

文章编号:1007-2780(XXXX)XX-0001-13

基于白光成像与YOLOv8模型融合的玉米种子 品种高精度无损识别方法研究

耿利杰¹, 侯灵奇¹, 付振祥¹, 毕成龙¹, 朱华杰¹,

刘炫邑¹, 侯兴松⁴, 杨坤^{1,2*}, 李晋^{3*}

1. 郑州轻工业大学 电子信息学院 河南省光电传感与信息处理工程技术研究中心,
河南 郑州 450000;
2. 中原工学院 物理与光电工程学院, 河南 郑州 450007;
3. 西北农林科技大学 机械与电子工程学院, 中国 杨凌 712100;
4. 河南九圣禾新科种业有限公司, 河南 新乡 453000)

摘要:种子纯度是决定农民收成与收入的关键因素,而快速精准的品种识别技术则是保障纯度的核心。本研究提出基于LED白光成像与YOLOv8模型融合的玉米种子无损检测方法,实验验证该方法兼具快速、高效、高精度和无损等优势。通过搭建优化的LED白光反射成像系统,完成了4个玉米品种共12 008粒种子的图像采集与标注。对比实验显示,YOLOv8m模型的各项核心指标显著优于轻量级YOLOv8s,有效解决了形态相似品种识别精度不足的难题。该模型对4个品种的识别平均精度(AP)、召回率(AR)和F1分数均达99.8%,平均mAP@0.5值高达99.4%。实时性测试中,YOLOv8m单图处理耗时68.6毫秒,满足种子分选系统的低延迟需求。研究还揭示了数据集规模对模型性能的影响规律,证实YOLOv8m在不同规模数据集上均保持卓越的稳定性。这项研究为种子品种识别领域提供了一种精确又实用的技术方案。

关键词:玉米种子;品种识别;深度学习;YOLOv8

中图分类号:TP394.41 文献标识码:A doi:10.37188/CJLCD.2026-0072 CSTR:32172.14.CJLCD.2026-0072

收稿日期:2026-04-27;修订日期:2026-05-25.

基金项目:河南省重点研发计划项目(No.241111212600);河南省高校青年骨干教师培养计划(No.2023GGJS088);河南省科技攻关项目(No.242102210157;No.252102210188);陕西省秦创原创新创业人才项目(No.QCYRCXM-2023-111)

Supported by the Key Research and Development Projects of Henan Province (No.241111212600); Training Plan of Young Backbone Teachers in Universities of Henan Province (No.2023GGJS088); Henan Provincial Science and Technology Research Project (No.242102210157, and 252102210188); Shaanxi Provincial Qinchuangyuan Innovation and Entrepreneurship Talent Project (No.QCYRCXM-2023-111)

*通信联系人, E-mail: yangkun@zzuli.edu.cn; lijin2023@nwafu.edu.cn

Research on a high-precision non-destructive identification method for corn seed varieties based on the fusion of white light imaging and YOLOv8 model

GENG Lijie¹, HOU Lingqi¹, FU Zhenxiang¹, BI Chenglong¹, ZHU Huajie¹,
LIU Xuanyi¹, HOU Xingsong⁴, YANG Kun^{1,2*}, LI Jin^{3*}

- (1. School of Electronic and Information, Henan Province Optoelectronic Sensing and Information Processing Engineering Technology Research Center, Zhengzhou University of Light Industry, 450000 Zhengzhou, China;
2. School of Physics and Optoelectronic Engineering, Zhongyuan University of Technology, 450007 Zhengzhou, China;
3. College of Mechanical and Electronic Engineering, Northwest A&F University, 712100 Yangling, China;
4. Henan Jiushenghe Rinke Seed Industry Co., Ltd. 453000 Xinxiang, China)

Abstract: Seed purity is a critical factor determining farmers' harvests and income, and rapid, accurate variety identification technology is the core to ensuring purity. This study proposes a non-destructive detection method for maize seeds based on the fusion of LED white light imaging and the YOLOv8 model. Experiments confirm that this method combines the advantages of speed, efficiency, high accuracy, and non-destructiveness. By constructing an optimized LED white light reflection imaging system, we completed image acquisition and annotation for a total of 12,008 seeds from four maize varieties. Comparative experiments show that the YOLOv8m model significantly outperforms the lightweight YOLOv8s in various core metrics, effectively addressing the issue of insufficient identification accuracy for morphologically similar varieties. The model achieved an average precision (AP), recall rate (AR), and F1 score of 99.8% for the four varieties, with an average mAP@0.5 value as high as 99.4%. In real-time performance tests, the YOLOv8m model took 68.6 milliseconds to process a single image, fully meeting the low-latency requirements of seed sorting systems. The research also reveals the impact pattern of dataset scale on model performance, confirming that YOLOv8m maintains excellent stability across datasets of different scales. This study provides a precise and practical technical solution for the field of seed variety identification.

Key words: maize seeds; variety Identification; deep learning; YOLOv8

1 引 言

玉米作为全球重要粮食作物,在粮食安全和工业发展中占据关键地位^[1]。随着农业产业化发展,其用途已从传统主粮消费扩展到饲料加工、生物能源、淀粉材料等多个领域。为适应不同种植条件和加工需求,育种专家培育出各具特色的玉米品种。然而,这些品种在种子外观(如形状、

颜色)上极为相似,给种子质量控制带来诸多难题:生产环节可能因机械混杂影响纯度;储运过程管理不当易导致品种混淆;更有不法商家以劣质种子冒充优质品种牟利^[2]。这些乱象不仅损害农民利益,更扰乱种业市场秩序^[3]。因此,开发高效准确的品种鉴定技术势在必行。

传统种子纯度检测技术主要包括形态学鉴定、田间种植鉴定、化学鉴定和电泳技术等方

法^[4-6]。前两种方法的操作直观,但存在检测周期长、准确率有限且高度依赖专业经验等不足^[7]。后两种方法虽能提升检测准确率,却需要破坏样本并接触化学试剂,既影响种子后续使用又可能造成环境污染^[8]。在此背景下,高光谱成像技术因其将光谱和图像信息结合的特性脱颖而出,该技术能在数秒内无损获取单粒种子的光谱特征,通过算法分析实现快速鉴别,平均准确率可达85%以上^[9]。最新研究显示^[10],通过融合400~1 000 nm光谱波段与图像纹理特征,配合最小二乘支持向量机(LS-SVM)分类器,玉米品种识别准确率已提升至88.89%。采用深度卷积神经网络(DCNN)聚焦胚乳区域光谱特征^[11],使4个玉米品种的分类准确率达到93.3%,较传统方法提升显著。高光谱成像技术已被证实可有效识别种子品种,但仍存在诸多局限性:与视觉技术相比,高光谱图像数据采集耗时更长,且高光谱数据维度较高,需进行复杂的特征降维处理。此外,高光谱设备价格昂贵,且对实验室环境有严格要求,这些因素一定程度上限制了该技术的推广应用。

计算机视觉与深度学习技术的快速发展为作物品种识别带来了新的发展^[12-13]。作为无损检测的核心技术,计算机视觉能高效获取并分析玉米种子的表型特征^[14]。卷积神经网络(CNN)凭借出色的特征提取能力,在图像分类任务中表现尤为突出^[15]。该技术已应用于玉米品种分类任务。Javanmardi团队^[16]开发的CNN-ANN混合模型对9个品种的分类准确率高达98.1%,处理2250个样本耗时26.8秒。Li等人^[17]改良的ResNet-50框架在6个品种分类中平均精度、召回率和F1值均约为91%。特别值得注意的是,Bi团队^[18]采用改进型Swin Transformer模型成功识别多个玉米品种,准确率达96.53%,证实了Transformer架构在农业图像识别的应用潜力。然而,当前基于视觉图像的深度学习方法仍面临两大挑战,一是处理速度难以满足现场实时检测需求,二是对形态相似品种的区分精度有待提高。这些技术瓶颈制约着该领域进一步发展和实际应用。

为解决上述问题,本研究将反射成像技术与


YOLOv8模型相结合,提出一种快速、无损、高效且高精度的检测方法,并开发了高效精准的玉米种子检测系统。通过搭建LED白光反射成像平台,在优化光学参数后,采集了4个品种共12 008粒玉米种子的189张高清图像。实验设置了五组不同规模的数据集,系统比较了YOLOv8s和YOLOv8m两种模型的性能差异。研究发现,虽然YOLOv8m模型的参数量和计算量略高于轻量级YOLOv8s模型,但其检测性能显著提升。YOLOv8m模型的核心指标表现优异:平均精度(AP)、召回率(AR)和F1分数均达到99.8%,mAP@0.5值高达99.4%。指标不仅优于YOLOv8s模型,也超越了同类检测方法的性能。在实时性方面,YOLOv8m单幅图像处理耗时68.6毫秒,YOLOv8s为63.7毫秒,两者均能满足种子分选系统的实时性要求。该方法成功解决了相似形态品种识别精度低的难题,实现了玉米种子的快速、无损、高精度检测,为现代农业检测技术发展提供了一种新的解决方案。

2 实验装置与方法

2.1 实验装置与图像采集


2.1.1 实验装置

本研究构建了一套高效可靠的玉米种子成像系统,用于获取高质量反射图像以支持品种精准分类。系统采用海康威视MV-CE100-30GC工业彩色面阵相机(3 840×2 748像素),通过GigE接口实现图像实时传输。相机经几何标定后垂直安装于样品台正上方,确保成像无畸变且清晰度满足表型检测要求。配合使用环形无影LED白光光源(7 000~8 000 K色温,24W功率),可提供均匀照明环境,有效避免光强不均对特征提取的干扰。实验使用的四个玉米品种种子由九圣禾种业股份有限公司提供,包括九圣禾257、郁青392、YD807和郁青358四个品种的玉米种子。四个品种玉米种子如图2所示,每个品种随机选取约3 000粒样本进行成像。该样本量设计基于深度学习网络的训练需求,确保模型能够充分学习品种特征。整个系统在保证成像质量的同时,兼顾了硬件成本与实用性的平衡,为后续的品种分类研究奠定了基础。



(a) 示意图

(a) Schematic diagram



(b) 实物图


(b) Physical diagram

图 1 玉米图像采集系统

Fig. 1 Maize seed image acquisition system

2.1.2 数据集标注与构建

采用自主搭建的玉米种子反射成像装置,对九圣禾 257、郁青 392、YD807 和郁青 358 四个品种共计 12 008 粒玉米种子进行了系统性的图像采集工作,最终获得 189 张高质量图像样本。在数据处理环节,采用 LabelImg 标注工具对图像中的不同品种种子进行精确标注,并建立了规范的命名体系:JSH257 对应九圣禾 257, YQ392 对应郁青 392, YD807 保持原名, YQ358 对应郁青




(a) 九圣禾 257

(b) 郁青 392

(a) JSH257

(b) YQ392



(c) YD807

(d) 郁青 358


(c) YD807

(d) YQ358

图 2 玉米种子样品图像


Fig. 2 Maize seed example images

358。基于此流程,成功构建了包含 12 008 个边界框标注的完整数据集。为确保模型训练的可靠性,数据集按照 7:2:1 的比例随机划分为训练集、验证集和测试集三个独立子集,具体划分如表 1 所列。数据集的标注可视化分布如图 3 所示,图 3(a)显示玉米种子边界框在单张图像中的空间分布均匀,无明显聚集现象。图 3(b)显示边界框尺寸分布比较集中,表明边界框的高度和宽度比较一致。



(a) 在图像中的位置分布

(a) Distribution of bounding



(b) 尺寸统计分布

(b) The statistical distribution

图 3 数据集标注的边界框可视化分布

Fig. 3 Visual distribution of annotated datasets box positions of the bounding box sizes

2.1.3 五组梯度缩减的数据集

为了研究数据集规模对YOLOv8s和YOLOv8m模型性能的影响,设计了多组对照实验。将原始数据集按10%的梯度递减,共设置了五组不同规模的数据子集。每组数据均按标准划分为训练集、验证集和测试集,具体划分方案详见表1至表5。

表1 4个玉米品种数据集的具体划分

Tab. 1 Division of the 4 maize variety datasets

类别	训练集	验证集	测试集	总计
JSH257	2 190	630	305	3 125
YQ392	2 183	608	311	3 102
YD807	2 043	610	271	2 924
YQ358	1 991	577	289	2 857

表2 第二组数据集的具体划分

Tab. 2 Specific division of the Group II

类别	训练集	验证集	测试集	总计
JSH257	2 002	588	305	2 895
YQ392	1 993	563	311	2 867
YD807	1 799	488	271	2 558
YQ358	1 823	514	289	2 626

表3 第三组数据集的具体划分

Tab. 3 Specific division of the Group III

类别	训练集	验证集	测试集	总计
JSH257	1 808	569	247	2 624
YQ392	1 836	521	248	2 605
YD807	1 670	488	271	2 429
YQ358	1 637	455	232	2 324

表4 第四组数据集的具体划分

Tab. 4 Specific division of the Group IV

类别	训练集	验证集	测试集	总计
JSH257	1 600	478	247	2 325
YQ392	1 652	475	248	2 375
YD807	1 401	488	235	2 124
YQ358	1 423	394	232	2 049

表5 第五组数据集的具体划分

Tab. 5 Specific division of the Group V

类别	训练集	验证集	测试集	总计
JSH257	1 483	436	247	2 175
YQ392	1 461	439	248	2 133
YD807	1 300	361	140	1 815
YQ358	1 324	394	174	1 896

2.2 YOLOv8模型介绍

YOLOv8是Ultralytics公司推出的目标检测框架,在检测效率、准确率和易用性方面均达到行业领先水平。作为YOLO系列的迭代版本,它延续了经典的You Only Look Once"单阶段检测理念,仅需单次前向传播就能完成多目标检测,相比Faster R-CNN等两阶段方法具有明显的速度优势。该模型在YOLOv5架构基础上进行了全面升级,最突出的创新是无锚框检测机制,这一改进大幅提升了非极大值抑制的处理效率。其网络结构采用模块化设计,包含特征提取主干网络(Backbone)、多尺度特征融合颈部网络(Neck)和检测头(Head)三个核心组件,整体架构简洁高效(如图4)。这些优化使YOLOv8成为当前目标检测领域综合性能优异的模型方案。该模型作为官方持续维护的成熟模型,具备代码稳定、验证充分的特点,确保了实验可复现性和工程可靠性。该模型在检测精度与推理速度间取得出色平衡,完美契合项目计算需求。其庞大的全球开发者社区可提供及时技术支持,完善的部署工具链则大幅简化实验流程,为后续工业化应用奠定基础。基于这些优势与生态支持,我们选择YOLOv8作为核心目标检测模型。

2.2.1 主干网络

作为模型的特征提取中枢,YOLOv8的主干网络采用跨阶段部分连接(CSP)的优化设计,其核心由C2f模块与快速空间金字塔池化(SPPF)模块组合。C2f模块通过高效的特征融合与跨阶段连接,既能增强特征表达能力,又能降低计算复杂度。而SPPF模块通过并行最大池化操作,可快速提取不同尺度的特征,提升模型对不同尺寸目标的感知能力。总体而言,YOLOv8主干网络结构紧凑高效,能在短时间内生成高质量特征图,为后续检测任务提供坚实基础。

2.2.2 颈部网络

YOLOv8的颈部结构采用轻量化特征金字塔网络与双向特征融合设计,通过跨阶段特征传递和多尺度融合优化,增强目标检测性能。其核心模块包含跨阶段部分连接结构,在减少计算冗余的同时引入通道注意力机制,有效提升关键特征提取能力。该设计在保证实时性的基础上,显著提高了检测精度,尤其增强了小目标的识别效果。

2.2.3 检测头

YOLOv8采用解耦式检测头设计,将分类和回归任务分离以减少干扰。其无锚框机制直接预测目标位置、尺寸和类别,简化了检测流程。通过动态标签分配策略,根据预测框匹配度智能分配正样本,提高检测精度。结合多尺度预测技术,在不同层级特征图上进行检测,有效识别不同尺寸的目标。

2.2.4 YOLOv8s与YOLOv8m的模型差异

本研究采用YOLOv8s和YOLOv8m模型进

行玉米种子品种识别,两模型架构相同但规模有别。YOLOv8s的网络深度和宽度系数分别为0.33和0.50,具有11.2M参数量和28.6GFLOPs浮点运算量,体积更小;而YOLOv8m的系数为0.67和0.75,参数量达25.9M,计算量78.9GFLOPs,能提取更复杂的特征,更适合识别形态相似的种子。这种规模差异为性能对比和场景选择提供了明确依据,同时保持了轻量化部署特性。

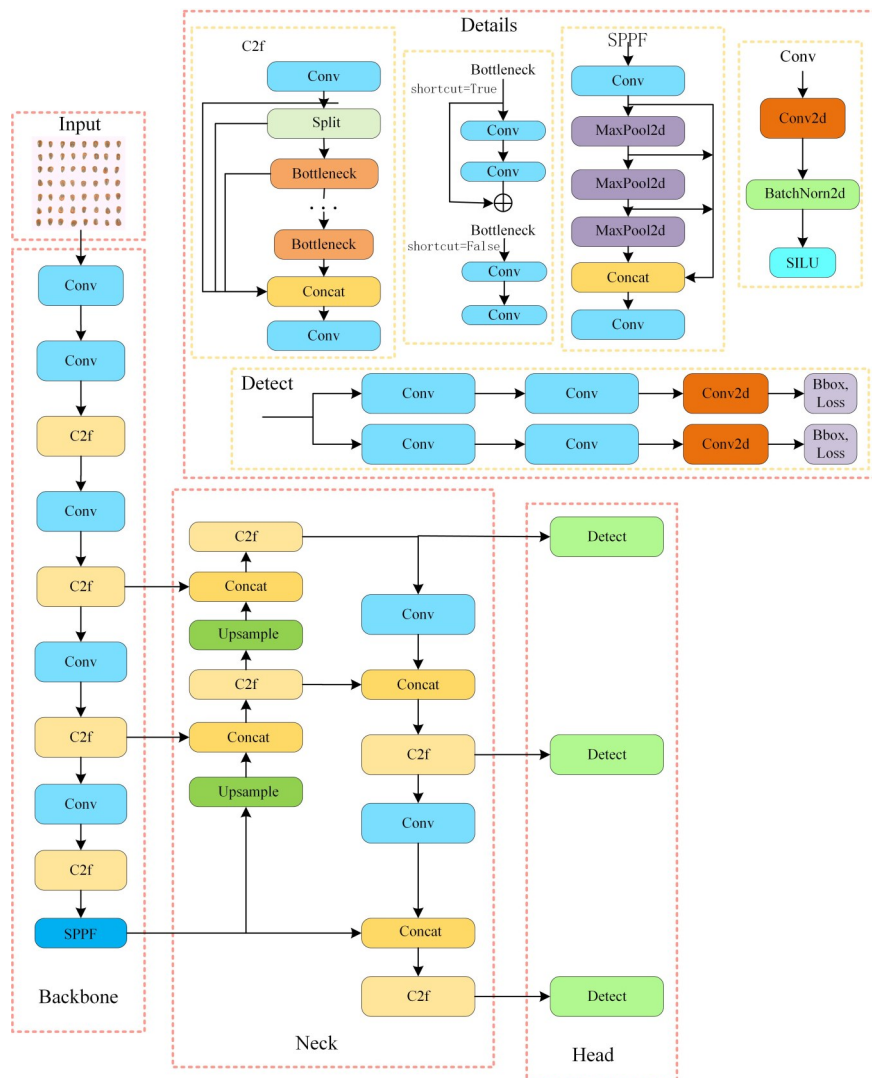


图4 YOLOv8的网络结构图

Fig. 4 Network structure diagram of YOLOv8

2.3 评价指标

实验采用精确率 (precision)、召回率 (recall)、平均精确率 (average precision, AP)、平均精确率均值 (mean average precision, mAP) 及 F1

分数 (F1-score) 作为评价指标,用于衡量模型性能。精确率 (Precision) 指在所有预测为阳性的样本中,真阳性样本所占的比例,通过公式 (1) 计算:

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% . \quad (1)$$

召回率指实际为阳性的样本中,被模型预测为阳性的样本所占的比例,通过公式(2)计算得出:

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% , \quad (2)$$

其中, TP:实际类别为阳性且模型预测也为阳性的样本数量。FP:实际类别为阴性,但模型错误预测为阳性的样本数量。FN:实际类别为阳性,但模型错误预测为阴性的样本数量。平均精确率(AP)表示模型对每个类别的检测平均准确率,其由公式(3)计算:

$$AP_i = \int_0^1 (\text{Precision}_i \times \text{Recall}_i) d\text{Recall}_i . \quad (3)$$

平均精确率均值是用于评估目标检测模型在多个类别上综合性能的指标。它先计算每个类别的平均精确率(AP),再对这些 AP 值取平均,以此衡量模型的整体性能,其通过公式(4)计算:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i . \quad (4)$$

F1 分数是精确率与召回率的调和平均值,综合了精确率和召回率的信息。当精确率和召回率均较高时,F1 分数也较高,用于平衡并综合评估模型在精确率和召回率两方面的性能,其定义为:

$$F1 - \text{Score} = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \times 100\% . \quad (5)$$

2.4 实验与模型训练

模型训练与测试在 Windows 10 操作系统(配置为 Intel Core i5 10600KF 处理器、64 GB 内存、NVIDIA GeForce RTX 3060 Ti 显卡)上进行。所使用的编程语言为 Python 3.10,深度学习框架为 PyTorch 2.4.1,并通过 CUDA 12.1 和 CUDNN 8.9.6 启用 GPU 加速。实验的详细超参数如表 6 所示。

表 6 实验的详细超参数

Tab. 6 Detailed hyperparameters of experiment

参数	值	参数	值
Image size	640×640	Optimizer	Adam
Batch size	8	IoU	0.7
Classes	4	Lr0	0.001 25
Epochs	800	Lrf	0.01
Momentum	0.9	Weight_decay	0.000 5

本研究采用统一的玉米种子图像数据集与超参数,分别对 YOLOv8s 与 YOLOv8m 模型开展训练,保证模型的训练过程与实验条件完全一致,确保实验结果具有可比性。实验采用了早停机制,即当平均精度不再显著提升时,训练会自动终止。

3 实验结果与分析

3.1 YOLOv8s 与 YOLOv8m 模型结果与分析

分别基于 YOLOv8s 和 YOLOv8m 模型开展训练实验,构建 4 个玉米种子品种的识别模型。实验所用数据集详情如表 1 所示,模型超参数设置如表 6 所示。

3.1.1 模型训练过程中的各项指标

图 5 展示了 YOLOv8s 和 YOLOv8m 模型的训练性能对比。前 3 列分别呈现了边界框损失、目标损失和分类损失的变化趋势,横轴为数据集的训练进度,纵轴为综合损失值大小。由图 5(a)可以看出,YOLOv8s 模型的训练集边界框损失和分类损失最终收敛至约 0.172 和 0.184,验证集对应值为 0.162 和 0.404。由图 5(b)可以看出,YOLOv8m 模型表现更优,训练集两项损失分别降至 0.147 和 0.125,验证集为 0.136 和 0.155,显示出更好的拟合性能、稳定性和收敛精度。尽管 YOLOv8m 在 200 轮训练时出现短暂波动(这是 YOLO 系列模型的典型现象,可能与学习细粒度样本有关),但在优化策略调控下各项指标快速恢复稳定并保持平稳收敛趋势,最终未出现过拟合。

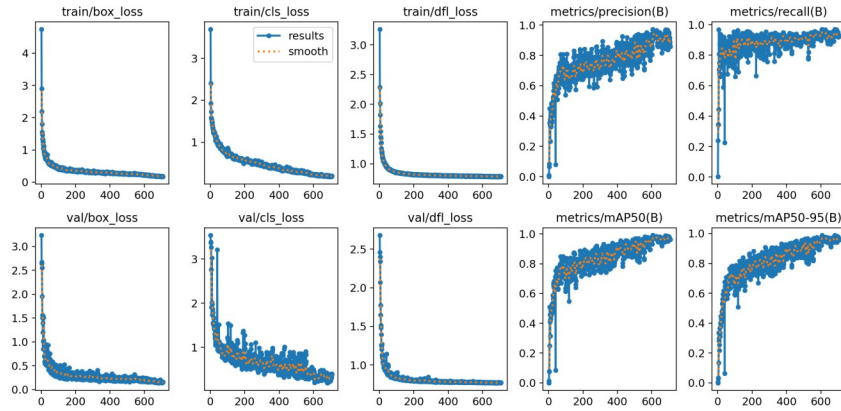
图中后 2 列曲线展示了精确率与召回率曲线,横轴为训练迭代次数,纵轴为精确率与召回率数值。该曲线反映了置信度阈值变化时玉米种子品种识别性能的评估结果,曲线数值越接近 1,表明模型的识别置信度越高。与 YOLOv8s 模型相比,YOLOv8m 模型后两列的性能指标曲线更稳定且更接近 1,表明其在本研究中的识别性能更优。

3.1.2 混淆矩阵

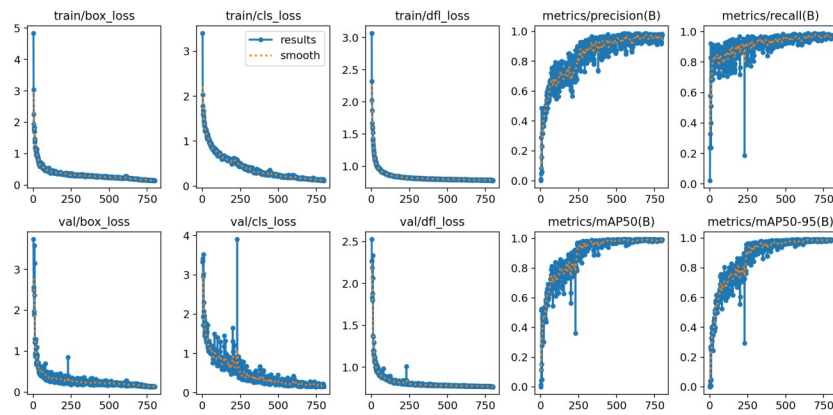
YOLOv8s 与 YOLOv8m 模型在测试集上的混淆矩阵如图 6 所示。混淆矩阵展示了 JSH257、YQ392、YD807、YQ358 及背景类别的预测分类与真实分类结果。矩阵网格中的每个

元素代表特定预测类别与真实类别组合的样本数量,正确分类结果位于主对角线上,表明预测

类别与真实类别一致。反之,非对角线上的元素代表误分类结果。




(a) YOLOv8s



(b) YOLOv8m

图5 模型训练过程中的性能指标值

Fig. 5 Performance values during the training process of the model



(a) YOLOv8s

(b) YOLOv8m


图6 模型的混淆矩阵

Fig. 6 Confusion matrix of the model

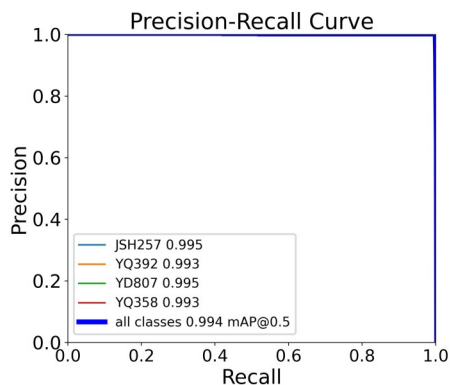
YOLOv8s 模型在测试集上的混淆矩阵如由图 6(a)所示,非对角线元素数值之和为 253,表明该模型存在一定程度的误分类现象,其中 JSH257 与 YQ392 品种间的误分类样本数量最多。图 6(b)为 YOLOv8m 模型的测试集混淆矩阵,其非对角线元素数值之和仅为 4。相较于 YOLOv8s 模型的 253, YOLOv8m 模型的误分类样本数量显著减少,这表明其对四种玉米品种的分类准确率显著优于 YOLOv8s 模型。

3.1.3 模型精确率-召回率曲线

图 7展示了 YOLOv8s 与 YOLOv8m 模型的精确率-召回率(PR)曲线。YOLOv8m 模型的 PR 曲线下面积更大,说明其在不同置信度下都具有更优异的泛化性能。值得注意的是,该模型对四个品种的 PR 曲线几乎完全重合,对四个品种的分类表现高度一致,其平均 mAP@0.5 达到 99.4% 的优异水平。相比之下, YOLOv8s 的平



(a) YOLOv8s



(b) YOLOv8m

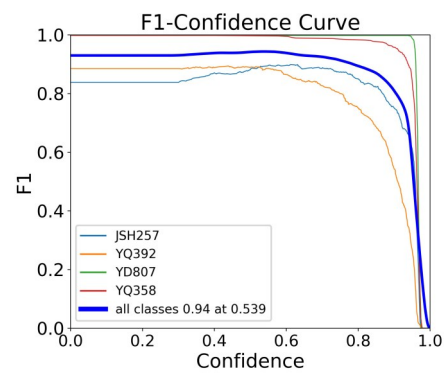
图 7 模型的精确率-召回率曲线

Fig. 7 Precision-recall curve of the model


均 mAP@0.5 为 97.2%,各品种曲线分离度较明显。这些数据充分证明, YOLOv8m 模型在本研究的玉米品种分类任务中展现出显著优势,其综合性能明显超越 YOLOv8s 版本。

3.1.4 模型 F1 分数

图 8展示了 YOLOv8s 与 YOLOv8m 模型的 F1-置信度曲线对比。从图 8(a)和(b)可以看出, YOLOv8m 模型的 F1 值更接近 1.0,说明其对四种玉米品种的分类性能稳定且优异。该模型在较宽置信度范围内的平均 F1 值保持在 99.8% 左右,而 YOLOv8s 仅在较窄区间内维持 94% 的平均 F1 值。这些数据充分证明 YOLOv8m 模型在本研究中的分类表现明显优于 YOLOv8s。



(a) YOLOv8s



(b) YOLOv8m

图 8 模型的 F1 - 置信度曲线

Fig. 8 F1-Confidence curve of the model

3.2 不同数据集对模型的影响

使用 YOLOv8s 和 YOLOv8m 模型,分别在五组数据量递减的数据集上进行训练验证,具体数据详见表 1 至表 5。

3.2.1 YOLOv8s 训练不同数据集的结果

基于五组数据集(表1~表5)的YOLOv8s模型训练结果显示,数据量对模型性能影响显著。如表7所示,随着数据量减少,模型性能明显下降。其中,第一组表现最佳,平均精确率93.9%、召回率94.7%、mAP@0.5达97.2%、F1分数94.2%;而第五组表现最差,各项指标分别为74.2%、83.7%、72.5%和78.6%,检测能力明显较弱。

表7 YOLOv8s 模型使用各组数据集的结果

Tab.7 YOLOv8s model Results for each group.

数据集	精确率/ %	召回率/ %	mAP@0.5/ %	F1分数/ %
第一组	93.9	94.7	97.2	94.2
第二组	76.2	93.3	82.5	83.2
第三组	82.5	90.2	88.4	86.7
第四组	82	86.1	86.4	84
第五组	74.2	83.7	72.5	78.6

3.2.2 YOLOv8m 训练不同数据集的结果

基于五组数据集(表1~表5)训练YOLOv8m模型,性能结果见表8。分析表明,该模型在所有数据集上表现稳定,受数据量影响较小。图9的F1-置信度曲线显示,YOLOv8m性能在所有数据集上均优于YOLOv8s,且随着数据规模减小,优势更明显。在第一组数据中,YOLOv8m取得近乎完美的指标(mAP@0.5:99.4%,F1:99.8%),优于YOLOv8s(97.3%,94.4%)。在样本较少的第五组数据中,YOLOv8m仍保持优势(mAP@0.5:96.8%,F1:93.1%),远超YOLOv8s的72.5%和78.6%。

3.3 双模型核心指标对比与部署适配性分析

模型部署适配性主要取决于参数量和浮点运算量两大指标。前者影响模型文件体积和内

表8 YOLOv8m 模型使用第一组数据集的结果

Tab.8 YOLOv8m model Results for Group I

数据集	精确率/ %	召回率/ %	mAP@0.5/ %	F1分数/ %
第一组	99.8	99.8	99.4	99.8
第二组	98	98.6	99.2	98.2
第三组	97.9	97.3	99.2	97.6
第四组	94.8	94.8	97.9	94.8
第五组	94.9	91.5	96.8	93.1




图9 YOLOv8 模型各数据集的F1-置信度曲线

Fig.9 F1-confidence curves for the YOLOv8 model across various datasets

存占用,后者决定硬件算力需求和推理速度。本研究采用 640×640 标准输入尺寸,对两个模型的核心指标进行测试,并结合已验证的精度和推理速度数据,开展多维度对比分析,结果详见表9。

表9显示,YOLOv8m的参数量是YOLOv8s的2.3倍,运算量达2.8倍,模型扩增带来显著精度提升。mAP@0.5提高2.2%,对相似品种JSH257和YQ392的识别精度更提升超10%。两者推理速度仅相差4.9毫秒,均满足实时监测需求。部署方面,YOLOv8s体积小、算力需求低,适合轻量化嵌入式场景。而YOLOv8m以微小速度代价换取精度和稳定性的显著提升,在本研究硬件环境中运行流畅,综合部署价值更优。

表9 YOLOv8s与YOLOv8m核心指标对比

Tab.9 Comparison table of core indicators between YOLOv8s and YOLOv8m

模型型号	参数量/M	浮点运算量/GFLOPs	平均mAP@0.5/%	单张图像推理耗时/毫秒
YOLOv8s	11.1	28.7	97.2	63.7
YOLOv8m	25.9	79.1	99.4	68.6

4 模型部署与应用验证

4.1 部署硬件环境

本研究开发了一套玉米种子品种识别的硬件系统,专为实验室小批量检测设计。系统由五大核心模块构成:1)带环形光源和工业相机的可调成像支架;2)光源控制器,通过交换机与成像模块联动,控制光源提供均匀稳定的照明;3)交换机,模块间通信枢纽;4)多规格种子承载台,单次承载50~100粒;5)计算机,搭载YOLOv8m模型,接收并实现图像处理全流程。该部署方案通过模块化设计实现了稳定成像与高效识别的一体化操作。

4.2 软件设计

玉米种子识别系统基于Windows10平台开发,采用Python语言编写,使用Pycharm作为IDE。系统整合了OpenCV、PySide2、PyQt5、Py-Installer、QtDesigner、Pytorch以及Numpy等图像处理和界面开发库。借助PyInstaller实现程序打包功能,使软件能在无Python环境的设备上运行。这些主流工具库为系统提供了高效的图像处理和用户界面开发能力,并简化了部署流程。

4.3 部署效果验证

基于“硬件装置+模型”的基础,开发了可视化操作软件,通过简化操作流程降低使用门槛。软件提供设备连接、模型加载、检测控制等集成功能,操作仅需三步:连接硬件→加载模型→启动检测。检测时可同步显示原始种子图像及标注结果,并自动统计各品种种子的数量。

系统采用FPS(1/单图平均推理耗时)评估实时性能,在测试环境下,YOLOv8m和YOLOv8s模型分别达到14.6FPS和15.7FPS,满足实时需求。以图10中玉米种子识别为例,从触发检测到界面输出最终结果,系统能在2秒内完成42粒种子的检测分类(YOLOv8m推理仅68.6毫秒),各品种识别准确,充分验证了系统的

实用性和高效性。



图10 玉米种子品种识别系统软件操作界面及检测结果
Fig. 10 Software operation interface and detection results of the corn seed variety recognition system

5 结 论

本研究针对玉米种子品种快速无损识别的行业需求,搭建了LED白光反射成像系统,获取4个玉米品种的白光反射成像数据,构建了多梯度规模标注数据集,并系统对比了YOLOv8s与YOLOv8m模型的性能差异。实验结果表明,YOLOv8m模型在各项指标上均优于YOLOv8s。在全量数据集测试中,YOLOv8m的平均mAP@0.5达到99.4%,F1值高达99.8%,特别是对形态相似的JSH257和YQ392品种的识别精度显著提升。虽然YOLOv8m的推理速度(68.6毫秒)略慢于YOLOv8s(63.7毫秒),但4.9毫秒的微小差距不影响实时检测需求。值得注意的是,YOLOv8m在数据集规模减小时展现出更强的稳定性。基于包含12008粒玉米种子的全量数据集测试,该模型在4个品种上的平均精度、召回率和F1值均达到99.8%的优异水平。这是目前基于LED白光成像和YOLOv8模型的玉米种子识别领域最佳性能,为农业检测自动化和种子质量管控提供了可靠的技术方案。建议在计算资源允许的情况下优先采用YOLOv8m模型,以获得最优的识别精度和跨数据集的鲁棒性。

参 考 文 献:

- [1] García-Lara S, Serna-Saldivar S O. Corn history and culture[J]. *Corn*, 2019: 1-18.
- [2] Sun J, Zou Y. Analysis on the method of corn seed purity identification[J]. *Hans J. Agric. Sci*, 2022, 10: 292-

298. DOI: 10.12677/HJAS.2020.105043.
- [3] Park H S, Choi K C, Kim J H, *et al.* Discrimination and quantification between annual ryegrass and perennial ryegrass seeds by near-infrared spectroscopy[J]. *The Journal of Animal & Plant Sciences*, 2016, 26(5): 1278-1283
- [4] Sundaram R M, Naveenkumar B, Biradar S K, *et al.* Identification of informative SSR markers capable of distinguishing hybrid rice parental lines and their utilization in seed purity assessment[J]. *Euphytica*, 2008, 163(2): 215-224. <https://doi.org/10.1007/s10681-007-9630-0>
- [5] Satturu V, Rani D, Gattu S, *et al.* (2018) DNA fingerprinting for identification of rice varieties and seed genetic purity assessment[J]. *Agricultural Research* 7(4): 379-390. DOI: 10.1007/s40003-018-0324-8
- [6] Pallavi HM, Gowda R, Shadakshari YG, *et al.* (2011) Identification of SSR markers for hybridity and seed genetic purity testing in sunflower (*Helianthus annuus* L.) [J]. *Helia* 34:59-66. <https://doi.org/10.2298/HEL1154059P>
- [7] 李浩光, 李卫军, 覃鸿, 等. 基于栈式自编码神经网络的包衣单籽粒玉米品种识别[J]. *农业机械学报*, 2017, 48(s1):422-428.
- LI Haoguang, LI Weijun, QIN Hong, YU Lina, YU Yunhua and PANG Yan. Varietal Identification for Single Maize Seed Based on Stacked Auto Encoder Neural Network[J]. *Society for Agricultural Machinery*, 2017, 48(s1): 422-428. DOI:10.6041/j.issn.1000-1298.2017.S0.065(in Chinese)
- [8] Huang M, Wang Q, Zhang M, Zhu Q. Prediction of color and moisture content for vegetable soybean during drying using hyperspectral imaging technology [J]. *J Food Eng*, 2014; 128: 24-30. <https://doi.org/10.1016/j.jfoodeng.2013.12.008>
- [9] Feng L, Zhu S, Liu F, *et al.* Hyperspectral imaging for seed quality and safety inspection: a review [J]. *Plant Methods*, 2019;15:91. <https://doi.org/10.1186/s13007-019-0476-y>
- [10] Wang L, Sun D-W, Pu H, Zhu Z. Application of Hyperspectral Imaging to Discriminate the Variety of Maize Seeds [J]. *Food Anal Methods*, 2016;9:225-234. <https://doi.org/10.1007/s12161-015-0160-4>
- [11] Zhang J, Dai L, Cheng F. Corn seed variety classification based on hyperspectral reflectance imaging and deep convolutional neural network[J]. *J Food Meas Charact*, 2021; 15: 484 - 494. <https://doi.org/10.1007/s11694-020-00646-3>
- [12] Fang X. , Hu X. , Li B. *et al.* Orbital angular momentum-mediated machine learning for high-accuracy mode-feature encoding. *Light Sci Appl* 13, 49 (2024)
- [13] Wang Y. , Liao K. , Zhang K. *et al.* Reconfigurable versatile integrated photonic computing chip. *eLight* 5, 20 (2025)
- [14] Xu P, Yang R, Zeng T, *et al.* Varietal classification of maize seeds using computer vision and machine learning techniques[J]. *J Food Process Eng*, 2021;44:e13846. <https://doi.org/10.1111/jfpe.13846>
- [15] 王驰, 沈晨, 黄庆, 等. 夜间动物图像自监督学习增强与检测方法[J]. *中国光学(中英文)*, 2024, 17(5): 1087-1097.
- WANG Chi, SHEN Chen, HUANG Qing, ZHANG Guo-feng, LU Han, CHEN Jin-bo. Self-supervised learning enhancement and detection methods for nocturnal animal images[J]. *Chinese Optics*, 2024, 17(5): 1087-1097.
- [16] Javanmardi S, Miraei Ashtiani S-H, Verbeek FJ, Martynenko A. Computer-vision classification of corn seed varieties using deep convolutional neural network [J]. *J Stored Prod Res*, 2021; 92: 101800. <https://doi.org/10.1016/j.jspr.2021.101800>
- [17] Li J, Xu F, Song S. A maize seed variety identification method based on improving deep residual convolutional network[J]. *Front Plant Sci*, 2024;15:1382715. <https://doi.org/10.3389/fpls.2024.1382715>

- [18] Bi C, Hu N, Zou Y, *et al.* Development of Deep Learning Methodology for Maize Seed Variety Recognition Based on Improved Swin Transformer[J]. *Agronomy*,2022;12:1843. <https://doi.org/10.3390/agronomy12081843>

作者简介:



耿利杰,男,副教授,2014年于哈尔滨工业大学获得博士学位,主要研究方向为太赫兹激光技术、机器视觉与深度学习技术。E-mail: genglijie1984@163.com



李 晋,男,教授,2013年于哈尔滨工业大学获得博士学位,研究方向为微纳光纤传感器、农业物联网与农机装备智能化。E-mail: lijn2023@nwafu.edu.cn



杨 坤,男,教授,2008年于中国科学院上海光学精密机械研究所获得博士学位,研究方向为光学传感与精密测量、机器视觉与AI。E-mail: yangkun@zzuli.edu.cn