

基于 EISW-YOLOv8n 的预制薯条外观缺陷检测方法

李健佳^{1,2} 王永强^{1,2} 周聪玲^{1,2} 王昊^{1,2}

(1. 天津市轻工与食品工程机械装备集成设计与在线监控重点实验室,天津 300457;
2. 天津科技大学机械工程学院,天津 300457)

摘要:[目的]解决传统预制薯条生产中残次品人工检测速度慢、效率低,易漏检、误检的问题,提高缺陷残次品的识别准确度和速度,保证安全生产。**[方法]**提出了一种基于 YOLOv8n 改进的识别算法 EISW-YOLOv8n。通过在网络中引入 EMCA 通道注意力机制,突出重要通道信息;为了提高模型对特征的提取能力以及捕获特征中的长距离依赖关系的能力,在 C2f 模块中引入由 SWC 卷积优化过的 iRMBS 模块;引入 WIOU 损失函数,增强预测框的定位精度以及模型的收敛速度。**[结果]**提出的模型对于预制薯条缺陷检测的平均精度达到 94.3%。与原始 YOLOv8n 模型以及常见的目标检测算法相比,该网络表现出了优越的性能。**[结论]**EISW-YOLOv8n 能够满足识别预制薯条的表面缺陷的需求。

关键词:预制薯条;缺陷识别;目标检测;YOLOv8

An appearance defect detection method for pre-fried potato chips based on EISW-YOLOv8n

LI Jianjia^{1,2} WANG Yongqiang^{1,2} ZHOU Congling^{1,2} WANG Hao^{1,2}

(1. Tianjin Key Laboratory of Integrated Design and On-line Monitoring for Light Industry and Food Machinery and Equipment, Tianjin 300457, China; 2. College of Mechanical Engineering, Tianjin University of Science & Technology, Tianjin 300457, China)

Abstract: [Objective] To address the low speed and efficiency as well as missed and false detection in manual inspection of defective products in pre-fried potato chip production, enhance the accuracy and speed of product defect identification, and ensure safe production. [Methods] An improved recognition algorithm, EISW-YOLOv8n, based on YOLOv8n is proposed. Firstly, the efficient multiscale channel attention (EMCA) mechanism is introduced into the network to highlight important channel information. Secondly, to improve the model ability to extract features and capture long-distance dependencies within features, the iRMBS module, optimized by SWC convolution, is introduced into the C2f module. Finally, the loss function WIOU is introduced to enhance the localization accuracy of the prediction box and the convergence speed of the model. [Results] The proposed model achieves the average precision of 94.3% for defect detection in pre-fried potato chips. Compared with the original YOLOv8n model and common object detection algorithms, this network demonstrates superior performance. [Conclusion] EISW-YOLOv8n can meet the requirements for identifying appearance defects in pre-fried potato chips.

Keywords: pre-fried potato chips; defect recognition; object detection; YOLOv8

市场上现有的薯条产品为工厂经过初步油炸后冷冻的预制薯条。在预制薯条的生产过程中,马铃薯原料的品质差异以及加工工艺的影响,致使薯条易出现绿斑、黑斑等表面缺陷。传统的预制薯条外观缺陷残次品检测是通

基金项目:天津市自然科学基金—青年项目(编号:23JCQNJC01170)

通信作者:王永强(1965—),男,天津科技大学教授,硕士。E-mail: wangyq@tust.edu.cn

收稿日期:2025-01-02 **改回日期:**2025-08-19

引用格式:李健佳,王永强,周聪玲,等.基于 EISW-YOLOv8n 的预制薯条外观缺陷检测方法[J].食品与机械,2025,41(11):84-90.

Citation:LI Jianjia, WANG Yongqiang, ZHOU Congling, et al. An appearance defect detection method for pre-fried potato chips based on EISW-YOLOv8n[J]. Food & Machinery, 2025, 41(11): 84-90.

过人工目测筛选,不仅费时费力、主观性大,而且容易发生误检和漏检。近年来,机器视觉已被越来越多地应用于食品以及农产品的生产、加工中代替人工进行相关工作。

早期的机器视觉主要根据颜色、形状、纹理等特征,通过阈值分割、K近邻分类、支持向量机(SVM)、随机森林等方法进行目标的检测识别。Leemans等^[1]提取出苹果缺陷的颜色、形状、纹理特征,使用K均值聚类的方法对存在缺陷的苹果进行了分级,准确率达到73%。吴陈陈等^[2]基于机器视觉设计了一套青豆自动化在线筛选系统,实现了残次品青豆的在线筛选和剔除。Blasco等^[3]提出了一种基于区域的分割算法,该法可以准确地检测出95%的柑橘类水果的果皮缺陷。向宇航等^[4]利用机械梳理装置将鲍鱼风味片整理成单层阵列排布采集图像,使用图像分割、边缘提取等方法进行图像处理,解决了鲍鱼风味片在生产过程中出现的边缘残损、内部气孔以及皮料厚度不均匀等外观缺陷自动化检测问题。以上研究均为传统机器学习方法在食品以及农产品的生产、加工中的缺陷检测、分类的应用。传统机器学习方法大多依赖人工进行特征的提取,泛化能力低,且易受光照等环境因素影响,鲁棒性不强,局限性大。

而深度学习技术通过自动学习有效特征,展现出更强的泛化能力和鲁棒性,近年来被广泛应用于农业、食品产业中。基于深度学习的目标检测算法,根据检测阶段的数量不同,目标检测模型主要有两类,一类是以基于区域的卷积神经网络(R-CNN)、更快的区域卷积神经网络(Faster R-CNN)等为代表的两阶段检测算法,另一类是以单次多边框检测器(SSD)和单次检测法(YOLO)系列为代表的一阶段目标检测算法^[5-7],相比两阶段检测算法一阶段算法不再需要生成候选框,直接将边框问题转化为回归问题,能够对多个目标的位置和类别进行快速的检测,准确率高且满足实时检测的需求。如:Pang等^[8]将高光谱成像与YOLOv3结合实现了对苹果碰伤的检测,F1分数(F1-score)为100%,每秒帧数(FPS)为68;高鹏翔^[9]应用深度学习算法,通过改进yolov5网络,开发了一种胡萝卜表面缺陷在线检测系统,实现了胡萝卜表面缺陷实时检测;Liu等^[10]为了提高机器人采摘番茄的效率,使用YOLOv3模型对温室中的番茄植株进行成熟和未成熟的番茄检测,平均精度达到了89.56%。

基于深度学习算法的农产品、食品的检测、分类,不仅无损、高效,而且精度高,节省了大量的人力物力,为农产品、食品加工产业的发展注入了新的动力。而在目标检测领域YOLO系列算法具有显著的优势,为了解决在预制薯条生产中人工筛选外观残次品效率低、易漏检等问题,研究拟提出一种基于YOLOv8n改进的缺陷检测算法。

1 材料与方法

1.1 数据集制作

预制薯条样品来自天津市轻工与食品工程机械装备集成设计与在线监控重点实验室。图像拍摄背景模拟实际生产,在滚动传送机械设备上进行拍摄,其背景主要为两个白色滚子,同时考虑到实际生产中会出现光照、噪声等环境因素的影响,所以在拍摄图像后通过调整图像的灰度值使其处于50~200改变图像光照条件以及添加高斯噪声,均值设定范围为0~5,标准差设定范围为1~50,该措施不仅可以防止模型训练过拟合,还可以提高模型检测分类的性能。整个数据集包含1 090张图像,其中包含黑斑缺陷实例个数1 362个、绿斑缺陷实例个数427个,缺陷种类如图1所示。数据集按照8:2比例划分训练集、验证集,进行模型训练。

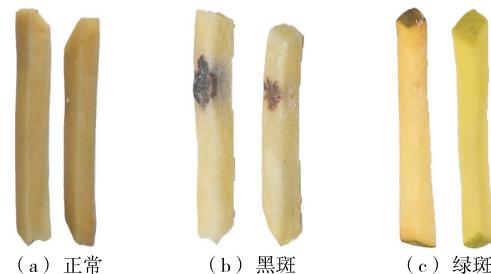


图1 预制薯条种类

Figure 1 Types of pre-fried potato chips

1.2 目标缺陷检测模型

YOLO系列算法是经典的一阶段目标检测算法,YOLOv8相比以往的版本具有更先进的性能,检测精度和速度有很好的平衡。但是由于样本数据集预制薯条的缺陷目标多尺度、形状不规则且小目标较多的特点,原始YOLOv8n模型的检测效果并不理想。为了解决YOLOv8n模型中存在的问题,提高其针对缺陷检测的准确性,提出了一种改进YOLOv8n模型EISW-YOLOv8n。首先在YOLOv8n的快速空间金字塔池化模块(SPPF)中引入高效多尺度通道注意力模块(EMCA)注意力机制,增强模型对于重要通道特征的关注度。其次在YOLOv8n的Neck部分3个C2f模块中引入多尺度移位卷积倒置残差移动模块(iRMBS),增强模型对于不同层级特征的提取、融合能力。最后将加权交并比损失函数(WIOU)引入模型,提高模型的收敛速度和定位精度。图2为改进后的EISW-YOLOv8n结构示意图。

1.2.1 嵌入EMCA注意力机制 注意力机制可以帮助网络提高重要信息的关注度。EMCA注意力机制是一种轻量高效的通道注意力机制,在ECA注意力^[11]的基础上,增加了对输入特征的全局最大池化操作,并将两种池化结果进行了拼接。图3为EMCA结构图。

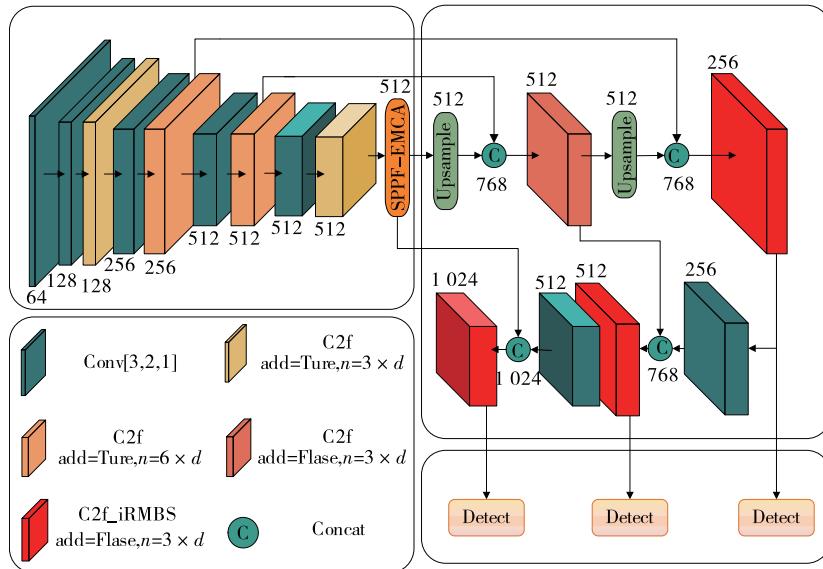


图 2 EISW-YOLOv8n 网络结构示意图

Figure 2 Schematic diagram of EISW-YOLOv8n network structure

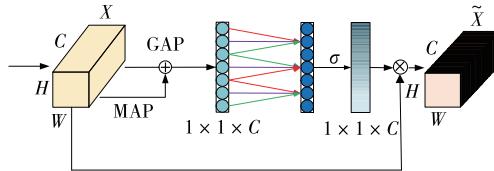


图 3 EMCA 注意力机制结构图

Figure 3 Structure of the EMCA mechanism

输入到 EMCA 注意力机制中的特征图首先分别进行全局平均池化操作和全局最大池化操作将维数从 $H \times W \times C$ 压缩至 $1 \times 1 \times C$, 然后将两种池化得到的特征图进行拼接, 增强了特征的全局视角信息和不同大小尺度的特征。拼接后特征图与自适应计算得到的卷积核大小为 k 的一维卷积进行卷积, 并经过 σ (Sigmoid) 激活函数得到自适应调整后特征图的每个通道的权重向量 ω , 在增加极少计算成本的情况下, 高效地捕获了跨通道的信息交互, 提取通道间的依赖关系, 提高模型对于重要特征的关注度。其中卷积核大小和权重向量计算如式(1)、式(2)所示。

$$k = \Psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} - \frac{b}{\gamma} \right\rfloor_{\text{odd}}, \quad (1)$$

$$\omega = \text{Sigmoid}(D_k(x)), \quad (2)$$

式中:

k —卷积核大小;

C —通道维度;

$\Psi(\cdot)$ —卷积核计算方法;

$|t|_{\text{odd}}$ —最接近 t 的奇数;

γ —线性比例系数, 取 2;

b —偏置量, 取 1;

ω —权重向量;

Sigmoid—激活函数;

D —一维卷积;

x —输入通道。

由式(1)可以看出, k 值大小通过通道尺寸的非线性映射来自适应确定, 维度高的通道具有更长范围的交互作用, 内核大小 k 体现出了局部跨通道交互的覆盖范围, 即有多少邻居参与了一个通道的注意力预测。将归一化权重向量和初始输入特征图逐通道相乘, 生成最终加权后的特征图。

EMCA 注意力机制可以增强 SPPF 模块中多尺度融合特征的通道表示, 使网络更好地关注小目标缺陷, 并更有效地利用重要的通道特征。由于 EMCA 注意力机制仅有极少的参数, 所以在不增加网络复杂程度、不降低计算速度的前提下, 提高了小目标的检测性能。

1.2.2 多尺度移位卷积倒置残差移动模块 iRMB 倒置残差移动模块是 EMO^[12] 模型的关键组成模块, 其结构如图 4 所示。特征输入该模块后, 首先会对输入特征进行通道维度的扩展, 通道扩展之后会通过高效多头自注意力机制(EW-MHSA)和深度可分离卷积(DW-Conv)^[13] 的级联结构有效提高模型感受野的扩张速度, 最后收缩通道维度将特征进行输出, 并且在其中使用了残差连接。EW-MHSA 注意力和 DW-Conv 卷积的级联结构的使用使 iRMB 模块中每个组件的通道数减半, 降低了模型的计算量, 并且同时具备 CNN 的静态短程建模能力和 Transformer 的动态长程特征交互能力。

为了进一步提高 iRMB 倒置残差移动模块的特征提取能力以及捕获特征中的长距离依赖关系的能力, 将移



图 4 iRMB 模块结构示意图

Figure 4 Schematic diagram of the structure of iRMB module

位卷积网络(Shift-ConvNet)中提出的一种稀疏组移位小卷积核的卷积操作方法(SWC卷积)引入到iRMB模块中,构建多尺度移位卷积倒置残差移动模块iRMBS。

为了达到大型卷积的效果且不过多地增加计算成本,SWC卷积操作设计使用了一种shift-wise运算操作,shift-wise将大卷积核转化为一些小卷积核,然后对每个小卷积核做出移位操作,如图5所示,并且shift-wise通过修剪操作减少计算成本,获得大核卷积的稀疏依赖性。通过这种运算操作可以扩大模型的感受野,捕获长距离依赖关系,进行远程的特征融合,提高模型的多尺度特征融合能力,达到大卷积核的效果。

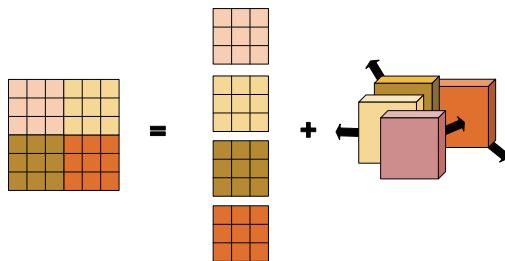


图 5 shift-wise 运算操作示意图

Figure 5 Schematic diagram of shift-wise operations

将SWC卷积操作融入iRMB倒置残差移动模块中,其结构图如图6所示,将iRMB中的DW-Conv变为SWC卷积,构成多尺度移位卷积倒置残差移动模块iRMBS。将iRMBS模块引入颈部网络中3个负责输出特征进行预测结果的C2f模块中构成C2f_iRMBS模块。C2f_iRMBS模块相比原C2f模块更加轻量化,并且增加了模型的感受野,使模型不仅可以有效提取局部特征、更深层特征,而且可以有效地捕获特征中的长程依赖关系,提高模型对于全局上下文信息的处理能力和模型对于多尺度特征的提取、融合能力。

1.2.3 WIOU边框损失函数 YOLOv8n目标检测任务损失函数主要包括两个方面:分类损失(BCE Loss)和回归损失(CIOU Loss+DFL Loss)。传统的边框损失函数更

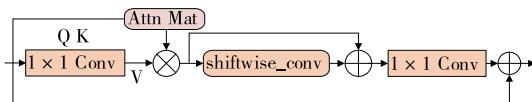


图 6 iRMBS 模块结构图

Figure 6 Structure of iRMBS module

加注重强化边界框损失的拟合能力,忽略了训练数据中低质量示例对模型的危害。由此在EISW-YOLOv8n网络模型中应用了WIOU损失函数,其公式如式(3)~式(5)所示,计算示意图如图7所示。

$$R_{\text{WIOU}} = \exp \left[\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \right], \quad (3)$$

$$L_{\text{WIOUv1}} = R_{\text{WIOU}} L_{\text{IOU}}, \quad (4)$$

$$L_{\text{WIOUv2}} = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \right)^\gamma L_{\text{WIOUv1}}, \quad \gamma > 0, \quad (5)$$

式中:

x —预测框中心点横坐标;

y —预测框中心点纵坐标;

x_{gt} —真实框中心点横坐标;

y_{gt} —真实框中心点纵坐标;

$\exp()$ —自然指数函数;

W_g 和 H_g —真实框A和预测框B的最小包围框的宽和高;

$R_{\text{WIOU}} \in [1, e]$ —WIOU高质量锚框损失;

$L_{\text{IOU}} \in [0, 1]$ —预测框B和真实框A交并比的损失;

L_{WIOUv1} —WIOUv1损失;

γ —增益比例系数;

L_{IoU}^* —针对交叉熵的单调聚焦机制构造的单调聚焦系数;

$\overline{L_{\text{IoU}}}$ —具有动量系数 m 的滑动平均值;

L_{WIOUv2} —WIOUv2损失。

R_{WIOU} 和 L_{IOU} 会减弱高质量锚框损失同时提高普通质量锚框损失,并在锚框与真实框重合较好时提高模型对锚框和真实框中心点距离的关注。式(5)中上标*表示在反向传播时将 W_g 和 H_g 从计算中分离,可以有效防止模型不收敛。 L_{IoU}^* 可以有效降低简单示例对损失值的贡献,使模型能够聚焦于困难实例, $r = \left(\frac{L_{\text{IoU}}^*}{\overline{L_{\text{IoU}}} \cdot \overline{L_{\text{IoU}}}^*} \right)^\gamma$ 帮助模型在训练后期加快收敛。

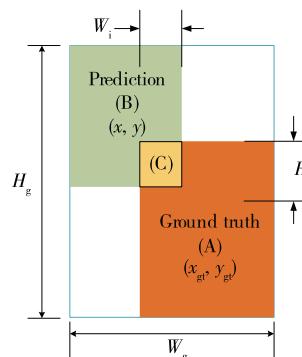


图 7 损失函数计算示意图

Figure 7 Schematic diagram of loss function calculation

通过将 YOLOv8n 中 CIOU 损失函数替换为 WIOU 损失函数,平衡了低质量锚框与高质量锚框之间的惩罚力度,降低了低质量示例对模型的影响,提高了模型的泛化能力,更好地解决样本不平衡问题,同时提高模型的收敛速度和检测框的定位精度。

2 结果与讨论

2.1 试验环境与评价指标

模型训练基于 pytorch 2.0.0 深度学习框架,开发语言 Python 3.10.13, 训练环境为 Windows 11 操作系统,CUDA12.0,硬件配备 NVIDIA GeForce RTX 4060 GPU(8 G 显存),inter(R) Core(TM) i7-13650HX (2.60 GHz) CPU(16 G 内存)。模型训练参数见表 1,为了保证模型充分收敛训练轮数设置为 200,同时为了防止模型的过度拟合,将模型的早停轮数设置为 50。训练参数中批次大小和线程数为模型读取训练数据的设置,在设备性能允许的情况下批次大小和线程数设置参数越大模型的训练速度越快,由于设备的限制设置批次大小和线程数分别为 32 和 4。表 1 中图像大小参数表示输入模型的图像尺寸,该参数依据实际图像采集大小设定,而优化器设置选择 SGD 优化器,该优化器计算效率高可以帮助模型快速收敛到损失函数的最小值。

表 1 模型训练参数

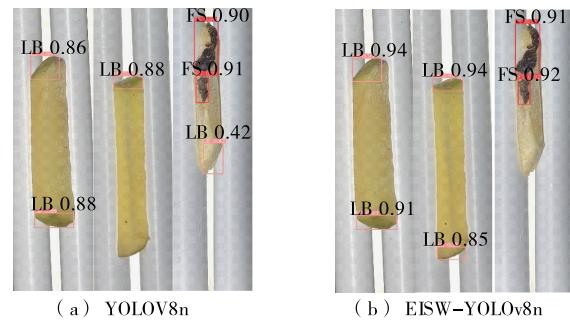
Table 1 Model training parameters

参数	数值	参数	数值
训练轮数	200	训练批次	32
早停轮数	50	图像大小	640×640
线程数	4	优化器	SGD

为了评估模型的性能,使用精确率(P)、召回率(R)、平均精度值(mAP)作为指标来反映模型的检测精度,这些指标参照文献[9]进行计算。

2.2 模型检测效果分析

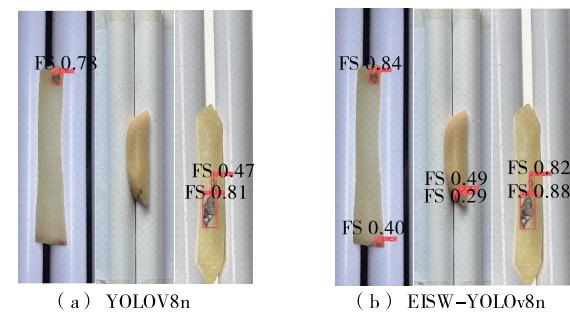
改进后的 EISW-Yolov8n 模型检测精确率、召回率、真实框和预测框交并比为 0.5 时的模型平均精度值(mAP50)分别达到了 0.929, 0.895, 0.943。为了展示缺陷检测效果以及改进模型相对于原始模型的先进性,在测试集中随机选取图像,比较使用原始模型和改进模型的检测效果,如图 8~图 10 所示。由图 8 可以看出,改进后的模型对于较为明显的绿斑缺陷的检测置信度有明显提高,而且改善了原模型对于不明显绿斑缺陷的漏检以及误检的情况。由图 9 可以看出,改进模型对于黑斑缺陷中存在的小目标的漏检情况有所改善,且提高了小目标的检测置信度。由图 10 可以看出,改进后的模型不仅提高了黑斑缺陷目标的检测置信度,而且减少了模型在目标密集情况下的重复识别,提高了模型对于多尺度缺陷目标的识别能力。



LB 代表绿斑缺陷 FS 代表黑斑缺陷

图 8 绿斑缺陷检测效果对比

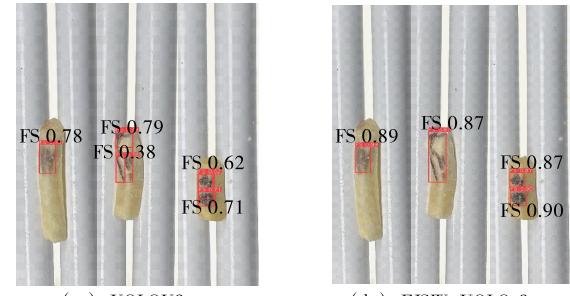
Figure 8 Comparison of detection performance for green spot defects



LB 代表绿斑缺陷 FS 代表黑斑缺陷

图 9 黑斑缺陷小目标检测效果对比

Figure 9 Comparison of detection performance for small targets of black spot defects



LB 代表绿斑缺陷 FS 代表黑斑缺陷

图 10 黑斑缺陷密集目标检测效果对比

Figure 10 Comparison of detection performance of dense targets of black spot defects

对比结果表明,EISW-Yolov8n 模型的性能得到了有效提升,不仅在缺陷检测精度上有所提高,改善了模型的漏检和误检情况,而且有效解决了密集缺陷目标的重复识别问题,提高了模型对小尺度、多尺度目标缺陷的识别能力。

2.3 消融试验

在相同的模型训练环境下以原始 YOLOv8n 为基准,

以精确率、召回率、mAP50、参数量为评价指标设计了一系列消融试验,结果见表2。从表2可以看出,在原网络模型的Neck网络的C2f模块加入iRMBS多尺度移位卷积倒置残差移动模块后模型的参数量有所下降,并且模型对于多层次特征的提取、融合能力得到明显加强,平均准确率提高了1.3%,精确率提高了3.6%。同时可以看出引入EMCA注意力机制后,模型对于小目标的重要通道特征更加关注,模型的平均准确率提高了1.3%,精确率提高了2.9%,且由于EMCA注意力机制极其轻量化所以模型

的参数量仅略有增加。而添加后的WIOU损失函数相比原函数为模型提供了更加准确的定位结果,模型的收敛速度得到提高且平均准确率和召回率均有所提高。同时采用WIOU损失函数和EMCA注意力机制,模型的平均准确率进一步提高1.9%,达到0.936。将3个模块融合使用,与原模型相比,改进后的模型在模型的参数量没有增加的情况下,模型的精确率提高了1.5%,召回率提高了2.7%,平均准确率提高了2.6%,模型的整体性能得到提升,验证了改进模型的有效性。

表2 消融试验结果[†]

Table 2 Results of ablation experiments

YOLOv8n	+iRMBS	+EMCA	+WIOU	精确率/%	召回率/%	mAP50/%	参数量
✓				91.4	86.8	91.7	3 006 038
✓	✓			95.0	86.8	93.0	2 989 556
✓		✓		94.3	86.8	93.0	3 006 042
✓			✓	91.6	90.6	92.8	3 006 038
✓		✓	✓	90.6	86.3	93.6	3 006 042
✓	✓	✓	✓	92.9	89.5	94.3	2 989 562

[†] ✓ 表示加入该模块。

2.4 其他算法对比试验

在相同的测试环境下,将EISW-YOLOv8n与目前较优秀目标检测算法进行对比试验,如表3所示。从表3可以看出,EISW-YOLOv8n相比其他对比算法在各个方面均表现出了显著的优越性。改进算法相比于两阶段的Faster-R-RCNN,不仅平均精度值远高于Faster-R-RCNN,而且改进算法的参数量、浮点运算次数也远小于Faster-R-RCNN。与RTMDET_tiny相比,改进算法的浮点运算次数略高于RTMDET_tiny,但是改进算法的平均精度值高出6.9%。与最新的实时目标检测算法RTDETR-L相比,改进算法的平均精度值高出4.4%,参数量和浮点运算次数远小于RTDETR-L。

表3 其他算法对比试验

Table 3 Comparative tests with other algorithms

方法	mAP50/%	参数量	浮点运算次数
Faster-R-RCNN	77.0	41 353 000	3.310×10^{10}
SSD	85.4	24 534 000	8.760×10^{10}
RTMDET_tiny	87.4	4 873 000	8.000×10^9
RTDETR-L	89.9	31 987 000	1.034×10^{11}
YOLOv3	88.1	107 976 000	2.823×10^{11}
YOLOv5n	90.3	2 503 000	7.100×10^9
YOLOv6n	86.0	4 233 000	1.180×10^{10}
YOLOv7	77.3	37 194 000	1.051×10^{11}
YOLOv8n	91.7	3 006 038	8.100×10^9
EISW-YOLOv8n	94.3	2 989 562	8.800×10^9

与YOLOv3、YOLOv5n、YOLOv6n、YOLOv7、YOLOv8n等YOLO系列算法相比,EISW-YOLOv8n的平均精度值分别提高6.2%,4.0%,8.3%,17.0%,2.6%,涨幅明显。而在参数量方面改进算法的数值仅比YOLOv5n略高,比YOLOv3、YOLOv6n、YOLOv7、YOLOv8n要小得多。

试验结果表明,与两阶段算法Faster-R-RCNN、实时目标检测算法RTDETR-L,以及经典的RTMDET_tiny算法和YOLO系列算法相比,改进算法EISW-YOLOv8n以较小的参数量和浮点运算次数,达到了最高的平均精度,可显著提高预制薯条的残次品缺陷检测效率,保证了缺陷检测的实时性要求,具有较高的优异性,且更加利于后续的模型部署。

2.5 热力图可视化分析

利用梯度加权的类激活热力图技术(Grad-CAM)^[14],随机选取一部分图像对原始YOLOv8n模型和改进后的EISW-YOLOv8n模型的第9、15、18、21层分别进行模型的关注区域可视化,如图11所示。从图11可以看出,改进后的模型相比于原始模型对于缺陷区域关注更为准确和集中,改进模型对于特征的提取和检测能力得到了加强。

3 结论

该研究提出的针对YOLOv8n进行改进的缺陷检测算法解决了传统生产中残次产品依靠人工检测费时费力、漏检等问题。高效多尺度通道注意力机制的加入,增强了原模型处理大量通道信息的能力,提高了模型对重

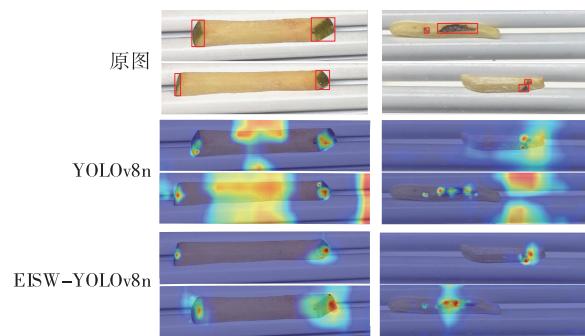


图 11 热力图

Figure 11 Heat map

要通道信息的关注,同时使用移位卷积网络中的具有移位操作的卷积对 EMO 模型中的倒置残差移动模块进行了优化,并引入 YOLOv8 网络 C2f 模块中,增强了模型对于不同层级缺陷特征的提取、融合能力;使用 WIOU 损失函数对样本质量进行平衡,提高模型预测框的定位精度以及模型收敛速度。

改进后的算法 EISW-YOLOv8n 性能优越,真实框和预测框交并比为 0.5 时的模型平均精度值、精确率、召回率分别达到 94.3%, 92.9%, 89.5%, 相比原始 YOLOv8n 模型分别提高了 2.6%, 1.5%, 2.7%, 同时性能优于其他经典目标检测算法,在保证模型轻量、检测速度不降低的前提下,达到了较高的检测准确率,可以满足预制薯条的缺陷残次品的实时检测要求。而且该算法避免了人为因素的干扰并极大减弱了外部因素对检测结果的影响,能保证食品生产的安全性。后续可以对模型进行轻量化相关研究,以便保证模型的检测性能将模型更好地部署在嵌入式设备上。

参考文献

- [1] LEEMANS V, DESTAIN M F. A real-time grading method of apples based on features extracted from defects[J]. Journal of Food Engineering, 2004, 61(1): 83-89.
- [2] 吴陈陈, 王永强, 周聪玲. 双线阵 CCD 青豆在线筛选系统设计[J]. 食品与机械, 2021, 37(3): 131-136, 167.
WU C C, WANG Y Q, ZHOU C L. Design of green beans online screening system based on double linear CCD[J]. Food & Machinery, 2021, 37(3): 131-136, 167.
- [3] BLASCO J, ALEIXOS N, MOLTÓ E. Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm[J]. Journal of Food Engineering, 2007, 81(3): 535-543.
- [4] 向宇航, 周聪玲, 王永强. 基于机器视觉的鲍鱼风味片残次品在线检测方法[J]. 食品与机械, 2022, 38(11): 95-100.
XIANG Y H, ZHOU C L, WANG Y Q. Online visual detection method of defective Baoyu-flavor-slices based on mechanical vision[J]. Food & Machinery, 2022, 38(11): 95-100.
- [5] 曾文炳, 李军. 基于深度学习的目标检测算法综述[J]. 汽车工程师, 2024(1): 1-11.
ZENG B W, LI J. Review of target detection algorithms based on deep learning[J]. Automotive Engineer, 2024(1): 1-11.
- [6] WANG M Y, ZHOU Y. Autonomous rail surface defect identification based on an improved one-stage object detection algorithm[J]. Journal of Performance of Constructed Facilities, 2024, 38(5): 1-14.
- [7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 580-587.
- [8] PANG Q, HUANG W Q, FAN S X, et al. Detection of early bruises on apples using hyperspectral imaging combining with YOLOv3 deep learning algorithm[J]. Journal of Food Process Engineering, 2022, 45(2): 1.
- [9] 高鹏翔. 基于深度学习的胡萝卜表面缺陷在线检测方法研究[D]. 沈阳: 东北农业大学, 2022: 32-46.
GAO P X. Research on on-line detection of carrot surface defects based on deep learning[D]. Shenyang: Northeast Agricultural University, 2022: 32-46.
- [10] LIU S H, ZHAI B L, ZHANG J T, et al. Tomato detection based on convolutional neural network for robotic application [J]. Journal of Food Process Engineering, 2023, 46(2): e14239.
- [11] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11 531-11 539.
- [12] ZHANG J, LI X, LI J, et al. Rethinking mobile block for efficient attention-based models[C]// Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris: IEEE, 2023: 15 954-15 965.
- [13] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1 800-1 807.
- [14] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]// Proceedings of the IEEE International Conference on Computer Vision (ICCV 2017). Venice: IEEE, 2017: 618-626.