The number of data set samples of hybrid rice bud seeds

数据集 Data set	未发芽种子		破胸露白种子		发芽种子		长芽种子		混合芽种 Mixed bud seed	合计 Total
	Ungerminated seed		Pre-germinated seed		Germinated seed		Long bud seed			
	多粒	单粒	多粒	单粒	多粒	单粒	多粒	单粒		
	Multiple seeds	Single seed	Multiple seeds	Single seed	Multiple seeds	Single seed	Multiple seeds	Single seed		
训练集 Training set	400	480	546	530	679	637	423	345	400	4440
验证集 Validation set	60	75	66	81	87	60	53	43	30	555
测试集 Test set	60	75	66	81	87	60	53	43	30	555

## 2 改进的 YOLOv5 目标分级检测模型

### 2.1 YOLOv5 网络

深度学习目标检测网络中,常见的算法主要有 Faster-Rcnn<sup>[17]</sup>、R-CNN<sup>[17]</sup>、SPPNet<sup>[18]</sup>、YOLO<sup>[19]</sup> 和 SSD<sup>[20]</sup> 等。YOLOv5 是 YOLO 系列的第 5 代算法,其中,YOLOv5s 的权重值最小、检测网络深度小且检测速度快,但该方法对深层图像特征的提取能力相对较低,在杂交稻芽种分级检测中易出现漏检和分类错误,不能满足杂交稻芽种分级检测精度要求。本文通过引入 SE(Squeeze-and-excitation) 注意力机制,同时将 GIoU(Generalized intersection over union) 损失函数改进为 CIoU(Complete intersection over union) 损失函数,对 YOLOv5s 进行改进和增强,提高了目标检测的特征提取和特征融合能力以及收敛速度。

### 2.2 YOLOv5 目标分级检测模型改进

2.2.1 引入 SE 注意力机制 注意力机制模仿了人类大脑的视觉注意力机制,通过浏览全局图像对输入信息进行注意力分配,确定重点关注区域,从而快速获取关键信息<sup>[21]</sup>。SE 注意力机制是一种通道注意力机制<sup>[22]</sup>,可以嵌入到 YOLOv5s 模型中,引进 SE 注意力机制不会改变原有通道信息提取能力,但能够对无用的背景信息进行过滤,并重点关注特殊内容和特殊位置的信息,从而有效地提高特征信息提取能力,进一步提高检测的准确率。在杂交稻芽种分级检测中,稻种发芽部位位于头部的一侧,其位置具有特殊性。本研究在 YOLOv5s 颈部结构中添加 SE 注意力机制以增强特征通道间的关注度,拟合目标通道相关特征信息并抑制无效信息,提高网络模型对水稻芽种发芽部位的关注度,减少背景干扰,有效地提升了模型检测精度。



首先, SE 模块对输入特征图  $X$  做全局平均池化, 生成长为  $H$ 、宽为  $W$ 、通道为  $C$  的通道特征图像, 然后对通道特征图像的长、宽求和再取平均值生成空间注意力特征。挤压 (Squeeze,  $F_{sq}$ ) 操作算法如下:

$$Z = F_{sq} = \sum_{i=1}^H \sum_{j=1}^W u(i, j) / (H \times W), \quad (1)$$

式中,  $Z$  表示通道特征图的平均特征值,  $u(i, j)$  表示特征图上的单个特征值。

然后, 激励 (Excitation,  $F_{ex}$ ) 操作将  $H \times W \times C$  的特征图压缩为  $1 \times 1 \times C$  特征图, 在  $F_{ex}$  操作中使用 2 层全连接自适应学习生成权重 ( $S$ ), 算法如下:

$$S = F_{ex} = \sigma[w_2 \times \delta(w_1 \times Z)], \quad (2)$$

式中,  $w_1$ 、 $w_2$  分别为 2 个全连接层的权重值,  $\delta$  为连接层使用的 Relu 激活函数,  $\sigma$  表示 Sigmoid 函数。

Sigmoid 函数归一化操作构建各个注意力特征通道之间的关系, 把每个通道的数值限制在 0~1 之间, 抑制无用特征通道信息, 激活重点关注区域特征通道。图 2 为 SE 注意力模块的结构示意图。




图 2 SE 注意力机制模块结构示意图

Fig. 2 The schematic diagram of SE attention mechanism module

2.2.2 改进损失函数 目标检测算法的损失函数一般由位置回归损失和分类损失组成。通常, 位置回归损失的评价指标为交并比 (Intersection over Union, IoU), 该指标用于衡量 2 个形状之间的相似性。IoU 的计算方法如下:

$$IoU = \frac{|A \cap B|}{|A \cup B|}, \quad (3)$$

式中,  $A$  表示真实框,  $B$  表示预测框,  $A \cap B$  表示预测框和真实框的重叠区域,  $A \cup B$  表示预测框和真实框的并集。

当预测框和真实框没有重叠区域时, IoU 损失函数不仅无法衡量两边界框之间的距离, 也无法进行梯度计算<sup>[11]</sup>。YOLOv5s 模型中则采用 GIoU 损失函数<sup>[23]</sup> 作为位置回归损失的评价指标。GIoU 损失函数是 IoU 的推广, 计算公式如下:

$$GIoU = IoU - \frac{|C - (A \cap B)|}{|C|}, \quad (4)$$

式中,  $C$  表示包含  $A$  和  $B$  的最小凸集。

虽然 GIoU 损失函数能解决两框不相交时的问题, 但采用 GIoU 损失函数检测水稻芽种时, 存在无法确认效果最佳的预测框情形。如图 3 所示, 图中 3 种情况为预测框都在真实框里面, 但预测框位置不同。此时, 虽然计算得到的 GIoU 损失函数值是相同的, 但无法确定哪个预测框是最佳预测框。为解决该问题, 本研究引入 CIoU 损失函数<sup>[24]</sup> 替代原 GIoU 损失函数, 优化两个框中心点之间距离, 有效提高预测框的回归效果。图 4 为 IoU 和 CIoU 的示意图, 实线框为真实框, 虚线框为预测框。CIoU 损失函数计算公式如下:

$$CIoU = 1 - IoU + \frac{\rho^2(A, B)}{c^2} + \alpha v, \quad (5)$$

式中,  $\alpha$  表示权衡参数, 通过对  $\alpha$  值调制, 更容易用于改进检测器的效果;  $\rho^2(A, B)$  表示两框中心点间距离;  $v$  表示长宽比一致性,  $c$  表示预测框和目标框的最小矩形框的对角线距离。


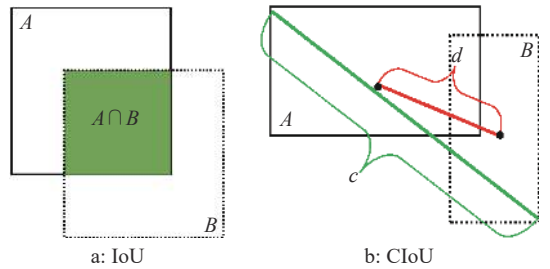


图 3 GIoU 损失函数值一致的不同情况

Fig. 3 Different cases of consistent GIoU loss function values



a: IoU b: CIoU

$A$ : 真实框;  $B$ : 预测框;  $c$ :  $A$  和  $B$  最小矩形框的对角线距离;  $d$ :  $A$  和  $B$  中心点的距离

$A$ : True frame;  $B$ : Prediction frame;  $c$ : Diagonal distance between the minimum rectangular frames of  $A$  and  $B$ ;  $d$ : Distance between the center points of  $A$  and  $B$

图 4 IoU 和 CIoU 示意图

Fig. 4 The schematic diagrams of IoU and CIoU

2.2.3 YOLOv5-1 目标分级检测算法 YOLOv5s 改进后的检测网络命名为“YOLOv5-I”, 其网络结构如图 5a 所示。主要包括 Input 端、Backbone 网络端、Neck 端和 Prediction 端 4 个部分。

1) Input 端: 包括图片输入、自适应锚框和马赛克数据增强。首先, 对图像进行预处理, 即将输入图像缩放至像素为  $608 \times 608$  的图像, 然后进行灰度

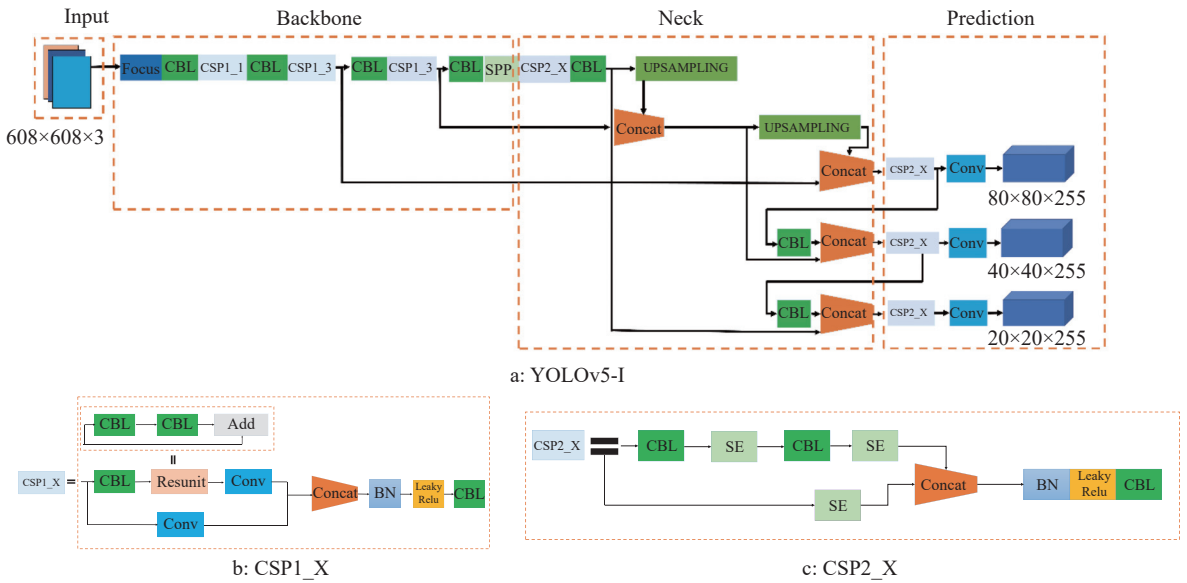


图 5 YOLOv5-I 网络结构以及 CSP1\_X 和 CSP2\_X 模块

Fig. 5 YOLOv5-I network structure, and CSP1\_X and CSP2\_X modules

处理。为提高检测速度,在自适应锚框训练前对数据进行标注;为提高目标检测精度,在网络训练过程中进行马赛克数据增强。

2) Backbone 网络端:包括 CSP1\_X 模块和 Focus 模块。CSP1\_X 模块的作用是对 2 个分支结构分别进行卷积操作生成 Concat 模块,经 BN (Batch normalization) 操作和 Leaky Relu 激活函数归一化处理最终生成 CBL 模块,如图 5b 所示。CBL 模块输出的特征图大小与 CSP1\_X 模块相同,保证了图像的完整性。Focus 模块的作用是对特征图进行切片操作,目的是在无特征参数下将输入维度进行下采样操作,大幅缩减对图片提取特征梯度的计算量,从而加快训练速度。


3) Neck 端:使用 FPN (Feature pyramid network) 和 PAN (Path aggregation network) 结构实现信息高维度和信息低维度的融合。FPN 采用自上向下的特征金字塔方式,将上采样信息融合成新的特征信息得到预测的特征图。PAN 采用自下而上的特征金字塔方式,对杂交稻芽种特征进行局部特征和全局特征的融合。CSP2\_X 对卷积层数量进行调整,如图 5c 所示。

4) Prediction 端:给出模型的预测结果和推断结果,该网络应用锚框 (Anchor box) 输出检测目标特征图的类别概率、包围框位置和目标得分。YOLOv5-I 网络预测端由 3 个检测层组成,输出  $80 \times 80 \times 255$ 、 $40 \times 40 \times 255$  和  $20 \times 20 \times 255$  的特征图,每个检测层最终输出 4 种不同芽种类别、1 种判断类别得分和 1 个包围框位置坐标,实现目标对象的检测。

## 3 模型训练与结果

### 3.1 模型训练

3.1.1 训练参数 硬件环境:主板是微星 B450M MORTAR MAX, CPU 为 AMD Ryzen 5 5600X, GPU 为 10 GB 显存的 GeForce RTX 3 080, 配置 CUDA toolkit 11.1 和 Cudnn 8.05 版本深度学习神经网络加速库, DDR4 3200MHZ 内存条;软件环境:在 Ubuntu 20.04 系统下,基于 Pytorch 1.10.0 构建总体框架,采用 Python 3.8 进行编程,使用 Pycharm 进行编译。按 Pascal Voc 数据的格式,使用标注工具 LabelImg 软件对杂交稻芽种图像进行标注,生成 .xml 格式文件,图 6 显示了标注过程。



图中,“px”表示破胸露白种子,“fy”表示发芽种子,“cy”表示长芽种子,“wfy”表示未发芽种子

In the figure, “px” means pre-germinated seed, “fy” means germinated seed, “cy” means long bud seed, “wfy” means ungerminated seed

图 6 杂交稻芽种图像标注

Fig. 6 Image annotation of hybrid rice bud seeds

3.1.2 评价指标 采用准确度 (Precision,  $P/\%$ )、召回率 (Recall,  $R/\%$ )、AP (Average precision,  $AP/\%$ ) 和 mAP (Mean average precision,  $mAP/\%$ ) 4 个指标对模型进行性能评估。计算公式如下:

$$P = \frac{TP}{TP + FP} \times 100\%, \quad (6)$$

$$R = \frac{TP}{TP+FN} \times 100\%, \quad (7)$$

$$AP = \int_0^1 P(R) dR \times 100\%, \quad (8)$$

$$mAP = \frac{1}{M} \sum_{k=1}^M AP(k) \times 100\%, \quad (9)$$

式中, TP 和 FP 分别表示真实的正样本和虚假的正样本, FN 为虚假的负样本,  $M$  为检测目标的类别总数,  $AP(k)$  为第  $k$  类 AP 值。

### 3.2 网络改进前后的检测结果比较

训练前, 网络输入图像像素为  $608 \times 608$ , 批量设置为 36, 动量设置为 0.937, 初始学习率为 0.0001, 权值衰减设置为 0.0005。模型迭代次数为 300 次, 训练过程中使用随机梯度下降法优化学习率, 训练过程如图 7 所示。由图 7 可知, YOLOv5-I 损失曲线始终位于 YOLOv5s 损失曲线下方, 表明 YOLOv5-I 模型的拟合效果优于 YOLOv5s 模型; 对 YOLOv5s 损失曲线而言, 当训练次数超过 100 次后, 在第 140 次和 240 次左右出现明显的 2 次断崖式衰减, 表明模型的稳定性欠佳; 对 YOLOv5-I 损失曲线而言, 当训练次数达到 50 次左右时, 损失曲线开始趋于收敛, 曲线也非常光滑, 表明模型的稳定性较好。说明基于 CIoU 损失函数的 YOLOv5-I 模型比基于 GIoU 损失函数的 YOLOv5s 模型具有更快的收敛速度和更好的稳定性。

图 8 给出了不同情形 (未发芽、破胸露白、发

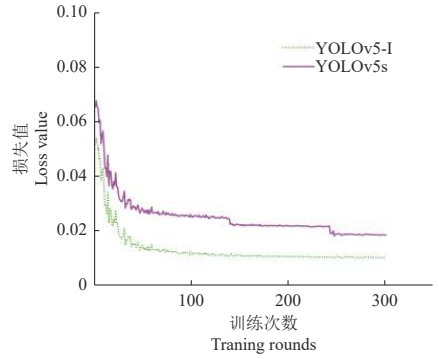


图 7 YOLOv5-I 和 YOLOv5s 模型训练损失曲线  
Fig. 7 Training loss curves of YOLOv5-I and YOLOv5s models

芽、长芽和混合芽种) 下 YOLOv5s 和 YOLOv5-I 目标检测模型的测试结果。由图 8 可见, 检测未发芽种子时, YOLOv5s 出现漏检情况, YOLOv5-I 均能检测出未发芽种子; 对于破胸芽种的检测情况, YOLOv5s 算法检测时出现分级错误, 即检测出 1 粒破胸芽种时出现 2 个预测框, 分别为“破胸”和“未发芽”, 而 YOLOv5-I 能够准确识别破胸芽种; 检测发芽种子时, YOLOv5s 准确检测出图片上所有芽种, 但平均置信度为 54.25%, 远远低于 YOLOv5-I 检测发芽种子的平均置信度 95.50%; 对于长芽芽种情况, YOLOv5s 出现漏检且分级错误, 而 YOLOv5-I 准确检测芽种状况并成功分类; 对于混合芽种检测情况, YOLOv5s 虽然平均置信度达到 92%, 但发生漏检现象, 而 YOLOv5-I 均能准确分级。综上所述, YOLOv5-I 检测效果优于 YOLOv5s。

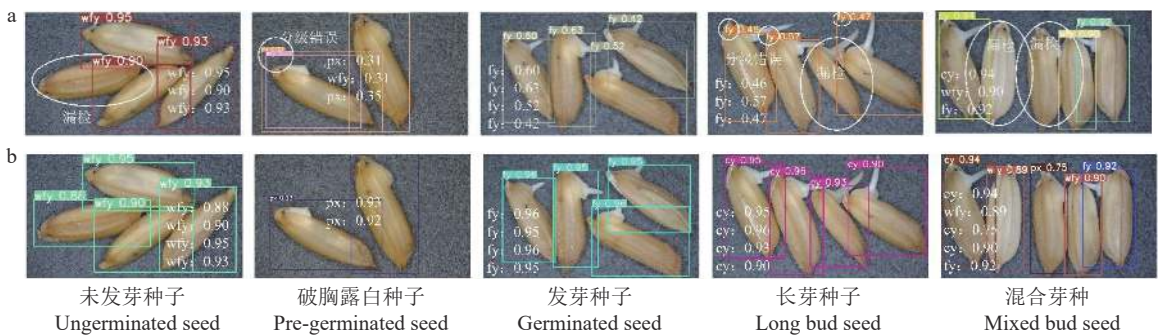


图 8 YOLOv5-I(a) 和 YOLOv5s(b) 模型的检测结果对比

Fig. 8 Detection effect comparison between YOLOv5-I (a) and YOLOv5s (b) models

YOLOv5-I 和 YOLOv5s 模型检测结果的  $P-R$  曲线如图 9 所示, 曲线与纵横坐标所形成的区域面积表示该模型检测的准确度。由图 9 可知, 对未发芽、破胸露白、发芽和长芽的芽种检测, YOLOv5-I 的  $P-R$  曲线均在 YOLOv5s 的外侧, 且曲线更靠近坐标点 (1,1), 表明 YOLOv5-I 检测的准确度高于 YOLOv5s, 性能更优。

### 3.3 YOLOv5-I 模型与其他算法检测结果比较

使用相同的数据集, 采用其他 4 种算法 YOLOv5s、Faster-RCNN、SSD 和 YOLOv4 进行训练, 得到最佳权重之后, 在同样的测试集上进行测试, 对 5 种目标检测网络在重合度阈值为 0.5 时进行 mAP、准确率、召回率和检测时间的计算, 结果如表 2 所示。由表 2 可知, 整体上, YOLOv5-I 目标






图 9 YOLOv5-I 和 YOLOv5s 模型对 4 种芽种检测结果的 P-R 曲线

Fig. 9 The P-R curves of detection effects of YOLOv5-I and YOLOv5s models for four types of bud seeds

表 2 不同目标检测网络对 4 种芽种的检测结果

Table 2 Detection results of different object detection networks for four types of bud seeds

种芽状况 Status of bud seeds	检测网络 Detection networks	平均精度(mAP)/%			准确率(P)/%	召回率(R)/%	检测时间/ms
		Mean average precision					
		单粒 Single seed	多粒 Multiple seeds	平均值 Mean			
未发芽 Ungerminated	YOLOv5-I	99.54	98.12	98.83	98.63	98.91	3.21
	YOLOv5s	97.21	97.87	97.54	98.56	98.87	5.56
	Faster-RCNN	96.52	94.85	95.68	97.56	96.45	23.54
	SSD	95.47	93.25	94.36	94.21	96.42	6.52
	YOLOv4	94.87	92.47	93.36	98.21	97.13	25.24
破胸露白 Pre-germinated	YOLOv5-I	98.17	96.85	97.51	97.72	98.46	3.63
	YOLOv5s	96.58	96.41	96.50	96.21	95.43	4.25
	Faster-RCNN	95.14	94.21	94.68	94.28	95.17	23.73
	SSD	95.42	92.21	93.82	89.57	88.52	4.36
	YOLOv4	94.82	91.57	93.20	93.24	95.72	24.83
发芽 Germinated	YOLOv5-I	98.28	94.22	96.25	98.16	97.54	4.58
	YOLOv5s	96.41	95.47	95.94	93.51	93.42	5.68
	Faster-RCNN	95.24	92.17	93.71	94.56	96.41	25.83
	SSD	94.85	93.57	94.21	85.72	86.36	7.98
	YOLOv4	93.47	92.28	92.88	92.53	94.26	26.83
长芽 Long bud	YOLOv5-I	97.57	97.39	97.48	96.89	98.16	3.56
	YOLOv5s	95.43	95.28	95.40	95.24	97.41	5.14
	Faster-RCNN	92.91	94.29	93.60	95.74	96.52	23.47
	SSD	89.56	93.82	91.69	90.52	89.71	5.75
	YOLOv4	90.51	93.82	92.17	93.58	94.28	24.84

检测网络在 mAP、准确率、召回率和检测速度上均优于其他目标检测算法。YOLOv5-I、YOLOv5s、Faster-RCNN、SSD 和 YOLOv4 算法的 mAP 依次为 97.52%、96.36%、94.42%、93.52% 和 92.90%，P 依次为 97.85%、95.88%、95.54%、90.01% 和 94.39%，R 依次为 98.27%、96.28%、96.14%、90.25% 和 95.35%，平均检测时间依次为 3.745、5.158、24.143、6.153 和 25.435 ms。YOLOv5-I 算法

的 mAP 分别比 YOLOv5s、Faster-RCNN、SSD 和 YOLOv4 算法高 1.16、3.10、4.00 和 4.62 个百分点；YOLOv5-I 算法的平均检测时间分别比 YOLOv5s、Faster-RCNN、SSD 和 YOLOv4 算法少 1.413、20.398、2.408 和 21.690 ms。此外，YOLOv5-I 模型占用内存空间为 13.7MB，相对较少，比 YOLOv5s 少了 1.9 MB。可见，YOLOv5-I 算法优于现有的算法，实现了检测精度和速度的提升，

相关性能能够满足杂交稻芽种分级检测的实用要求。

## 4 结论

基于YOLOv5s模型,通过引入SE注意力机制和优化损伤函数,提出了一种杂交稻芽种快速分级检测模型YOLOv5-I,实现了杂交稻芽种快速分级检测。采用YOLOv5-I模型检测杂交稻芽种分级时,平均精度为97.52%,平均准确率为97.85%,平均召回率为98.27%,平均检测时间为3.745 ms,能够满足杂交稻芽种快速分级检测的实用要求。与YOLOv5s、Faster-RCNN、SSD和YOLOv4算法比较,YOLOv5-I算法无论是精度还是速度都有明显提升,平均精度分别比YOLOv5s、Faster-RCNN、SSD和YOLOv4算法高1.16、3.10、4.00和4.62个百分点,平均检测时间分别比YOLOv5s、Faster-RCNN、SSD和YOLOv4算法少1.413、20.398、2.408和21.690 ms。

### 参考文献:

- [1] 李振华, 王建华. 种子活力与萌发的生理与分子机制研究进展[J]. 中国农业科学, 2015, 48(4): 646-660.
- [2] 李泽华, 马旭, 李秀昊, 等. 水稻栽植机械化技术研究进展[J]. 农业机械学报, 2018, 49(5): 1-20.
- [3] 李文彬, 于秀琪, 刘春宇, 等. 农作物种子活力检测方法研究进展[J]. 农业灾害研究, 2021, 11(6): 7-10.
- [4] 袁俊, 郑雯, 祁亨年, 等. 种子活力光学无损检测技术研究进展[J]. 作物杂志, 2020(5): 9-16.
- [5] 孙俊, 张林, 周鑫, 等. 采用高光谱图像深度特征检测水稻种子活力等级[J]. 农业工程学报, 2021, 37(14): 171-178.
- [6] PANG L, WANG L, YUAN P, et al. Feasibility study on identifying seed viability of *Sophora japonica* with optimized deep neural network and hyperspectral imaging[J]. Computers and Electronics in Agriculture, 2021, 190(106426): 1-12.
- [7] YANG Y, CHEN J, HE Y, et al. Assessment of the vigor of rice seeds by near-infrared hyperspectral imaging combined with transfer learning[J]. The Royal Society of Chemistry, 2020, 72(10): 44149-44158.
- [8] MA T, TSUCHIKAWA S, INAGAKI T. Rapid and non-destructive seed viability prediction using near-infrared hyperspectral imaging coupled with a deep learning approach[J]. Computers and Electronics in Agriculture, 2020, 177(105683): 1-9.
- [9] NIE P, ZHANG J, FENG X, et al. Classification of hybrid seeds using near-infrared hyperspectral imaging technology combined with deep learning[J]. Sensors and Actuators: B: Chemical, 2019, 296(126630): 1-12.
- [10] PANG L, MEN S, YAN L, et al. Rapid vitality estimation and prediction of corn seeds based on spectra and images using deep learning and hyperspectral imaging techniques[J]. IEEE Access, 2020, 8(123026): 1-11.
- [11] 张秀花, 静茂凯, 袁永伟, 等. 基于改进YOLOv3-Tiny的番茄苗分级检测[J]. 农业工程学报, 2022, 38(1): 221-229.
- [12] 王立舒, 秦铭霞, 雷洁雅, 等. 基于改进YOLOv4-Tiny的蓝莓成熟度识别方法[J]. 农业工程学报, 2021, 37(18): 170-178.
- [13] 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.
- [14] 骆润玫, 殷惠莉, 刘伟康, 等. 基于YOLOv5-C的复杂背景广佛手病虫害识别[J]. 华南农业大学学报, 2023, 44(1): 151-160.
- [15] 殷献博, 邓小玲, 兰玉彬, 等. 基于改进YOLOX-Nano算法的柑橘梢期长势智能识别[J]. 华南农业大学学报, 2023, 44(1): 142-150.
- [16] 邵延华, 张铎, 楚红雨, 等. 基于深度学习的YOLO目标检测综述[J]. 电子与信息学报, 2022, 44(10): 3697-3708.
- [17] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [18] PURKAIT P, ZHAO C, ZACH C. SPP-Net: Deep absolute pose regression with synthetic views[EB/OL]. arXiv: 1712.03452. (2017-12-09)[2022-05-12]. <https://arxiv.org/abs/1712.03452>.
- [19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [EB/OL]. arXiv: 2004.10934. (2020-04-23)[2022-05-21]. <https://arxiv.org/abs/2004.10934>.
- [20] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]//LEIBE B, MATAS J, SEBE N, et al. Computer vision-ECCV 2016. Cham: Springer, 2016: 21-37.
- [21] 陈东培. 基于图神经网络和注意力机制的会话推荐算法研究[D]. 广州: 华南理工大学, 2021.
- [22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [23] REZATOFI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]// IEEE. 2019 IEEE/CVF conference on computer vision and pattern recognition (CVPR). CA: IEEE, 2019: 658-666.
- [24] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]// EAAI. Proceedings of the 34<sup>th</sup> AAAI Conference on Artificial Intelligence. NY: EAAI, 2020: 12993-13000.