

基于 YOLO-HDR 的小龙虾缺陷品质检测方法

王淑青 陈开元 周 森 范博淦

(湖北工业大学电气与电子工程学院, 湖北 武汉 430068)

摘要: [目的] 改善工业生产线上小龙虾质量检测方法单一、效率低、检测成本高的问题。[方法] 提出了一种基于 YOLO-HDR 的轻量化神经网络检测模型。使用 PP-HGNetv2 模型设计一种新的 YOLOv8 骨干网络并引入 HGstem 和 DWConv 的轻量化模块重构网络; 使用动态卷积块以及官方库中的其他轻量化卷积 (GhostConv、RepConv) 重新设计新骨干网络的 HGBlock, 得到动态高性能网络模块 (DynamicHGBlock、RepHGBlock、GhostHGBlock 等) 来改进 HGBlock, 以提升网络的特征表达能力; 用重复跨阶段局部保边注意力网络 RepNCSPeLan4 改进原颈部网络的 C2f 模块, 并改善骨干模块改进后的轻量网络的性能。[结果] 改进模型的精确度及平均精度均值达到 92.8% 和 95.9%, 相较于原模型分别提高了 3.5% 和 1.9%, 优于其他对比目标检测算法。改进后模型的参数量及模型大小相比原 YOLOv8n 模型分别降低了 17.7% 和 16.2%, 计算量减少了 19.8%。[结论] 试验方法在密集遮挡噪声背景下的检测性能均有提高, 能够满足工业流水线小龙虾冷冻分装前复杂背景下质量检测需求。

关键词: 深度学习; 品质检测; 小龙虾; 注意力机制; PP-HGNetV2

A method for detecting quality defects of crayfish based on YOLO-HDR

WANG Shuqing CHEN Kaiyuan ZHOU Miao FAN Bogan

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan, Hubei 430068, China)

Abstract: [Objective] This study aims to address the problems of single methods, low efficiency, and high costs of the quality inspection of crayfish in industrial processing. [Methods] A YOLO-HDR-based lightweight neural network model was proposed. The PP-HGNetv2 model was employed to design a new YOLOv8 backbone network, and the lightweight modules of HGstem and DWConv were introduced to reconstruct the network. The dynamic convolution block and other lightweight convolutions (GhostConv and RepConv) in the official library were used to redesign the HGBlock of the new backbone network. The dynamic high-performance network modules (DynamicHGBlock, RepHGBlock, and GhostHGBlock) were obtained to improve HGBlock and the feature expression of the network. The C2f module of the original neck network was improved by the repeated cross-stage local edge-preserving attention network RepNCSPeLan4 to address the performance degradation caused by the lightweight network. [Results] The accuracy and average precision of the improved model reached 92.8% and 95.9%, respectively, which were 3.5% and 1.9% higher than those of the original model and better than those of other comparative target detection algorithms. The number of parameters and model size of the improved model were reduced by 17.7% and 16.2%, respectively, compared with those of the original YOLOv8n model, and the amount of computation was reduced by 19.8%. [Conclusion] The method established in this study demonstrates improved detection performance under the dense occlusion noise background, enabling the quality inspection of crayfish in industrial processing in the complex background before frozen packaging.

Keywords: deep learning; quality inspection; crayfish; attention mechanism; PP-HGNetV2

龙虾的初级加工产品主要为速冻制品, 包括速冻虾尾、虾仁和整肢虾^[1]。目前, 小龙虾的新鲜程度和瑕疵检

基金项目: 国家自然科学基金 (编号: 62306107)

通信作者: 王淑青 (1969—), 女, 湖北工业大学教授, 博士。E-mail: 1258868715@qq.com

收稿日期: 2024-06-28 改回日期: 2024-12-12

引用格式: 王淑青, 陈开元, 周森, 等. 基于 YOLO-HDR 的小龙虾缺陷品质检测方法[J]. 食品与机械, 2025, 41(3): 100-107.

Citation: WANG Shuqing, CHEN Kaiyuan, ZHOU Miao, et al. A method for detecting quality defects of crayfish based on YOLO-HDR [J]. Food & Machinery, 2025, 41(3): 100-107.

测主要依靠人工,效率低且误差大。在食品农业科技领域,深度卷积神经网络如VGG^[2]、Faster-RCNN^[3]、ResNet^[4]和YOLO等被广泛应用。王淑青等^[5]设计了一种改进YOLOv4神经网络预测小龙虾合格与否模型,在单一背景下有较高的识别率,但数据集单一、训练成本高、训练效率较低且在复杂背景下的检测效果未知。鲁濠等^[6]利用改进YOLOv5神经网络预测小龙虾的合格与不合格分类,但存在分类简单、不能满足商业需求、模型训练时间长、收敛慢、训练成本高、模型尺寸大等问题。Zhang等^[7]利用龙虾的总挥发碱性氮值训练深度学习模型进行新鲜度分类,预测精度高,但数据集采集困难。高竞博等^[8]提出了一种基于深度学习的小龙虾(大中小)分级算法,通过比较EfficientNetB0、ResNet50、VGG16、VGG19 4种网络对处理过的339张小龙虾样本在3种不同噪声图像处理下的识别分类准确率,发现EfficientNetB0网络的效果最佳,但该方法不符合商业加工需求且样本数小,不具有普适性。李小占等^[9]通过改进VGG模型对哈密瓜表面缺陷进行检测,发现卷积层数的增加可显著提高特征提取效果,但在多目标复杂背景下的效果未知。陈斌等^[10]使用Faster-RCNN在自然环境下检测油茶果,获得了高准确率(98.92%),但查错率较高。Elbassuoni等^[11]提出了端到端深度学习模型并用于食品健康识别,测试准确率达90%。Helwan等^[12]设计了一种利用ResNet-50对香蕉进行缺陷检测的水果分级智能系统,效果优良。Mukhiddinov等^[13]通过优化YOLOv4模型,使用Mish激活函数,显著提高了水果和蔬菜新鲜度分级的精确度和速度。Mi等^[14]将注意力机制嵌入DenseNet用于小麦条锈病检测,显著提升了模型性能。Kamilaris等^[15]研究表明,深度学习可提高精度,优于传统的图像处理技术。综上,基于深度学习的小龙虾生产线,复杂背景往往会影响到小龙虾检测和定位,且大多研究仅在实验室理想环境下进行,背景单一,泛化能力低,针对实际加工复杂背景下小龙虾的密集场景、堆叠遮挡、噪声问题检测的相关研究较少;模型体积带来的部署成本高的问题尚有优化空间。研究拟基于较为先进的、具有高精度、低参量的深度学习方法YOLOv8模型,提出一种新的改进网络模型YOLO-HDR,对实际加工复杂背景下的小龙虾生产线检测进行优化和改进,以期工业小龙虾加工线检测提供依据。

1 材料与方法

1.1 数据集建立

1.1.1 数据采集 数据采集于湖北省某小龙虾加工厂。采集设备为Intel RealSense D435,图像分辨率为1 280像素×924像素,以JPG格式保存。采集过程利用机械臂和工业相机从上方俯视进行连续拍摄,视频帧率为48帧/s,

每隔6帧提取一次图像,共获得4 325张图像,并对其进行编号。由于部分图像受相机震动影响出现过度模糊,经人工筛选后,选取4 100张质量较高的图像,涵盖小龙虾的五大外观质量缺陷类型:新鲜完整虾1 053张、新鲜破损虾1 046张、死亡完整虾1 015张、死亡破损虾986张和脱落的残肢虾1 500张,保证了数据集的平衡性。

识别原理:进行品质检测前,小龙虾通常被处理至半熟状态。未煮熟的鲜活小龙虾肉质更为优良,而死亡或品质较差的小龙虾肉质较为松散。处理前,鲜活的小龙虾一般呈蜷缩状态,尾部弯曲至胸前;反之,死亡的小龙虾则更为伸展且僵硬。小龙虾的鲜活程度可以通过测量其蜷曲度来判断,即头部、头尾连接处与尾部3点形成的夹角。蜷曲度<90°为鲜活的合格小龙虾;否则为不新鲜或已死亡的小龙虾。新鲜与死亡的小龙虾还可以根据是否完整进一步分类,以满足商业需求。带瑕疵的小龙虾可能在头部与尾部连接处松弛,甲壳部分脱落。此外,加工和运输过程中产生的断肢会散落在生产线上,龙虾密集堆叠遮挡干扰分拣过程,需要通过检测来识别。

1.1.2 数据预处理 使用LabelImg标注数据集,每张图片至少标注一个标签,使用矩形框将虾体部分全部框出,导出为yolo格式的txt文件。采用变亮、变暗、旋转、高斯模糊、椒盐等对数据进行增强,增加数据集的复杂性,改善网络在复杂背景下的稳定性能。数据扩充完成后经人工辨识挑选共得到数据集6 400张,其中训练集5 400张,验证集700张,测试集300张。

1.2 小龙虾质量分级检测改进方法

基于YOLOv8网络,主要在3个方面进行改进。YOLO-HDR模型结构如图1所示。

(1) 使用PP-HGNetv2^[16]模型设计一种新的YOLOv8骨干网络并引入HGStem^[17]和深度卷积DWConv^[18]结构来获得更大感受野的同时使网络的参数量更少,且精度可以进一步提升。

(2) 为改善轻量级网络因其低计算负载约束(深度与通道方面的约束)导致性能降低的问题,提升轻量级神经网络的特征表达能力,使用动态卷积块(DynamicConv)以及官方库中的其他轻量化卷积(GhostConv、RepConv)改进PP-HGNetV2网络中的HGBlock,得到动态高性能网络模块(DynamicHGBlock、RepHGBlock、GhostHGBlock等)替换HGBlock。

(3) 用RepNCSPeLan4模块改进原颈部网络的C2f模块,进一步提升网络的特征识别能力。

1.2.1 骨干网络改进 PP-HGNetv2是PP-HGNetV1的下一代版本,来自一种创新的实时端到端物体检测系统RT-DETR^[19](高性能GPU骨干网络)。其在PP-HGNetV1的基础上,拥有更多的2×2前沿以学习更丰富的局部特征,使用更小的通道数来提升更大的分辨率任务如目标检




图 1 YOLO-HDR 网络模型结构图

Figure 1 Structure diagram of the YOLO-HDR-based network model

测、图像分割等的推理速度;替换了 PP-HGNet 中靠后期的标准波形层为 PW+DW5×5 组合;增加了 Learn Affine Block 模块,其可以在增加极少参数量的同时大幅提升较小模型的精度,且对推理时间无损;默认提供了精度更高、泛化能力更强的 SSLD 预训练权重,其在下游任务中表现更佳。PP-HGNetV2 由多个 HG-Block 组成,每个 HG 块处理数据的不同抽象层次,允许网络从低级和高级特征中学习。HG-Block 结构如图 2 所示。




图 2 HG-Block 结构图

Figure 2 Diagram of the HG-Block structure

Stem 层是网络的初始预处理层,通常包含卷积层,开始从原始输入数据中提取特征。可学习的下采样层(LDS)位于 HG 块之间,执行下采样操作,减少特征图的空间维度,减少计算负载并增加后续层的感受野。最终的卷积和全连接(FC)层执行最终分类任务的层结束。这通常涉及一个卷积层(1×1 卷积)来组合特征,然后将这些特征映射到所需输出类别数量的全连接层。这种架构的主要思想是利用层次化的方法来提取特征,其中复杂的模式可以在不同的规模和抽象层次上学习,提高网络处理复杂图像数据的能力。图 2 还显示了 HG 块的扩展视图,包括多个不同滤波器大小的卷积层,以捕获多样化的特征,然后通过一个元素级相加或连接的操作(由 + 符

号表示)在数据传递到下一层之前。

1.2.2 动态卷积(DynamicConv)改进 HG-Block 的方法

(1) 动态卷积(DynamicConv):动态卷积通过引入一个基于注意力机制的方法来动态聚合多个卷积核,使模型能够根据输入特征进行自适应调整。具体来说,动态卷积不通过增加网络的深度或宽度来提升性能,而是在同一层中并列使用多个小型卷积核,并通过注意力权重将这些卷积核结合起来。尽管每个动态卷积层包含多个卷积核,但由于卷积核较小,其额外的计算成本相对较低,使得这种动态聚合方式在计算资源有限的情况下,依然能够有效地增强网络的表征能力。动态卷积的生成方式如图 3 所示。




图 3 动态卷积层

Figure 3 A DynamicConv layer

描述传统或静态的感知器模型为

$$y = g(W^T x + b), \quad (1)$$

式中:

W ——权重矩阵和偏置向量;

g ——激活函数。

动态感知器则是通过组合多个(K 个)线性函数 $\tilde{W}_k^T x + \tilde{b}_k$ 定义的。

$$y = g(\tilde{W}^T(x) x + \tilde{b}(x)), \quad (2)$$

$$\tilde{W}(x) = \sum_{k=1}^K \pi_k(x) \tilde{W}_k, \tilde{b}(x) = \sum_{k=1}^K \pi_k(x) \tilde{b}_k, \quad (3)$$

$$\text{s.t. } 0 \leq \pi_k(x) \leq 1, \sum_{k=1}^K \pi_k(x) = 1, \quad (4)$$

式中:

π_k ——第 k 个线性函数 $\tilde{W}_k^T(x) x + \tilde{b}_k(x)$ 注意力权重。

需要注意的是,总权重 $\tilde{W}(x)$ 置 $\tilde{b}(x)$ 输入 x 数,且共享相同的注意力机制。注意力权重 $\pi_k(x)$ 不是固定的,而是随输入 x 不同而变化,其代表了对于特定输入最优地聚合线性模型 $\tilde{W}_k^T(x) x + \tilde{b}_k(x)$,此聚合后的模型 $\tilde{W}^T(x) x + \tilde{b}(x)$ 为非线性函数,使动态感知器具有比静态感知器更强的表现力。动态卷积层中注意力权重 $\pi_k(x)$ 按式(5)计算。

$$\pi_k(x) = \text{softmax}\left(\text{FC}\left(\text{ReLU}\left(\text{FC}\left(\text{GAP}(x)\right)\right)\right)\right). \quad (5)$$

其中,GAP代表全局平均池化,FC代表全连接层。式(5)通过两层全连接网络(其中间有ReLU激活函数)处理全局平均池化后的特征,然后通过softmax函数正规化,从而产生用于加权卷积核的注意力权重。与静态感知器相比,动态感知器具有相同数量的输出通道,但模型

尺寸更大。其还引入了两项额外的计算:计算注意力权重 $\pi_k(x)$ 及基于注意力的参数聚合 $\pi_k(x)\tilde{W}_k$ 。这些额外的计算成本远小于计算 $\tilde{W}^T(x)x + \tilde{b}(x)$ 的。

(2) 动态卷积(DynamicConv)改进HG-Block:改进前与改进后的HG-Block对比如图4所示。




图4 改进前后HG-Block对比结构图

Figure 4 Comparison of HG-Block before and after improvement

HG-Block的改进提升了网络的表现力和适应性。在原始设计中,HG-Block由两个串联的标准卷积层组成,并辅以两个轻量级卷积(LightConv)层和一个残差连接,这种配置为网络提供了基础的特征提取能力。在改进后的设计中,引入了动态卷积(DynamicConv)^[20],取代了原始结构中的轻量级卷积层。与传统的卷积相比,动态卷积能够根据输入特征动态调整滤波器参数,使网络可以适应不同的数据分布和特征模式。在DynamicConv中,包含一个Single-DynamicConv,其利用条件卷积(CondConv2d)和一个后置的线性变换(Linear)来调整卷积权重,从而提供有针对性的特征调制,嵌入了Sigmoid线性单元(SiLU)作为激活函数,并集成了二维批量归一化(Batch Norm 2d)以稳定训练过程。SiLU提供了比传统ReLU更加平滑的梯度流,有助于避免梯度消失的问题。批量归一化则标准化了层输入的分布,有利于提高学习速度和网络的泛化能力。此改进实现了更高效的特征提取并增强了网络的适应性,为处理复杂的特征提取任务,尤其是在变化多端的视觉数据中提供了有效的方法。

1.2.3 RepNCSPELAN4模块 采用YOLOv9^[21]的新型卷积神经网络结构RepNCSPELAN4,通过优化信息流和

参数利用率来提高网络性能。该结构由多个子模块组成,涉及多个并行和串行操作,以实现高效的特征提取。其详细结构图如图5所示。

结构的输入经过一个卷积层(Conv1(c1,c3)),其后是一个分割操作。这个分割操作将特征图分为两个通道数为C/2的分支,其中一个分支直接传递,另一个分支进入一个RepNCSP子模块(RepNCSP(c3/2,c4))。该子模块进一步通过卷积层(Conv1(c4,c4))处理信息,然后将两个分支的输出进行拼接(Concat,c3=3×2+c4),并通过卷积层(Conv1(c,c2))以减少维度。与此同时,RepNCSP模块路径中的特征图经两个卷积层(Conv1(c1,c_)和Conv2(c1,c_)),然后输入到RepNBottleneck模块。该模块内部包含扩展因子e用于控制卷积层内的通道数,进一步的卷积层(Conv3)和尺度变换操作确保特征图的尺寸和通道数适配后续的操作。在后续的RepConvN模块中,特征图经历一个可选的短路连接(shortcut),若满足特定条件(If c1=c2 and shortcut is true),则通过相加合并来增强特征。该模块内部实现了一个卷积操作的组合,首先是一个空间分辨率为3×3的卷积(Conv1(c1,c2)),然后是1×1卷积(Conv1(c1,c2))以优化网络的计算效




图 5 RepNCSPELAN4 结构图
Figure 5 Diagram of RepNCSPELAN4 structure

率。最终,通过上述复杂的特征处理和优化路径,RepNCSPELAN4能够有效地进行特征学习,从而提高在特定任务上的性能。

2 试验与分析

2.1 试验环境

试验环境为 Windows11 64 位操作系统,使用 GPU 为 NVIDIA GeForce RTX 3060, Python3.8 版本, Pytorch1.13 框架, cuda11.7 版本。训练参数见表 1。试验中 batch 设置为 -1, 根据模型大小、试验环境配置自动选择 batchsize, 输入图像尺寸为 640×640, 训练轮数为 500, 耐心值 (patience) 默认 50 轮, 在最近 50 轮训练没有提升时会触发早停机制, 算法会提前结束并保存训练。

2.2 主流模型对比试验

为验证试验改进算法的优越性, 将其与当前主流的众多模型算法 (YOLOv3、YOLOv5、YOLOv6、YOLOv7、

表 1 训练参数

Table 1 Training parameters

参数	设置	参数	设置
训练轮数	500	禁用马赛克	10
批次	-1	初始学习率	0.01
图片尺寸	640	最终学习率	0.01
线程数	8	动量	0.937
早停观察轮	50	权重衰减	0.005
优化器	SGD	热身轮数	3

YOLOv8、ASF-YOLO) 在相同的试验环境下进行对比, 结果见表 2。

由表 2 可知, YOLOv8 在同等体量 (n 模型) YOLO 系列主流模型中, mAP@50 和 mAP@50-95 最高, 模型大小比 YOLOv5 高出 17.8%, 精度较 YOLOv8s 低 1.9%, 拥有改进空间。改进后的 YOLOv8-PDR 在精度上较

表 2 主流模型对比试验

Table 2 Comparison on the performance of YOLO models

模型	精确度/%	mAP@50	mAP@50-95	浮点量/G	参数量/MB	模型大小/MB
YOLOv3n	83.0	91.9	86.8	12.00	4.05	7.97
YOLOv5n	88.7	93.6	89.5	7.10	2.50	5.10
YOLOv6n	74.7	88.4	78.4	11.80	4.23	8.26
YOLOv8n	89.3	94.0	90.1	8.10	3.00	5.99
YOLOv8s	92.3	95.8	93.4	28.40	11.10	21.50
ASF-YOLO	86.4	92.9	87.7	12.00	2.49	5.20
YOLO-HDR	92.8	95.9	91.2	6.50	2.47	5.02

YOLOv3n、YOLOv5n、YOLOv6n 分别高出 11.8%,4.1%,8.1%,与 YOLOv8s 的接近,且较 ASF-YOLO 的高出 6.4%。在 mAP@50 指标上,YOLOv8-HDR 比 YOLOv3n、YOLOv5n、YOLOv6n、ASF-YOLO 分别高出 4.0%,2.3%,7.5%,3.0%,与 YOLOv8s 的持平。相较于 YOLOv3n 和 YOLOv6n,YOLO-HDR 的模型大小分别减少了 37%和 39%。与 YOLOv8n 相比,YOLO-HDR 的模型大小减少了 16.2%。综上,YOLO-HDR 在绝大参数上具有优越性,在效率和成本效益之间达到了较好的平衡。

2.3 HG-Block 改进对比试验

将 PP-HGNetV2 骨干网络替换原始 YOLOv8 骨干后并保持原始 YOLOv8 网络其余部分(Neak、Head)不变。通过分析 PP-HGNetV2 骨干中 HG-Block 的结构,发现其有大量的卷积块,因此使用一些更轻量化或更高性能的卷积块来改进 HG-Block,以第二次提升模型的精度和性能。使用 DynamicConv、RepConv 和 GhostConv 3 种卷积进行对比试验,其中后两种卷积来自 ultralytics 官方库,试验结果见表 3。

表 3 HG-Block 改进对比
Table 3 Comparison on the performance of HG-Block improved with different methods

模型	精确度/%	mAP@50	mAP@50-95	浮点量/G	参数量/MB	模型大小/MB
YOLOv8n	89.3	94.0	90.1	8.1	3.00	5.99
YOLOv8n_HGNetV2	86.2	93.7	89.9	6.9	2.35	4.77
YOLOv8n_HGNetV2_DyConv	91.3	95.5	90.7	6.7	2.56	5.15
YOLOv8n_HGNetV2_RepConv	90.4	94.6	90.5	6.5	2.48	4.77
YOLOv8n_HGNetV2_GhostConv	87.4	92.0	85.6	6.8	2.31	4.65

由表 3 可知,将 YOLOv8 原主干替换成 HGNetV2 主干后,模型大小、浮点量和参数量分别减少了 20.4%,14.8%,21.7%,达到了轻量化的目的,同时在 mAP@50 和 mAP@50-95 指标上也略有上升,精确度略有下降。使用 DynamicConv 改进 HGNetV2 主干的 HG-Block 后,模型的参数量略微上升,模型大小相对前者改进主干后仅上升 7.9%,但精确度、mAP@50、mAP@50-95 分别提高了 5.1%,1.8%,0.8%;采用 RepConv 改进后,精度和模型大小与前者基本持平,但精度也比 YOLOv8 原主干略微提升。

采用 GhostConv 改进后,模型大小和参数量最小,但精度较差。因此,选用 DynamicConv 来改进 HG-Block 进行后续试验。

2.4 消融试验

为了验证试验算法改进的有效性,以原始 YOLOv8n 模型数据为基准线,试验侧重于评估 PPHGNetV2 骨干、DynamicConv、RepNSPELAN4 模块在精度、mAP@50、mAP@50-95、浮点量、参数量、模型尺寸和帧率等多个维度的影响,结果见表 4。

表 4 消融试验†
Table 4 Ablation test

PPHGNetV2 轻量化网络	DynamicConv 改 进 HGBlock	RepNCSPELAN4	精确度/%	mAP@50	mAP@50-95	浮点量/G	参数量/ MB	模型大 小/MB	帧率/FPS
×	×	×	89.3	94.0	90.1	8.1	3.00	5.99	121.5
×	×	✓	87.6	92.2	87.4	7.9	2.93	5.84	115.7
✓	×	×	86.2	93.7	89.9	6.9	2.35	4.77	123.1
✓	×	✓	90.6	93.9	89.9	6.6	2.27	4.64	124.3
✓	✓	×	91.3	95.5	90.7	6.7	2.56	5.15	119.7
✓	✓	✓	92.8	95.9	91.2	6.5	2.47	5.02	132.6

† ×表示未使用此改进,✓表示使用此改进。

由表 4 可知,单独使用 RepNCSPELAN4 模块后,模型参数和大小略微降低,精度指标也小幅下降;单独引入 PPHGNetV2 骨干后,模型大小和参数量显著下降,但精度略微下降,表明该方法是以牺牲少量精度带来的轻量化改进;将 PPHGNetV2 骨干和 RepNCSPELAN4 模块共同

使用时,模型大小、参数量以及运算量均最低,说明该组合将轻量化达到了极致,同时也牺牲了微量的精度;将动态卷积加入 PPHGNetV2 骨干后再一同改进原网络,精度有较大幅提升,精确度、mAP@50、mAP@50-95 相对原网络分别提升了 2.0%,1.5%,0.6%,浮点量、参数量、模型大

小相对前者最低组仅增长了 1.5%, 12.8%, 11.0%, 说明该方法是以增加少量体量指标得到精度指标的较大幅提升; 将动态卷积改进的 PPHGNetV2 骨干、RepNCSPELAN4 模块组合加入改进时, 精度达到了最大值, 精确度、mAP@50、mAP@50-95 相对原网络分别提升了 3.5%, 1.9%, 1.1%, 浮点量最低, 参数数量和模型大小也有 17.7% 和 16.2% 的降幅。

2.5 损失函数

使用 YOLOv8 默认的 CIOU。传统的 IOU 方法在某些情况下可能不够精确, 其仅考虑了重叠面积, 忽略了边界框形状和位置的差异。为了弥补这一不足, 在 YOLOv8 中引入 CIOU 损失函数, 其不仅考虑了重叠面积, 还包括中心点距离和边界框的纵横比。CIOU 损失函数由 IOU 损失、中心点距离损失和边界框形状损失 3 部分组成, 计算式为:

$$L_{\text{CIOU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v, \quad (6)$$

式中:

IoU——预测边界框与真实边界框的重叠面积比;

$\rho^2(b, b^{\text{gt}})$ ——预测边界框和真实边界框中心点之间的欧氏距离;

c ——包围预测边界框和真实边界框的最小闭包矩形的对角线长度;

v ——衡量边界框形状的一致性;

α ——平衡系数。

CIOU 损失函数综合考虑了 IOU、中心点距离和边界框形状, 使得预测框不仅在重叠面积上接近真实框, 还在位置和形状上更加一致。改进前后模型损失值对比结果如图 6 所示。




图 6 改进前后损失变化对比图

Figure 6 Comparison on losses before and after improvement

2.6 小龙虾样品检测

为直观对比 YOLOv8n 和试验改进算法 YOLO-HDR 在小龙虾工业生产线上检测效果, 选择小龙虾密集场景、小龙虾密集遮挡场景、小龙虾密集遮挡且设备噪声场景对算法进行可视化验证。小龙虾密集场景中, 原 YOLOv8 模型出现了大目标漏检的情况, 而 YOLO-HDR 能准确识别所有目标且综合置信度更高。小龙虾密集且相互遮挡场景中, 原 YOLOv8 模型未识别出龙虾主体且出现了错检和龙虾主体漏检的情况, 而 YOLO-HDR 均能

准确识别所有目标且置信度更高。小龙虾设备噪声且密集遮挡场景中, 原 YOLOv8 模型出现了多目标漏检和大目标丢失的情况, 而 YOLO-HDR 能正常识别出所有目标但出现了一例无目标错检情况, 综合检测效果更好。

3 结论

为改善工业小龙虾生产线复杂背景下识别检测的问题, 降低小龙虾生产加工人工检测成本、提高小龙虾食品质量和生产效率, 提出了一种基于 YOLOv8 神经网络的轻量化小龙虾检测算法 YOLO-HDR。结果表明, YOLO-

HDR的平均精度均值达到了95.9%,比原YOLOv8n提高了1.9%;模型大小为5.02 MB,比YOLOv8n降低了16%;参数量为2.47 MB,比原模型降低了17.7%;准确率为92.8%,比YOLOv8n提高了3.5%;帧数达到了132.6帧/s,比原模型提高了9.1%。改进后模型针对工业小龙虾生产线上密集龙虾场景、密集堆叠场景、噪声密集堆叠场景下的复杂背景识别效果有较好提升,降低了部署在嵌入式设备上的成本。后续将针对其他中下游产业对象检测可行性进行研究,并对模型的损失进行优化和改进以期提升网络的性能。

参考文献

- [1] 于秀娟,郝向举,杨霖坤,等.中国小龙虾产业发展报告(2023)[J].中国水产,2023(7):26-31.
YU X J, HAO X J, YANG L K, et al. China crayfish industry development report (2023) [J]. China Fisheries, 2023(7): 26-31.
- [2] SWAIN S, TRIPATHY A K. Automatic detection of potholes using VGG-16 pre-trained network and Convolutional Neural Network[J]. Heliyon, 2024, 10(10): e30957.
- [3] CHEN S H, ZHU Z R, HOU X N. Classification of wafer map defect based on ResNeSt[J]. Journal of Physics: Conference Series, 2024, 2 741(1): 012019.
- [4] KONG X H, LI X J, ZHU X X, et al. Detection model based on improved faster-RCNN in apple orchard environment[J]. Intelligent Systems with Applications, 2024, 21: 200325.
- [5] 王淑青,黄剑锋,张鹏飞,等.基于YOLOv4神经网络的小龙虾质量检测方法[J].食品与机械,2021,37(3):120-124,194.
WANG S Q, HUANG J F, ZHANG P F, et al. Crayfish quality detection method based on YOLOv4[J]. Food & Machinery, 2021, 37(3): 120-124, 194.
- [6] 鲁濠,王淑青,鲁东林,等.基于改进YOLOv5的小龙虾品质检测方法[J].湖北工业大学学报,2023,38(4):76-81.
LU H, WANG S Q, LU D L, et al. Quality detection method of crayfish based on improved YOLOv5[J]. Journal of Hubei University of Technology, 2023, 38(4): 76-81.
- [7] ZHANG Y H, WEI C C, ZHONG Y, et al. Deep learning detection of shrimp freshness via smartphone pictures[J]. Journal of Food Measurement and Characterization, 2022, 16(5): 3 868-3 876.
- [8] 高竞博,李晔,杜闯.基于深度学习的小龙虾分级算法[J].现代计算机,2020(26):40-46.
GAO J B, LI Y, DU C. Crawfish classification algorithm based on deep learning[J]. Modern Computer, 2020(26): 40-46.
- [9] 李小占,马本学,喻国威,等.基于深度学习与图像处理的哈密瓜表面缺陷检测[J].农业工程学报,2021,37(1):223-232.
LI X Z, MA B X, YU G W, et al. Surface defect detection of Hami melon using deep learning and image processing[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(1): 223-232.
- [10] 陈斌,饶洪辉,王玉龙,等.基于Faster-RCNN的自然环境下游茶果检测研究[J].江西农业学报,2021,33(1):67-70.
CHEN B, RAO H H, WANG Y L, et al. Study on detection of *Camellia* fruit in natural environment based on Faster-RCNN [J]. Acta Agriculturae Jiangxi, 2021, 33(1): 67-70.
- [11] ELBASSUONI S, GHATTAS H, EL ATI J, et al. Deep NOVA: a deep learning NOVA classifier for food images[J]. IEEE Access, 2022, 10: 128523.
- [12] HELWAN A, SALLAM MA'AITAH M K, ABIYEV R H, et al. Deep learning based on residual networks for automatic sorting of bananas[J]. Journal of Food Quality, 2021, 2 021: 5516368.
- [13] MUKHIDDINOV M, MUMINOV A, CHO J. Improved classification approach for fruits and vegetables freshness based on deep learning[J]. Sensors, 2022, 22(21): 8 192.
- [14] MI Z W, ZHANG X D, SU J Y, et al. Wheat stripe rust grading by deep learning with attention mechanism and images from mobile devices[J]. Frontiers in Plant Science, 2020, 11: 558126.
- [15] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70-90.
- [16] 滕文想,王成,费树辉,等.基于HGTC-YOLOv8n模型的煤矸识别算法研究[J].工矿自动化,2024,50(5):52-59.
TENG W X, WANG C, FEI S H, et al. Research on coal gangue recognition algorithm based on HGTC-YOLOv8n model[J]. Journal of Mine Automation, 2024, 50(5): 52-59.
- [17] WOO W M, ORO A E. SnapShot: hair follicle stem cells[J]. Cell, 2011, 146(2): 334.
- [18] ZHANG P F, LO E, LU B T. High performance depthwise and pointwise convolutions on mobile devices[J]. Computer Science, 2020, 34(4): 6 795-6 802.
- [19] HAN K, WANG Y H, GUO J Y, et al. ParameterNet: parameters are all you need for large-scale visual pretraining of mobile networks[C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2024: 15 751-15 761.
- [20] CHEN Y P, DAI X Y, LIU M C, et al. Dynamic convolution: attention over convolution kernels[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 11 027-11 036.
- [21] WANG C Y, YEH I H, MARK LIAO H Y. YOLOv9: learning what you want to learn using programmable gradient information[C]// Computer Vision-ECCV 2024. Cham: Springer Nature Switzerland, 2025: 1-21.