

基于 LMA – DEIM 的高通量密集粘连小麦籽粒目标检测模型

王新法¹ 王一兆¹ 欧行奇² 王崧屹¹ 王警博¹ 李 听¹ 李学勇¹ 张博轩³

(1. 河南科技学院计算机科学与技术学院, 新乡 453003; 2. 河南科技学院农学院, 新乡 453003;

3. 河南理工大学软件学院, 焦作 454000)

摘要: 针对密集粘连小麦籽粒高通量检测存在籽粒计数精度与效率难以兼顾、嵌入式部署困难的问题,本文提出一种基于 LMA – DEIM 的轻量化密集粘连小麦籽粒目标检测模型。构建了包含 5 种小麦品种共 2.3×10^5 粒籽粒目标框的 WSD 数据集,为模型训练与评估提供数据基础。在 DEIM 框架基础上,设计轻量化全局建模主干网络 Lite – Mamba,以线性计算复杂度增强对粘连区域的区分能力;提出基于选择性状态空间的 MIFI 模块替换原 AIFI 模块,实现高效特征交互的同时降低计算复杂度;引入轻量化下采样模块 ADown,缓解下采样过程细节丢失,提升细节特征保留能力。试验结果表明,LMA – DEIM 模型在 WSD 测试集上精确率、召回率与 mAP@50 分别达到 92.7%、91.5% 和 92.0%,检测速度达 143.1 f/s,相比原 DEIM 框架,在精度显著提升的同时,参数量减少 66.9%,速度提高 240%,在高密度测试子集上计数平均相对误差仅为 3.08%,满足嵌入式设备对高通量籽粒实时、高精度检测的部署需求。

关键词: 小麦籽粒; 籽粒计数; 密集粘连; 目标检测; DEIM 框架

中图分类号: TP391.4; S24

文献标识码: A

文章编号: 1000-1298(2026)14-0057-11

OSID:



High-throughput Target Detection Model for Densely Cohesive Wheat Grains Based on LMA – DEIM

Wang Xinfa¹ Wang Yizhao¹ Ou Xingqi² Wang Songyi¹ Wang Jingbo¹ Li Ting¹

Li Xueyong¹ Zhang Boxuan³

(1. School of Computer Science and Technology, Henan Institute of Science and Technology, Xinxiang 453003, China

2. School of Agriculture, Henan Institute of Science and Technology, Xinxiang 453003, China

3. School of Software, Hennan Polytechnic University, Jiaozuo 454000, China)

Abstract: Aiming to address the challenges of balancing accuracy and efficiency, and the difficulty of embedded deployment, in high-throughput detection of densely clustered wheat grains, a lightweight LMA – DEIM-based model for detecting densely clustered wheat grains was proposed. Firstly, a WSD dataset containing 230 000 grain target boxes from five wheat varieties was constructed to provide a data foundation for model training and evaluation. Secondly, based on the DEIM framework, a lightweight global modeling backbone network, Lite – Mamba, was designed to enhance the ability to distinguish clustered regions with linear computational complexity. A MIFI module based on selective state space was proposed to replace the original AIFI module, achieving efficient feature interaction and reduced computational complexity. A lightweight downsampling module, ADown, was introduced to mitigate detail loss during downsampling and improve the ability to preserve detailed features. Experimental results showed that the LMA – DEIM model achieved precision, recall, and mAP@50 of 92.7%, 91.5%, and 92.0% on the WSD test set, respectively, with an inference speed of 143.1 f/s and an average relative counting error of only 3.08% on the high-density test subset. Compared with the original DEIM

收稿日期: 2025 – 12 – 15 修回日期: 2026 – 02 – 26

基金项目: 河南省重点研发专项(251111210800, 261111210600)、河南省科技攻关计划项目(252102111172, 252102210088)和河南省研究生教育改革与质量提升工程项目(YJS2025AL69)

作者简介: 王新法(1972—),男,教授,博士,主要从事农业工程与农业智能装备研究,E-mail: wangxf@hist.edu.cn

通信作者: 李学勇(1979—),男,副教授,博士,主要从事智慧农业技术研究,E-mail: lxy@hist.edu.cn

framework , the proposed method significantly improved accuracy while reducing the number of parameters by 66.9% and increasing speed by 240% , meeting the deployment requirements of embedded devices for high-throughput , real-time , and high-precision grain detection.

Key words: wheat grains; grain count; densely adhered; target detection; DEIM framework

0 引言

小麦作为全球重要的粮食作物,优良品种的选育对保障国家粮食安全具有关键意义^[1]。千粒重是评价小麦品种产量潜力和稳定性的核心指标之一^[2-3]。然而,当前主流的千粒重测定方法主要依赖人工计数,费时费力且误差较大^[4]。研究密集小麦籽粒高通量自动计数方法对提升作物育种效率具有重要意义^[5]。

早期的密集籽粒计数研究集中于传统图像处理算法,包括形态学操作^[6-7]、分水岭算法等^[8-10]。这类方法存在 2 大局限:①依赖人工设计的特征,对复杂堆叠、粘连情况的泛化能力与鲁棒性不足^[11]。②算法计算复杂度高,处理效率低^[12],难以满足高通量实时检测的应用需求。与之相比,近年来迅速发展的深度学习技术为此问题提供了新的解决方案。以卷积神经网络^[13-14]、Transformer^[15]为代表的模型,摒弃了繁琐的手工特征设计,能够直接从数据中自动学习更具判别力的特征。这类方法不仅在处理籽粒粘连、遮挡等复杂情况时表现更优,推理速度也大幅提升,足以支撑高通量的实时检测应用。针对重度粘连问题,宋怀波等^[16]提出了改进的 YOLO v5 算法,通过引入混合深度可分离卷积模块与 SE 注意力机制,将模型 mAP@ 50 - 95 提升至 99.4% ,单图检测时间为 0.3 s ,但在籽粒数量超过 300 时累计计数误差显著增大,难以适应高通量检测需求。类似地,Ma 等^[17]基于 YOLO v8 提出 YOLO v8 - HD 模型,通过共享卷积层精简检测头、并在 C2f 模块中加入可变形注意力机制,实现 mAP@ 50 为 99.3% ,在重度粘连场景下计数准确率为 77.6% ,反映出训练数据集覆盖场景有限,对复杂真实环境的适应性不足。上述研究都达到了较高检测精度,但在密集粘连、高通量的鲁棒性与泛化能力仍面临明显挑战,主要受限于现有数据集的质量和模型的架构。

对实际育种场景,检测设备需兼具便携性与实时处理能力。然而,移动及嵌入式平台计算资源通常受限,现有深度学习模型往往参数量大、内存占用量高,导致在嵌入式设备上部署面临挑战。因此,模型轻量化已成为当前研究的关键方向之一^[18-20]。杨森森等^[21]提出了一种基于轻量级架构的杂草识别方法,引入 MobileViT 模块与卷积混合结构构建

特征提取网络,模型参数量仅 1.12×10^7 的条件下,识别准确率达 99.61%。相比之下,以 ResNet50 为骨干的模型准确率达 99.00% ,但参数量高达 1.35×10^8 ,显著增加了部署成本。由此可知,通过合理的轻量化设计,可在保持高精度的前提下大幅降低模型参数量与计算量。

综上所述,密集籽粒目标检测与计数研究已取得长足进展,然而在重度密集粘连籽粒的高通量检测场景下,现有方法仍面临明显局限。此外,在计算资源受限的嵌入式平台上,如何实现高精度、高效率的实时检测与计数,仍缺乏同时兼顾精度与速度的轻量化解决方案。

针对上述问题,本文构建较大规模的多品种小麦籽粒检测(Wheat seed detection, WSD)数据集,提出轻量化密集粘连籽粒检测架构 LMA - DEIM。设计基于选择性状态空间的 Lite - Mamba 轻量化主干网络,以线性复杂度实现全局上下文建模,提升对籽粒粘连区域的区分能力。提出 MIFI (Mamba-based intra-scale feature interaction)特征交互模块,替代原框架内基于自注意力机制的 AIFI (Attention-based intra-scale feature interaction)模块,实现深层特征图内部高效交互,进一步降低计算量,便于在资源受限的嵌入式设备中部署。此外,针对轻量化模型在细节保持上引入下采样模块 ADown (Adaptive downsampling),在特征图尺度变换中有效保留关键细节,以适配对图像分辨率与细节敏感较高的考种。三者协同工作,以期使 LMA - DEIM 模型在检测精度、推理速度及嵌入式部署性能上得到显著提升。

1 数据集构建

为了丰富高通量密集粘连小麦籽粒目标检测领域的的数据,本研究构建 5 个小麦品种 WSD 数据集,涵盖矮抗 58、百农 607、郑麦 379、屯麦 127 及豫农 916 (简称分别为 AK58、BN607、ZM379、TM127、YN916),共计 2.3×10^5 粒籽粒目标框。

1.1 数据采集

使用华为 Mate60、小米 14 Pro 等多种移动设备进行图像采集,在白色 A4 纸与瓦楞纸(用于模拟田间土地颜色)2 种背景下进行采集,拍摄高度为 20 ~ 30 cm,每幅图像内样本数 100 ~ 500 粒且粘连程度较大,图像示例及其标注如图 1 所示。




图 1 数据集示例

Fig. 1 Dataset examples

原始数据集包含 2 368 幅图像,约 3.83×10^4 个籽粒目标,图像分辨率为 4 624 像素 $\times$ 2 080 像素,多品种的图像与背景条件可有效提升数据集的泛化能力。

1.2 数据增强

为扩充数据集数量,使模型更好地学习各种场景的密集粘连籽粒特征,采用翻转、平移、旋转、改变颜色和添加随机高斯噪声方式对原始图像和标签进行扩充,增强效果如图 2 所示,扩充后图像数量达 14 207 幅。使用 LabelImg 软件标注籽粒目标,目标检测标签格式为 VOC,共 230 051 个籽粒目标框,数据集的类别分布与目标框统计信息如图 3 所示。标注后将数据集按比例 8:1:1 划分为训练集、验证集

和测试集(其中训练集 11 367 幅,验证集和测试集各 1 420 幅)。

2 模型构建

目前,主流目标检测框架可分为 2 类,CNN 框架^[22](如 YOLO、FCOS、CenterNet 等)与 Transformer 框架(如 DETR、RT - DETR 等)。在密集籽粒检测中,CNN 框架因依赖 NMS (Non-maximum suppression)后处理和卷积的局部感受野,易误删重叠检测框或漏检粘连的籽粒目标^[23];Transformer 框架通过端到端设计和全局注意力消除 NMS 并捕捉长距离依赖,但存在收敛慢和监督稀疏的问题^[24]。为了解决上述问题,DEIM 框架^[25]在 RT - DETR 模




图 2 数据增强示例

Fig. 2 Data augmentation examples




图3 数据集类别与目标框统计

Fig.3 Dataset categories and bounding box statistics

型基础上,采用 Dense O2O (Dense One-to-One) 匹配策略有效增强监督信号并引入匹配感知 (Match-aware) 损失提高收敛速度,为密集目标的实时检测任务提供了新的思路。

2.1 LMA-DEIM 目标检测模型

以 DEIM 框架为基础,提出一种轻量化的密集小麦籽粒检测模型 LMA-DEIM,网络结构如图 4 所示。设计轻量化的线性复杂度全局建模主干网络 Lite-Mamba,引入状态空间方程实现高效、全局建模的视觉特征提取;提出线性时间复杂度的

高效特征交互模块 MIFI 替换原始框架的 AIFI 模块,显著降低计算量的同时实现深层语义特征图内部交互;引入 ADown 轻量化下采样模块,以较少的参数量增加为代价显著降低下采样导致的精度损失。

2.2 Lite-Mamba 轻量化主干网络

小麦籽粒目标微小、排列紧密且易粘连重叠,因此,堆积籽粒的边界需通过与周围多个邻居及远端籽粒的关系才能被正确界定,而传统卷积算法获取籽粒间的长程依赖关系有限。基于自注意力的主干网络能够实现全局建模,但复杂度较高,难以满足嵌入式设备的部署和高通量检测需求。

本文提出一种轻量化主干网络 Lite-Mamba,引入选择性状态空间模型^[26],以线性计算复杂度实现全局上下文建模,从而在保持效率的同时提升对粘连区域的区分能力。

如图 4 所示,输入特征图经层归一化 (Layer norm) 稳定训练后,通过 1×1 卷积压缩通道至 $\frac{C}{4}$ 以降低计算量。考虑到籽粒的粘连边界是任意方向,仅沿单一方向扫描会引入方向偏差,借鉴 VMamba 网络^[27] 处理思路,将降维后特征图通过并行的水平与垂直扫描选择性状态空间模块,分别沿 2 个空间方向捕获长程依赖,输出各为 $\frac{C}{2} \times H \times W$ 的特征图,以全面捕捉全局上下文信息。为减少对输入特征图因降维导致局部特征丢失而影响精度,在状态空间进行全局建模的同时,通过并行 1×1 卷积分支将通




图4 LMA-DEIM 网络架构

Fig.4 LMA-DEIM network architecture

道扩展回 C , 尽可能保留原始局部特征。最后, 融合来自全局建模与局部保留的多分支特征, 输出增强后的 $C \times H \times W$ 特征图。通过方向分离的扫描机制与轻量化多分支设计, Lite-Mamba 在显著降低计算量同时, 实现对密集粘连籽粒间复杂空间关系的高效建模。

2.3 MIFI 高效特征交互模块

原始 DEIM 框架采用 AIFI 模块进行深层语义特征图的内部交互, 但由于基于自注意力机制, 计算复杂度过高, 难以满足嵌入式设备的部署需求。因此设计基于 Mamba 的高效特征交互模块 MIFI, 通过选择性状态空间方程替代自注意力机制, 使用基于线性计算复杂度的 SSM 实现对深层特征图全局信息交互与建模, 在增强深层特征语义表征能力的同时大幅降低模型计算量, 结构如图 5 所示。




图 5 MIFI 模块架构

Fig. 5 MIFI module architecture

给定来自主干网络的 S5 特征图, 空间尺寸为 20×20 , 通道数为 32。将特征图沿空间维度展平并调整维度, 形成输入序列 $X \in \mathbb{R}^{400 \times 256}$, 再通过 3 个独立的线性变换层, 由输入序列动态生成参数 B 、 C 与 Δ , 同时从模块内部获取可学习静态参数 A 。

在此基础上, 采用零阶保持方法将连续时间状态空间模型离散化, 离散化计算式为

$$\bar{A} = \exp(\Delta A) \quad (1)$$

式中 $\exp(\cdot)$ ——矩阵指数运算

Δ ——离散化步长

A ——连续时间系统矩阵, 是 MIFI 模块中可学习的参数

$\bar{A}$ ——离散状态转移矩阵

离散化后输入矩阵为

$$\bar{B} = (\Delta A)^{-1} (\exp(\Delta A) - I) (\Delta B) \approx \Delta B \quad (2)$$

式中 B ——连续时间系统输入矩阵

$\bar{B}$ ——离散化后离散输入矩阵

I ——单位矩阵

离散化后, 单个时间步状态空间方程可表示为

$$y_t = C_t h_t \quad (3)$$

$$h_t = \bar{A}_t h_{t-1} + \bar{B}_t x_t \quad (4)$$

其中

式中 t ——时间步索引, $1, 2, \dots, L$

L ——序列长度

x_t ——第 t 个时间步输入向量

h_t ——第 t 个时间步隐藏状态向量

$\bar{A}_t$ ——第 t 个时间步离散状态转移矩阵

$\bar{B}_t$ ——第 t 个时间步离散输入矩阵

C_t ——第 t 个时间步输出矩阵

y_t ——第 t 个时间步输出标量

通过高效的并行扫描算法, 对序列中所有时间步执行上述计算, 得到蕴含全局上下文信息的输出序列 $Y \in \mathbb{R}^{400 \times 256}$, 最终, 通过残差连接将输出与输入序列融合, 得到模块最终输出 $Y_{out} = Y + X$ 。MIFI 模块以线性复杂度实现特征图内高效全局建模, 显著降低模型计算量, 提升推理速度。

2.4 ADown 轻量化下采样模块

传统下采样方法往往在降低分辨率时导致特征图的信息丢失, 因此引入 ADown 模块^[28], 对模型结构进行改进, 通过结合空洞卷积与特征重排机制, 在降低计算复杂度的同时, 有效缓解因下采样导致的籽粒细节丢失问题, 提升检测性能。

3 结果与分析

3.1 评价指标

选用精确率 (P)、召回率 (R)、平均精度均值 ($mAP@50$ 、 $mAP@50-95$)、参数量 (Param)、浮点运算量、检测速度及模型显存占用量共 7 个指标, 对模型性能进行综合评价。由于研究面向高通量、密集粘连的籽粒检测与计数任务, 因此重点关注模型检测速度与平均精度均值。

3.2 不同主干网络性能

为验证所提 Lite-Mamba 主干网络的改进效果, 在相同试验条件下, 分别使用 ResNet50、EfficientNetV2-S、MobileNetV3-Small、PVTv2-B2、Swin-T Tiny、EdgeNeXt-XXS、VMamba-Tiny 以及 Lite-Mamba 作为 LMA-DEIM 框架的主干网络进行试验。不同主干网络在 WSD 数据集上的性能如表 1 所示。

由表 1 可知, 采用 Lite-Mamba 主干网络的模型在密集粘连籽粒检测任务中表现最佳, $mAP@50$ 高达 92.0%, 检测速度为 143.1 f/s, 所有模型中检测速度最快, 同时显存占用量仅为 3.7 GB。表明 Lite-Mamba 主干网络具有强大的特征提取能力和优异的实时性, 适用于检测效率要求较高的应用场景。

表 1 不同主干网络性能试验结果

Tab.1 Performance test results of different backbone networks

主干网络	mAP@ 50/%	浮点运算量	参数量	检测速度/(f·s ⁻¹)	显存占用量/GB
ResNet50	86. 2	8. 10 ×10 ⁹	3. 56 ×10 ⁷	42. 1	7. 8
EfficientNetV2 – S	89. 7	2. 14 ×10 ¹⁰	4. 34 ×10 ⁷	103. 3	5. 9
MobileNetV3 – Small	76. 5	2. 30 ×10 ⁹	1. 54 ×10 ⁷	125. 4	4. 3
PVTv2 – B2	87. 9	6. 00 ×10 ⁹	3. 53 ×10 ⁷	48. 0	7. 2
Swin – T Tiny	89. 5	9. 50 ×10 ⁹	3. 83 ×10 ⁷	35. 2	8. 9
EdgeNeXt – XXS	83. 8	3. 25 ×10 ⁹	1. 56 ×10 ⁷	145. 8	3. 6
VMamba – Tiny	90. 1	7. 10 ×10 ⁹	3. 01 ×10 ⁷	112. 2	4. 6
Lite – Mamba	92. 0	6. 30 ×10 ⁹	1. 18 ×10 ⁷	143. 1	3. 7

3.3 消融试验

为验证 LMA – DEIM 模型中各改进模块的有效性,以 DEIM 框架为基线模型,依次增加 Lite – Mamba 主干网络、MIFI 特征交互模块以及 ADown 下采样模块,在 WSD 测试集上进行消融试验,结果如表 2 所示。由表 2 可知,在模型主干网络中引入 Lite – Mamba 模块,模型 mAP@ 50 相较于基线的 86.2% 显著提升 4.3 个百分点,达到 90.5%,同时参数量锐减 67%,检测速度提升 187%,验证了基于

选择性状态空间模型的轻量化主干在高效捕获全局依赖、区分密集粘连目标方面的突出优势。将 AIFI 模块替换为 MIFI 模块后,mAP@ 50 提升 1.0 个百分点,同时检测速度增加,表明 MIFI 模块以线性时间复杂度实现了更高效的特征交互,可有效替代原自注意力机制。引入 ADown 轻量化下采样模块,mAP@ 50 增加 0.6 个百分点,验证了通过优化下采样过程,能缓解特征图细节丢失,对提升粘连籽粒目标检测精度具有积极作用。

表 2 消融试验结果

Tab.2 Ablation experiment results

Lite – Mamba	MIFI	ADown	精确率/%	召回率/%	mAP@ 50/%	参数量	检测速度/(f·s ⁻¹)	显存占用量/GB
			88. 9	87. 5	86. 2	3. 56 ×10 ⁷	42. 1	7. 8
✓			91. 8	90. 2	90. 5	1. 44 ×10 ⁷	121. 0	3. 7
	✓		89. 5	88. 1	87. 2	3. 30 ×10 ⁷	72. 5	5. 1
		✓	89. 1	87. 8	86. 8	3. 58 ×10 ⁷	40. 5	7. 9
✓	✓		92. 3	91. 0	91. 4	1. 20 ×10 ⁷	136. 2	3. 5
✓		✓	92. 0	90. 5	91. 1	1. 21 ×10 ⁷	130. 5	3. 6
	✓	✓	89. 8	88. 3	87. 5	3. 32 ×10 ⁷	70. 8	5. 0
✓	✓	✓	92. 7	91. 5	92. 0	1. 18 ×10 ⁷	143. 1	3. 7

注:✓表示加入该模块。

当 Lite – Mamba 与 MIFI 模块结合使用时,模型在轻量化主干网络带来的高性能基础上,mAP@ 50 进一步提升 0.9 个百分点至 91.4%,检测速度也同步增长,说明高效主干与线性复杂度交互模块能产生显著的协同效应,共同优化特征提取与融合流程。而 Lite – Mamba 与 ADown 模块的组合,使模型在平均精度均值 mAP@ 50 (91.1%) 和检测速度 (130.5 f/s) 上均优于各自单独使用,表明改进的下采样策略能与先进的全局建模主干网络有效配合,进一步保障多尺度特征的完整性。

当全部 3 个改进共同集成到 DEIM 框架后,LMA – DEIM 实现了最佳性能。相较于原始基线模型,精确率、召回率与平均精度均值分别提升 3.8、4.0、5.8 个百分点,最终达到 92.7%、91.5% 和

92.0%。尽管模型显存占用量相比 Lite – Mamba 与 ADown 模块的组合略有增加,但参数量被控制在 1.18 ×10⁷,计算量大幅降低,参数量减少 66.9%,同时检测速度提升至 143.1 f/s,提高 240%。表明本文模块在显著提升模型精度的同时,实现了模型的轻量化与检测速度,使模型在精度、速度与计算量间达到了更优的平衡,满足在计算资源受限的嵌入式或移动设备上高通量、实时检测的部署需求。

3.4 不同目标检测模型性能

为验证模型有效性,选择主流目标检测模型与本文提出的 LMA – DEIM 模型进行对比试验,包括 YOLO 系列 (YOLO v5s、YOLO v8n、YOLO v8s、YOLO v10n、YOLO 11n、YOLO 12n)、DETR 系列 (DETR – ResNet50、RT – DETR – R18、RT – DETR – R50) 以及

两阶段模型 Faster R - CNN (ResNet50 - FPN)。试验在 WSD 数据集上进行,使用相同的训练和测试设置,试验结果如表 3 所示,训练过程验证集的 mAP 变化趋势如图 6 所示。

表 3 不同目标检测模型性能试验结果

Tab.3 Performance test results of different target detection models

模型	精确率/%	召回率/%	mAP@50/%	参数量	浮点运算量	检测速度/(f·s ⁻¹)	显存占用量/GB
Faster R - CNN	88.5	86.9	87.2	4.12×10^7	1.37×10^{11}	18.4	8.3
YOLO v5s	90.1	88.5	88.7	7.10×10^6	1.56×10^{10}	102.5	4.2
YOLO v8n	89.6	87.8	88.1	3.10×10^6	8.10×10^9	118.3	2.9
YOLO v8s	91.2	89.5	89.8	1.10×10^7	2.83×10^{10}	88.7	5.7
YOLO v10n	90.5	88.2	89.2	2.70×10^6	7.90×10^9	132.6	2.6
YOLO 11n	91.8	88.1	89.5	2.50×10^6	6.80×10^9	138.3	2.5
YOLO 12n	89.0	86.0	87.9	3.00×10^6	8.50×10^9	135.2	2.8
DETR - ResNet50	87.2	85.6	85.9	4.10×10^7	8.62×10^{10}	12.5	7.9
RT - DETR - R18	90.9	89.1	89.4	2.00×10^7	5.82×10^{10}	68.4	6.4
RT - DETR - R50	92.0	90.2	90.8	3.18×10^7	1.01×10^{11}	46.8	8.2
LMA - DEIM	92.7	91.5	92.0	1.18×10^7	6.30×10^9	143.1	3.7




图 6 mAP 变化曲线
Fig.6 Change curve of mAP

由表 3 可知,在检测精度方面,LMA - DEIM 模型在精确率、召回率和平均精度均值上均最优,分别为 92.7%、91.5% 和 92.0%。相较于两阶段模型 Faster R - CNN,LMA - DEIM 的 mAP@50 提升 4.8 个百分点,主要得益于端到端的检测范式避免了区域提议网络可能引入的定位误差,对密集籽粒目标更为友好。在 YOLO 系列模型中,YOLO 11n 的 mAP@50 最优 (89.5%),但相比 LMA - DEIM 仍低 2.5 个百分点,表明基于 CNN 的 YOLO 架构在处理

高度密集和严重粘连的小麦籽粒时,其依赖 NMS 后处理机制仍可能导致重叠目标的误抑制。在基于 Transformer 的模型中,RT - DETR - R50 mAP@50 为 90.8%,证明了全局注意力机制在建模目标间复杂关系上的优势。LMA - DEIM 在继承 DEIM 框架端到端检测优势的基础上,通过引入 Lite - Mamba 和 MIFI 等模块,进一步将 mAP@50 提升 1.2 个百分点,达到了所有模型中最高水平。

在模型效率与实时性方面,LMA - DEIM 同样展现出卓越性能,检测速度达到 143.1 f/s,为所有模型中最快,相比次快的 YOLO 11n 提升 3.5%,相比 YOLO v8n 提升 21%。与此同时,LMA - DEIM 的浮点运算量仅为 6.30×10^9 ,显著低于同精度级别的模型。在模型复杂度方面,LMA - DEIM 参数量为 1.18×10^7 ,虽高于 YOLO v8n、YOLO v10n、YOLO 11n 等极致轻量化版本,但远低于两阶段模型和大型 DETR 模型,在精度与模型参数量间取得了良好平衡。显存占用量 3.7 GB 也处于较低水平,满足边缘设备的部署限制。LMA - DEIM 在保持最高检测精度的同时,实现了最快的检测速度,为高通量、实时小麦籽粒检测任务提供了理想的技术方案。

综合来看,LMA - DEIM 模型在密集粘连小麦籽粒检测任务中,实现了精度与速度的最佳平衡。与当前主流的目标检测模型相比,在检测精度、检测速度、计算复杂度等方面均展现出显著优势,验证了模型设计的有效性与先进性,特别适合于在计算资源受限的嵌入式或移动平台上进行高通量、实时籽粒检测与计数。

3.5 Lite - Mamba 热力图可视化

为直观评估 Lite - Mamba 主干网络在密集粘连籽粒检测任务中特征区分能力,引入 Grad - CAM + + 算

法,对模型在输入图像上的关注区域进行可视化分析。在原始 DEIM 框架基础上,将 ResNet50 主干网络替换为本文提出的 Lite - Mamba,并基于相同输入图像生成对应的类别激活热力图,结果如图 7 所示。由图 7 可知,采用 Lite - Mamba 的主干网络在密集籽粒区域所产生的激活响应,更集中分布于籽粒中心区域,籽粒间邻接边缘的响应较弱,边缘更加

锐化,边界区分度显著提高。相比之下,基于 ResNet50 的原始 DEIM 框架在籽粒边缘处呈现较强的激活响应,很容易弥散至邻接边界,易导致模型在分割粘连籽粒时混淆相邻目标,从而增大漏检与误检的概率。Lite - Mamba 主干网络能更有效地对独立籽粒的实体特征进行建模,抑制粘连区域干扰,进而提升检测鲁棒性与精度。




图 7 Grad - CAM + + 热力图可视化
Fig. 7 Grad - CAM + + heatmap visualization

3. 6 检测结果可视化

为直观对比不同模型检测性能,采用 Faster R - CNN、YOLO 11n、RT - DETR 及本文 LMA - DEIM 模型对测试集进行测试,选取其中 1 幅包含 342 粒籽粒的重度粘连籽粒图像,如图 8 所示。试验统计显示,4 种模型漏检籽粒数依次为 5、4、1、

1,错检(即将多个粘连籽粒误检为单个目标)数分别为 5、3、4、1 粒,计数误差分别为 - 10、- 7、- 6、- 2 粒。本文 LMA - DEIM 模型在漏检、错检数目与计数误差上均为最低,表明在严重粘连场景下具有更优的检测准确性与鲁棒性,验证了本文方法的有效性。




图 8 检测结果可视化
Fig. 8 Visualization of detection results

3. 7 计数准确率试验

为评估 LMA - DEIM 模型在密集粘连小麦籽粒计数任务上的精度与鲁棒性,在未参与训练的测试集上进行计数准确率试验。为全面量化模型

性能,采用决定系数(R^2)、平均绝对误差(MAE)、平均相对误差(MRE)和平均推理耗时作为评价指标。从原始测试集中构建一个更具挑战性的高密度测试子集,包含 100 幅图像,所选样本的籽粒数

量均超过 300,且在粘连程度、背景复杂度方面均显著高于测试集平均水平,旨在模拟高通量检测的极端工况,可更有效地验证模型在实际复杂环境下性能极限。

采用 Faster R - CNN、YOLO 11n、RT - DETR 及本文 LMA - DEIM 模型,对高密度测试子集进行试验。通过统计每幅图像中检测框的数量,并作为预测籽粒数,与真实标注数目进行对比分析。各模型预测结果与真实标注结果如图 9 所示,相应的计数性能指标如表 4 所示。




图 9 预测与真实籽粒数关系

Fig.9 Relationship between prediction and real grain number

表 4 各模型籽粒计数指标

模型	R^2	MAE/粒	MRE/%	平均推理耗时/ms
Faster R - CNN	0.820 2	47.59	8.84	243.76
YOLO 11n	0.886 5	36.51	6.48	23.29
RT - DETR	0.915 2	32.68	5.85	48.12
LMA - DEIM	0.973 5	17.41	3.08	12.45

由图 9、表 4 可知,LMA - DEIM 模型在高密度籽粒计数任务中,取得了全面且显著优于其他主流模型的性能。LLA - DEIM R^2 高达 0.973 5,表明籽粒数量预测与真实值具有极高的线性相关性和一致性。MAE 为 17.41 粒,MRE 低至 3.08%,在所有模型中均表现最佳。证明改进模型在极端密集粘连场景下,仍能保持极高的检测完整性与计数准确性。此外,平均推理耗时为 12.45 ms,体现了模型轻量化设计的成功,将基于状态空间模型的高效全局建模能力与 DEIM 框架的端到端效率结合,实现了精度与速度的平衡。

3.8 嵌入式设备部署

为增强模型的工程应用价值,基于 Python 语言与 Django 框架,设计了小麦检测与计数 WEB 系统,部署于 Raspberry Pi 5 嵌入式平台,集成显示屏、高拍仪等转化为便携式计数系统,如图 10 所示。在输入图像分辨率为 640 像素 × 640 像素时,模型检测速度达到 62 f/s,可满足高通量实时计数需求,适宜

集成在千粒重等设备中实现计数功能的扩展,具有较高的实用价值。




图 10 便携式计数系统

Fig. 10 Portable counting system

1. 显示屏 2. Raspberry Pi 5 开发板 3. 小麦籽粒样本 4. 高拍仪 5. 小麦检测与计数系统

在此基础上集成开发了一套计数称量系统,并在实际工程应用中得到了使用和验证,如图 11 所示。




图 11 计数称重系统

Fig. 11 Counting and weighing equipment system

developed by team

1. RK3588 工控主机 2. 高拍仪 3. 电子天平 4. 小麦籽粒样本及托盘

4 讨论

尽管提出的 LMA - DEIM 模型在高通量小麦籽粒目标检测与计数任务上展现了优越的性能,有效解决了小麦育种计数中面临的密集粘连计数不准、终端部署算力不足、实时响应差等核心工程问题,实现了高通量、高精度的籽粒计数,为自动化考种的效率提升奠定了基础。但在面向精细考种应用和更高级视觉任务时,仍存在一定局限。一方面,从计数到精准考种仍存在差距,本研究目前主要实现了籽粒的快速、准确计数,这只是考种工作的第一步;然而,完整的考种分析还需要获取每颗籽粒的形态(如长、宽、长宽比、投影面积、粒形等)、色泽、饱满度/均匀度、硬度、容量和纹理等精细表型参数;当前基于目标检测框(Bounding box)模型仅提供籽粒的

近似位置,无法提供精确的轮廓信息,因此难以直接用于籽粒形态指标的精准测量,限制了模型在品种鉴定、品质分级等需要高精度性状分析场景下的直接应用能力。另一方面,对重叠与极端密集区域的计数仍存在偏差,虽然 LMA - DEIM 模型对中度粘连籽粒的区分能力较强,但在籽粒极度密集、多层重叠的极端情况下,检测框之间仍可能出现无法避免的重合或漏检,导致计数结果出现微小偏差,对于要求绝对精确的千粒重推算的初始计数场合,可能仍需少量人工校正。

将模型从目标检测推广到实例分割,以获取每个籽粒的像素级精确掩膜,是一个自然且需求迫切的方向,但面临本质性挑战:①方法架构的局限,LMA - DEIM 核心优化在于特征提取与目标检测头,输出形式是边界框和类别得分,直接将其转换为实例分割输出并非易事。典型的实例分割架构(如 Mask R - CNN)在检测头后需引入一个并行的掩膜头,需对每个感兴趣区域进行像素级预测。LMA - DEIM 中用于区分粘连的注意力机制和上下文建模模块对框的区分有效,但直接生成高质量、边界清晰的掩膜,尤其是对于粘连边界,需要重新设计和大量训练。②粘连边界分割的精度问题,即使推广成功,模型在分割紧密粘连籽粒时性能预计将显著低于检测性能。目标检测允许边界框存在一定重叠,而实例分割必须精确界定粘连处的像素归属,需要模型具备更强大的底层特征分辨能力和语义边缘感知能力,而这可能超出了当前 LMA - DEIM 设计的主要优化目标。初步推断,在粘连严重的区域,分割结果的边界准确度和 IoU 值可能会下降。最后仍需要权衡数据与计算成本。实例分割需要像素级标注的训练数据,制作成本远高于边界框标注。此外,掩膜预测会增加模型的计算量,可能影响“高通量”处理的速度优势。

基于以上讨论,未来研究可沿以下路径深化:①开发 LMA - DEIM - Seg 变体,设计兼容的掩膜预测头,构建端到端的“检测-分割”联合模型,并利用

实例分割数据微调,系统评估在籽粒分割任务上的性能极限。②探索弱监督与交互式分割,利用当前检测模型输出的框作为初始提示,结合弱监督学习或交互式分割算法,以较低成本生成籽粒掩膜,为考种应用提供实用工具。③开发融合多任务考种框架,构建一体化多任务模型,能够从图像中同时输出籽粒数量、精确轮廓、形态参数和病害斑点等信息,真正实现全自动智能化考种。

5 结 论

(1)针对密集粘连小麦籽粒检测数据缺乏的问题,构建了涵盖多个品种、复杂背景与高密度目标的 WSD 数据集,为模型训练与评估提供了高质量基准。

(2)提出了轻量化密集粘连小麦籽粒检测模型 LMA - DEIM,基于 DEIM 框架,引入轻量化主干网络 Lite - Mamba 以及线性计算复杂度实现全局特征建模,增强对密集粘连籽粒的区分能力;基于选择性状态空间的 MIFI 模块替换原有 AIFI 模块,在降低计算复杂度的同时实现高效特征交互;加入轻量化下采样模块 ADown,有效缓解下采样过程的细节信息丢失,从而在保持高精度的同时显著提升模型效率。

(3)改进模型在 WSD 测试集上精确率、召回率与 mAP@50 分别达到 92.7%、91.5% 和 92.0%,参数量仅为 1.18×10^7 ,检测速度达 143.1 f/s。与主流检测模型相比,在精度、速度与轻量化水平上均取得显著提升,尤其在高密度粘连场景下计数平均相对误差低至 3.08%,满足嵌入式设备对高通量、实时籽粒检测的需求。

(4)通过对重度粘连样本的可视化检测结果与计数试验分析,LMA - DEIM 在漏检、错检与计数误差上均优于其他模型,表现出更强的鲁棒性和场景适应性,验证了模型在复杂密集粘连条件下的有效性与实用性,为小麦高通量自动计数提供了可靠的轻量化端侧部署方案。

参 考 文 献

[1] 尚书旗,吴秀丰,杨然兵,等. 小区育种播种装备与技术研究现状与展望[J]. 农业机械学报,2021,52(2):1 - 20.
Shang Shuqi, Wu Xiufeng, Yang Ranbing, et al. Research status and prospect of plot-sowing equipment and technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(2):1 - 20. (in Chinese)

[2] 宋初苏,华娇,蓝景针,等. 转盘斜刮式光电自动数粒仪设计[J]. 农业机械学报,2011,42(11):89 - 92,75.
Song Rengsu, Hua Jiao, Lan Jingzhen, et al. Design of turntable-inclined scratch style photoelectric instrument to automatically count granules[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(11):89 - 92,75. (in Chinese)

[3] 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)

[4] 梁宁. 基于机器视觉与深度学习的高通量种子识别与分割方法研究[D]. 杭州:浙江大学,2023.
Liang Ning. High-throughput seed recognition and segmentation based on machine vision coupled with deep learning[D].

- Hangzhou: Zhejiang University, 2023. (in Chinese)
- [5] 周麟, 武威, 刘涛, 等. 稻麦籽粒计数方法研究现状及展望[J]. 现代农业科技, 2020(12): 18-20, 22.
Zhou Lin, Wu Wei, Liu Tao, et al. Research status and prospect of rice and wheat grain counting methods[J]. Modern Agricultural Science and Technology, 2020(12): 18-20, 22. (in Chinese)
- [6] Tu K, Wu W, Cheng Y, et al. Alseed: an automated image analysis software for high-throughput phenotyping and quality non-destructive testing of individual plant seeds[J]. Computers and Electronics in Agriculture, 2023, 207: 107740.
- [7] 宋鹏, 张晗, 王成, 等. 玉米籽粒考种信息获取装置设计与试验[J]. 农业机械学报, 2017, 48(12): 19-25.
Song Peng, Zhang Han, Wang Cheng, et al. Design and experiment of maize kernel traits acquisition device[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 19-25. (in Chinese)
- [8] Liu T, Chen W, Wang Y, et al. Rice and wheat grain counting method and software development based on Android system[J]. Computers and Electronics in Agriculture, 2017, 141: 302-309.
- [9] 权龙哲, 辛伯来, 奚德君, 等. 粘连玉米粒群的分水岭分割与粒形的多尺度小波校正算法研究[J]. 中国科技论文, 2016, 11(2): 191-196.
Quan Longzhe, Xin Bolai, Xi Dejun, et al. Automatic segmentation method of touching corn kernels in digital image based on improved watershed algorithm[J]. China Sciencepaper, 2016, 11(2): 191-196. (in Chinese)
- [10] 柳冠伊, 刘平义, 魏文军, 等. 玉米果穗粘连籽粒图像分割方法[J]. 农业机械学报, 2014, 45(9): 285-290.
Liu Guanyi, Liu Pingyi, Wei Wenjun, et al. Method of image segmentation for touching maize kernels[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(9): 285-290. (in Chinese)
- [11] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1-17.
Lu Hongtao, Zhang Qinchuan. Applications of deep convolutional neural network in computer vision[J]. Journal of Data Acquisition and Processing, 2016, 31(1): 1-17. (in Chinese)
- [12] 沈夏炯, 吴晓洋, 韩道军. 分水岭分割算法研究综述[J]. 计算机工程, 2015, 41(10): 26-30.
Shen Xiajiong, Wu Xiaoyang, Han Daojun. Survey of research on watershed segmentation algorithms[J]. Computer Engineering, 2015, 41(10): 26-30. (in Chinese)
- [13] Dargan S, Kumar M, Ayyagari M R, et al. A survey of deep learning and its applications: a new paradigm to machine learning[J]. Archives of Computational Methods in Engineering, 2020, 27(4): 1071-1092.
- [14] Wang X, Wu Z Jia M, et al. Lightweight SM-YOLO v5 tomato fruit detection algorithm for plant factory[J]. Sensors, 2023, 23(6): 3336.
- [15] Han K, Wang Y, Chen H, et al. A survey on vision transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(1): 87-110.
- [16] 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)
- [17] Ma N, Su Y, Yang L, et al. Wheat seed detection and counting method based on improved YOLO v8 model[J]. Sensors, 2024, 24(5): 1654.
- [18] 高杨, 曹仰杰, 段鹏松. 神经网络模型轻量化方法综述[J]. 计算机科学, 2024, 51(增刊 1): 23-33.
Gao Yang, Cao Yangjie, Duan Pengsong. Lightweighting methods for neural network models: a review[J]. Computer Science, 2024, 51(S1): 23-33. (in Chinese)
- [19] 邹强, 宋欣, 宋中越, 等. 基于残差连接的轻量化番茄作物病害检测模型[J]. 农业机械学报, 2026, 57(1): 140-148.
Zou Qiang, Song Xin, Song Zhongyue, et al. Lightweight tomato crop disease detection model based on residual connections[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(1): 140-148. (in Chinese)
- [20] 刘祥, 项若雪, 班成龙, 等. 基于改进 YOLO v8 的轻量化棉铃识别模型与产量预测方法研究[J]. 农业机械学报, 2025, 56(5): 130-140.
Liu Xiang, Xiang Ruoxue, Ban Chenglong, et al. Lightweight cotton boll detection model and yield prediction method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5): 130-140. (in Chinese)
- [21] 杨森森, 张昊, 兴陆, 等. 改进 MobileViT 网络识别轻量化田间杂草[J]. 农业工程学报, 2023, 39(9): 152-160.
Yang Sensen, Zhang Hao, Xing Lu, et al. Light weight recognition of weeds in the field based on improved MobileViT network[J]. Transactions of the CSAE, 2023, 39(9): 152-160. (in Chinese)
- [22] Zou Z, Chen K, Shi Z, et al. Object detection in 20 years: a survey[J]. Proceedings of the IEEE, 2023, 111(3): 257-276.
- [23] Bodla N, Singh B, Chellappa R, et al. Soft-NMS—improving object detection with one line of code[C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 5561-5569.
- [24] Shehzadi T, Hashmi K A, Liwicki M, et al. Object detection with transformers: a review[J]. Sensors, 2025, 25(19): 6025.
- [25] Huang S, Lu Z, Cun X, et al. Deim: detr with improved matching for fast convergence[C] // Proceedings of the Computer Vision and Pattern Recognition Conference, 2025: 15162-15171.
- [26] Gu A, Dao T. Mamba: linear-time sequence modeling with selective state spaces[C] // First Conference on Language Modeling, 2024.
- [27] Liu Y, Tian Y, Zhao Y, et al. Vmamba: visual state space model[J]. Advances in Neural Information Processing Systems, 2024, 37: 103031-103063.
- [28] Wang C Y, Yeh I H, Mark L H Y. YOLOv9: learning what you want to learn using programmable gradient information[C] // European Conference on Computer Vision, 2024: 1-21.