

# 基于改进轻量化 YOLOv4 模型的虾只肉壳辨识方法

陈学深，吴昌鹏，党佩娜，梁俊，刘善健，武涛\*

(华南农业大学工程学院, 广州 510642)

**摘要:** 为实现虾只机械剥壳环节裸肉虾与带壳虾自动分选, 该研究提出一种基于改进 YOLOv4 模型的虾只肉壳辨识方法。将 YOLOv4 模型中 CSP-Darknet53 网络替换为 GhostNet 网络, 增强模型自适应特征提取能力及简化模型参数计算量。在 YOLOv4 主干特征提取网络 Resblock 模块中引入轻量级注意力机制, 增强主干特征提取网络的特征提取能力。将 YOLOv4 模型中 GIoU 损失函数替换为 CIoU 损失函数, 提高模型预测框的回归效果。为检测改进效果进行了不同模型对比验证, 轻量化结果表明改进 YOLOv4 模型参数量最少、计算量最小; 消融试验表明改进 YOLOv4 模型的平均精度均值为 92.8%, 比 YOLOv4 模型提升了 6.1 个百分点。不同场景下应用改进 YOLOv4 模型进行虾只肉壳辨识性能试验。结果表明: 同品种不同环境的虾只肉壳辨识总体平均准确率为 95.9%, 同品种不同剥壳方式的虾只肉壳辨识准确率平均值为 90.4%, 不同品种虾只肉壳辨识准确率平均值为 87.2%。研究结果可为裸肉虾与带壳虾自动分选提供技术支撑。

**关键词:** 机器视觉; 目标检测; 虾只; 深度学习; YOLOv4

doi: 10.11975/j.issn.1002-6819.202303076

中图分类号: S985.2

文献标志码: A

文章编号: 1002-6819(2023)09-0278-09

陈学深, 吴昌鹏, 党佩娜, 等. 基于改进轻量化 YOLOv4 模型的虾只肉壳辨识方法[J]. 农业工程学报, 2023, 39(9): 278-286. doi: 10.11975/j.issn.1002-6819.202303076 <http://www.tcsae.org>

CHEN Xueshen, WU Changpeng, DANG Peina, et al. Improved lightweight YOLOv4 model-based method for the identification of shrimp flesh and shell[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2023, 39(9): 278-286. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202303076 <http://www.tcsae.org>

## 0 引言

中国虾产量位居世界第一, 近年来增长迅速, 年产量涨幅为 12.5%<sup>[1-2]</sup>。机械剥壳是虾只生产加工的重要环节, 由于现有技术和装备不够完善, 脱壳后裸肉虾中混杂的带壳虾需要进一步人工清选, 存在劳动强度大、生产成本高、分选效率低等问题<sup>[3-4]</sup>。因此, 准确辨识裸肉虾与带壳虾实现虾只自动分选十分必要。

国内外学者主要采用机器视觉技术进行了相关研究, 分为传统图像处理和机器学习两种方法。LEE 等<sup>[5]</sup>基于大津法 (OTSU) 提取了虾只轮廓, 结合快速曲线相似度评价方法, 在蓝色背景下实现了虾只识别。罗艳<sup>[6]</sup>基于 Zhang-Suen 细化算法有效去除多余分支, 并提取了虾只主骨架线, 实现了虾只识别。上述方法主要通过设定形状、姿态阈值实现虾只识别, 识别方法对虾只光照和背景有一定要求, 抗干扰能力较差。

为提高虾只肉壳辨识的抗干扰能力, 更多学者采用机器学习方法, 主要包括人工特征选择的机器学习和自动特征提取的深度学习两种方法。HU 等<sup>[7]</sup>优选了虾只颜色、形状、纹理特征, 构建了虾识别模型。洪辰等<sup>[8]</sup>基于灰度差异法提取了虾只骨架线, 融合虾只体长、头

胸甲长、头胸甲宽等特征, 构建了虾只识别模型。上述机器学习方法识别精度高度依赖特征提取的有效性, 但不同品种、不同剥壳方式的虾只特征存在差异, 基于选择特征的机器学习方法泛化能力不理想。

深度学习在图像识别领域取得了巨大成功, 能够不依赖特定特征, 自动学习原始图像像素数据的特征表达, 可获得比原始数据表达能力更好的特征描述<sup>[9-10]</sup>。深度学习识别方法可分为两类, 一类基于区域推荐的目标检测方法<sup>[11]</sup>。龚瑞<sup>[12]</sup>采用此检测方法基于 Faster R-CNN 模型实现虾只自动识别, 准确率为 85%。另一类是基于回归的目标检测方法, 该方法可实现端到端的网络结构, 具有较高的识别精度, 目前应用最为广泛<sup>[13-14]</sup>。其中, YOLO<sup>[15-16]</sup>系列最典型。刘雄<sup>[17]</sup>采用 Darknet 作为 YOLOv4 模型特征提取网络, 对虾只剥壳效果进行检测, 准确率达 90% 以上。王淑青等<sup>[18]</sup>采用 CIoU 作为 YOLOv4 模型的损失函数, 有效提高了预测框回归效果, 同时引入 CBAM 注意力机制增强模型特征抓取能力, 模型检测准确率为 97.8%。虽然改进 YOLOv4 模型在识别精度方面获得了较好的效果, 但仍存在网络结构复杂、资源占用多等问题。为此, 许多学者针对 YOLOv4 主干特征提取网络进行轻量化处理<sup>[19-21]</sup>, 目前较成熟的轻量级网络有 Google 的 MobilenetV3 系列<sup>[23]</sup>和 Efficientnet Lite 系列<sup>[24]</sup>, 旷世的 Shufflenet 系列<sup>[25]</sup>, 华为的 GhostNet<sup>[26]</sup>等, 上述轻量级网络在一定程度上提高了模型的检测效率。

本文根据虾只肉壳辨识要求, 在 YOLOv4 模型基础上, 通过替换主干特征提取网络、引入轻量级注意力机

收稿日期: 2023-03-13 修订日期: 2023-04-06

基金项目: 广东省重点领域研发计划项目 (2021B0202060002)

作者简介: 陈学深, 博士, 副教授, 研究方向为现代农业技术与智能装备。

Email: chenxs@scau.edu.cn

\*通信作者: 武涛, 副教授, 研究方向为现代农业技术装备。Email: wt55pub@126.com

制、替换损失函数等改进方法, 构建了裸肉虾与带壳虾的辨识模型实现虾只自动分选。

## 1 数据集与预处理

### 1.1 图像采集

模型样本为经过去头处理的中国明对虾, 经夹尾、开背、去肠、脱壳等机械剥壳处理, 单只对虾落料在传送带上, 由虾只肉壳辨识试验台进行裸肉虾与带壳虾辨识分选。图像采集于华南农业大学工程学院虾只肉壳辨识试验台, 如图 1 所示。试验台尺寸为 190 cm×30 cm×90 cm, 传送带输送速度为 0.1 m/s。图像采集设备为 HIKVISION 工业相机, 有效像素为 1800 万。样本采集时天气晴朗, 分为白天和晚上 2 个时段, 其中晚上采用人工光源。采集时相机镜头与水平方向分别以 30°、45°、75°、90°夹角拍摄, 图像分辨率为 2928×3904 (像素), 原图像保存为 jpg 格式, 总计拍摄 1400 张图像, 人工筛选出质量高、画质清晰的 1321 张作为图像数据集。



1. 相机 2. 输送装置 3. 分选装置驱动电机 4. 肉壳分选装置  
1. Camera 2. Conveyor 3. Sorter drive motor 4. Meat shell sorting device

图 1 虾只肉壳辨识试验台

Fig.1 Shrimp meat and shell identification test bench

### 1.2 图像预处理

为提高训练效果、增强模型泛化能力, 对采集图像进行预处理。运用 OpenCV 改变原始图像亮度和对比度以模拟不同光照射度下的环境状况; 引入高斯噪声与椒盐噪声, 扰乱图像可观测信息, 提升模型对目标的捕捉能力; 进行图像旋转, 增加检测目标的姿态。通过图像预处理增加了裸肉虾图像 622 张, 带壳虾图像 699 张, 图像数据集增强效果如图 2 所示。为降低信息泄露, 更准确反映模型效能, 保证模型分辨准确率, 将训练集和测试集按 9:1 进行划分, 训练集为 2387 张, 验证集为 264 张。同时使用 Labelimg 对处理的虾只图像进行标注, 生成与图片名称相对应的 XML 文件。

## 2 YOLOv4 网络模型改进

### 2.1 幻象模块 (Ghost Module) 引入

YOLOv4 模型由许多基本结构块组成, 但由于大量卷积模块计算得到的中间特征图存在高度冗余, 导致模型计算量增加<sup>[27-29]</sup>。本文引入幻象模块 (Ghost Module) 使 YOLOv4 模型更加紧凑, 通过减少冗余特征图, 提升

主干特征提取网络的运算速度。采用幻象模块对输入图像进行处理, 流程如图 3 所示, 具体实现步骤为: 1) 输入图像经标准卷积运算生成原始特征图; 2) 原始特征图经低成本深度卷积得特征图  $\varphi$ ; 3) 特征图经标准卷积运算输出叠加特征图。

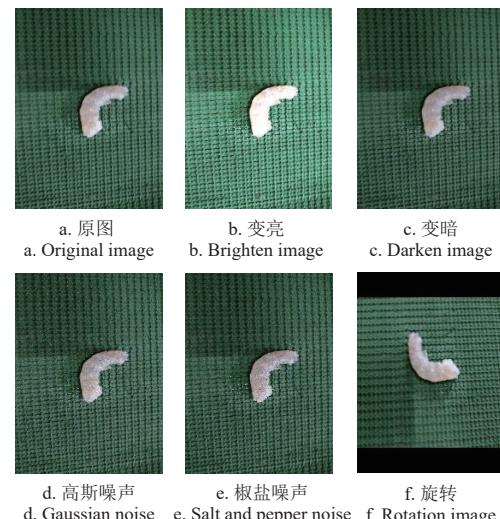
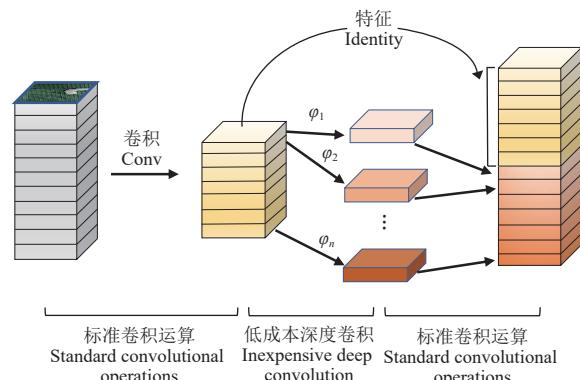


图 2 虾只图像数据集增强  
Fig.2 Shrimp image dataset enhancement



注:  $\varphi_n$  为第  $n$  个特征图。  
Note:  $\varphi_n$  is the  $n$ -th feature map.

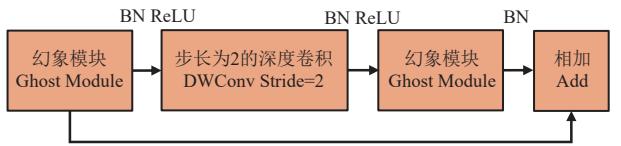
图 3 幻象模块示意图  
Fig.3 Ghost module diagram

模型引入幻象模块后, 可代替 YOLOv4 模型的普通卷积, 为主干特征提取网络替换提供了基础。

### 2.2 主干特征提取网络替换

构建特征金字塔时, YOLOv4 主干特征提取网络 CSPDarknet53 会将 3 个有效特征层分别传入到加强特征提取网络 SPP 和 PANet 中<sup>[30-31]</sup>, 由于此过程需要进行大量卷积计算, 降低了网络运算速率。幻象瓶颈结构通过对图像特征层“可分离卷积—深度可分离卷积和普通卷积—可分离卷积”处理, 实现特征层宽高压缩, 使模型更轻量化。

为减少卷积计算量, 在改进 YOLOv4 网络中利用 Ghost Module 代替 CSPDarknet53 中的普通卷积获得幻象瓶颈结构 (Ghost bottleneck), 如图 4 所示。



注: BN ReLU 为批标准化与 ReLU 激活函数的组合, BN 为批标准化。  
Note: BN ReLU is a combination of the batch normalisation and ReLU activation function, BN denotes batch normalisation.

图 4 幻象瓶颈结构  
Fig.4 Ghost bottleneck structure

本文将输入层的图像大小调整为  $416 \times 416 \times 3$ , 并使用 Ghost Module 代替普通卷积, 组成轻量化神经网络 GhostNet, 得到第一有效特征层(尺寸为  $52 \times 52 \times 40$ )、第二有效特征层(尺寸为  $26 \times 26 \times 112$ )、第三有效特征层(尺寸为  $13 \times 13 \times 160$ ) 3 个有效特征层, 模型经过改进后减少了储存容量, 改进前和改进后有效特征层尺寸大小如表 1 所示。由表 1 可知, GhostNet 主干特征提取网络比原 CSPDarknet53 主干特征提取网络的有效特征层更为轻量化, 进而提高了模型的检测效率。

表 1 有效特征层尺寸大小对比

Table 1 Comparison of effective feature layer size

主干特征提取网络 Backbone feature extraction network	有效特征层尺寸 Effective feature layer size		
	第一层 First layer	第二层 Second layer	第三层 Third layer
	$52 \times 52 \times 256$	$26 \times 26 \times 512$	$13 \times 13 \times 1024$
CSPDarknet53	$52 \times 52 \times 40$	$26 \times 26 \times 112$	$13 \times 13 \times 160$
GhostNet			

### 2.3 注意力机制嵌入

注意力机制模仿人类大脑视觉注意力机制, 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>[32-34]</sup>。为提高改进 YOLOv4 模型虾只肉壳辨识准确率, 在预测端嵌入典型 SE 注意力机制模块, 拟合目标通道相关特征信息, 提高模型抗干扰和特征提取能力。SE 注意力机制处理流程如图 5 所示, 具体实现步骤为:

- 1) 对输入特征图  $X(h' \times w' \times l)$  进行转换, 生成长为  $h$ 、宽为  $w$ 、通道为  $l$  的通道特征图像  $Y$ ;
- 2) SE 模块对输入特征图  $X$  做全局平均池化, 将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, 有效提升对图像的关注能力;
- 3) 通过挤压(Squeeze)操作将  $h \times w \times l$  的特征图压缩为  $1 \times 1 \times l$  特征图, 压缩层操作算法如式(1)所示;
- 4) 通过激励(Excitation)操作使用两层全连接自适应学习生成权重  $S$ , 激励操作算法如式(2)所示;
- 5) 将通道注意力的权重  $S(1 \times 1 \times l)$ 、原始输入特征图  $Y(h \times w \times l)$ , 进行逐通道乘以权重系数, 输出具有通道注意力的特征图  $\tilde{X}(h \times w \times l)$ 。

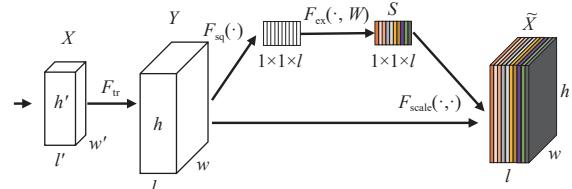
$$Z = F_{\text{sq}} = \sum_{i=1}^H \sum_{j=1}^W u(i, j) / (H \times W) \quad (1)$$

式中  $u(i, j)$  为特征图上的单个特征值,  $Z$  为通道特征图的平均特征值,  $H$  为特征图的高度,  $W$  为特征图的宽度。

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

式中  $w_1$ 、 $w_2$  分别为两个全连接层的权值,  $\delta$  为连接层的 ReLU 激活函数,  $\sigma$  为 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。



注:  $X$  表示输入特征图,  $Y$  表示经过特征转换的原始输入特征图,  $S$  表示通道注意力的权重,  $\tilde{X}$  表示具有通道注意力的特征图,  $h' \times w' \times l'$  表示输入特征图尺寸,  $h \times w \times l$  表示经过特征转换的原始输入特征图尺寸,  $1 \times 1 \times l$  表示权重尺寸,  $F_{\text{tr}}$  表示特征图转换,  $F_{\text{sq}}(\cdot)$  表示挤压操作,  $F_{\text{ex}}(\cdot, W)$  表示激励操作,  $F_{\text{scale}}(\cdot, \cdot)$  表示规范化操作。

Note:  $X$  for the input feature map,  $Y$  for the original input feature map after feature transformation,  $S$  for the weight of channel attention,  $\tilde{X}$  for the feature map with channel attention,  $h' \times w' \times l'$  for the input feature map size,  $h \times w \times l$  for the original input feature map size after feature transformation,  $1 \times 1 \times l$  for the weight size,  $F_{\text{tr}}$  for feature map transformation,  $F_{\text{sq}}(\cdot)$  for squeezing operation,  $F_{\text{ex}}(\cdot, W)$  for excitation operation,  $F_{\text{scale}}(\cdot, \cdot)$  for scaling operation.

图 5 SE 注意力机制流程图

Fig.5 SE attention mechanism flowchart

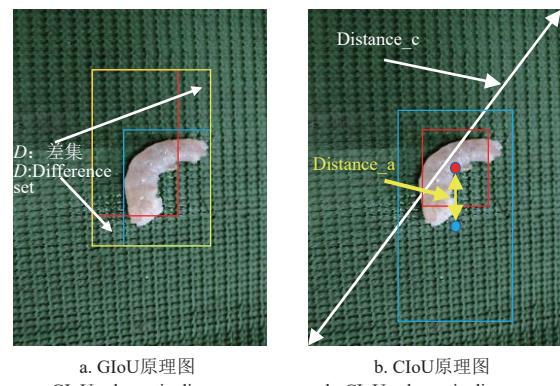
### 2.4 CIoU 损失函数设计

合理选择损失函数可以使检测框更适合虾只尺寸, 有助于提高模型收敛速度。YOLOv4 模型中采用 GIoU 损失函数作为位置回归损失的评价指标, 计算如式(3)所示。

$$G_{\text{IoU}} = \frac{|A \cap B|}{|A \cup B|} - \frac{|C/(A \cap B)|}{|C|} \quad (3)$$

式中  $A$  为预测框,  $B$  为真实框,  $C$  为包含  $A$  和  $B$  的最小凸集。

GIoU 损失函数原理如图 6a 所示, 针对检测框位置或大小不同时, 增加了相交尺度的衡量方式, 但 GIoU 损失函数无法区分相对位置关系, 例如检测框面积相同且在标注框内部不同位置时, 检测框和标注框差集  $D$  相同, 导致模型目标检测误差增大。相比较, ZHENG 等<sup>[35]</sup>提出的 CIoU 损失函数可有效区分相对位置关系, 减小目标检测误差, 原理如图 6b 所示, 计算式如(4)~(7)所示。



a. GIoU 原理图

a. GIoU schematic diagram

b. CIoU 原理图

b. CIoU schematic diagram

注: 黄框为最小外接矩形; 红框为检测框; 蓝框为标注框。Distance-a 为标注框和预测框中心点坐标距离, Distance-c 为最小外接矩形对角线距离。

Note: Yellow box is minimum outer rectangle; red box is detection box; blue box is labelling box. Distance-a is the coordinate distance between the center point of the dimension box and the prediction box, Distance-c is the minimum circumscribed rectangular diagonal distance.

图 6 GIoU 和 CIoU 原理图

Fig.6 GIoU and CIoU schematic diagram

$$C_{IoU} = I_{IoU} - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \quad (4)$$

$$\alpha = \frac{v}{1 - I_{IoU} + v} \quad (5)$$

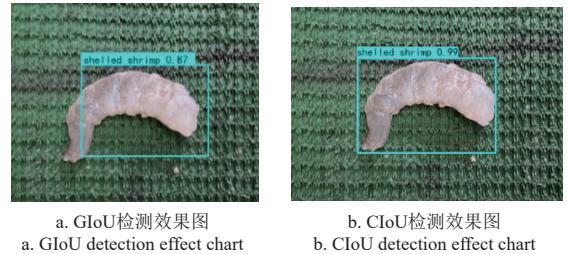
$$v = \frac{4}{\pi^2} (\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h})^2 \quad (6)$$

$$C_{IoU} = 1 - I_{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (7)$$

式中  $\rho^2(b, b^{gt})$  为预测框和真实框中心点的欧式距离,  $I_{IoU}$  为交并比,  $\alpha$  为权衡参数,  $v$  为宽高比度量函数,  $w$ 、 $h$  和  $w^{gt}$ 、 $h^{gt}$  分别为预测框高宽和真实框高宽,  $c$  为能够同时包含预测框和真实框最小闭包区域的对角线距离,  $C_{IoU}$  为 ClIoU Loss 函数。

与 GIoU 损失函数相比, ClIoU 损失函数考虑重叠面积、中心点距离和宽高比, 可以直接最小化检测框和标注框中心点之间距离, 使非极大值抑制得到的结果更为合理有效, 模型预测框更为准确。GIoU 和 ClIoU 损失函数的框选效果如图 7 所示, 由图 7 可知 GIoU 损失函数

预测框未能将虾只完整框选, 而 ClIoU 损失函数预测框则完整框选了虾只。



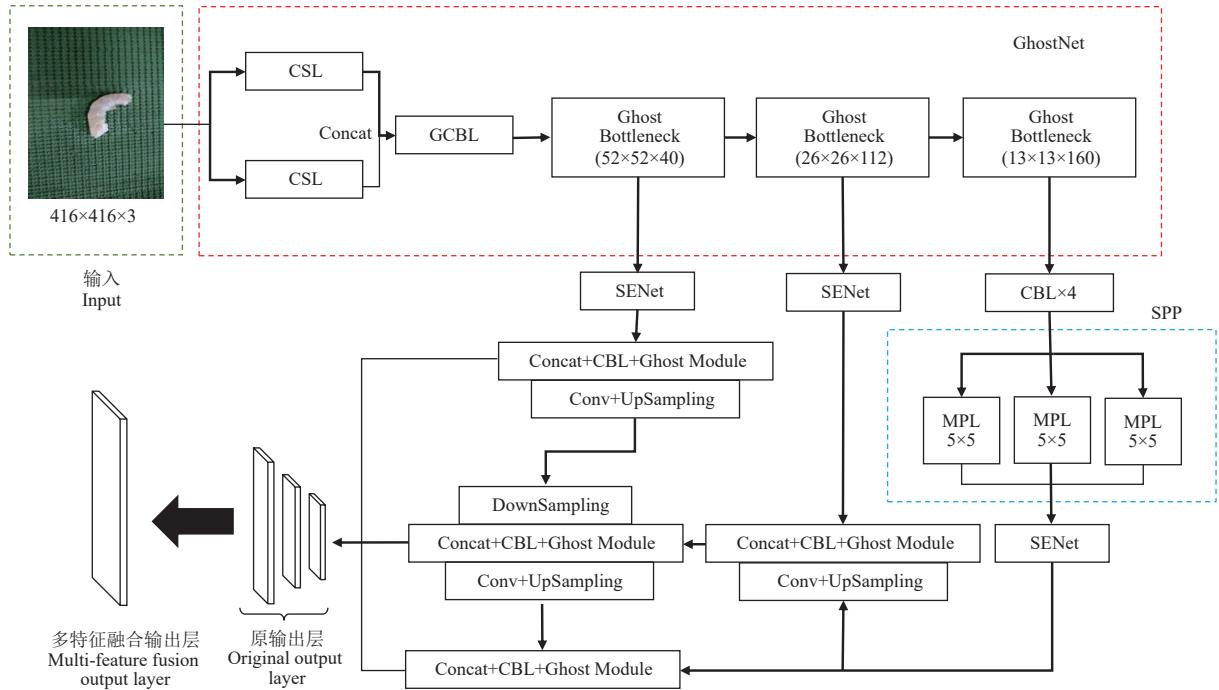
a. GIoU detection effect chart  
b. ClIoU detection effect chart

Fig. 7 不同损失函数的框选效果

Effects of frame selection with different loss functions

## 2.5 改进后的 YOLOv4 网络模型

YOLOv4 模型经过主干特征提取网络替换、SE 注意力机制嵌入、ClIoU 损失函数设计, 构建的改进 YOLOv4 网络模型 (GhostNet-YOLOv4) 结构如图 8 所示, 模型经过改进减少了运算量、增强了特征通道间的关注度、提高了预测框的回归效果, 可有效提升模型检测准确率和实时性。



注: Conv 表示卷积, CBL 表示卷积、BN 层与 ReLU 激活函数模块的组合, CSL 表示 Cross-Stage Lightweight 模块、BN 层与 ReLU 激活函数模块的组合, GCBL 表示幻象模块、BN 层与 ReLU 激活函数模块的组合, Ghost Bottleneck 表示幻象瓶颈结构, MPL 表示最大池化层, SENet 表示 SE 注意力机制, Concat 表示连接特征图, Ghost Module 表示幻象模块, UpSampling 表示上采样, DownSampling 表示下采样。

Note: Conv indicates convolution, CBL indicates combination of convolution, BN layer and ReLU activation function module, CSL indicates Cross-Stage lightweight module, GCBL indicates combination of phantom module, BN layer and ReLU activation function module, Ghost Bottleneck indicates phantom bottleneck structure, MPL indicates maximum pooling layer. SENet denotes SE attention mechanism, Concat denotes connected feature map, Ghost Module denotes phantom module, UpSampling denotes upsampling and DownSampling denotes downsampling.

图 8 改进 YOLOv4 网络结构图  
Fig.8 Improved YOLOv4 network architecture diagram

## 2.6 评价指标

采用召回率 (recall,  $R$ , %)、准确率 (precision,  $P$ , %)、 $A_P$  值 (average precision,  $A_P$ , %) 和 mAP (mean average precision, %) 4 个指标对模型进行性能评估, 计算如式 (8) ~ (11) 所示。

$$R = \frac{T_P}{T_P + F_N} \quad (8)$$

$$P = \frac{T_P}{T_P + F_P} \quad (9)$$

$$A_P = \int_0^1 P(R) dR \times 100\% \quad (10)$$

$$mAP = \frac{1}{M} \sum_{k=1}^M A_P(k) \times 100\% \quad (11)$$

式中  $T_P$  和  $F_P$  分别表示真实的正样本和虚假的正样本,  $F_N$  为虚假的负样本,  $M$  为检测目标的类别总数,  $A_P(k)$  为

第  $k$  类  $A_p$  值。

### 3 结果与分析

#### 3.1 不同模型轻量化对比

为检验模型改进效果, 选择 YOLOv7、EfficientNet Lite3-YOLOv4、ShuffleNetV2-YOLOv4、MobilenetV3-YOLOv4 模型, 以及改进 YOLOv4 模型进行轻量化对比验证, 结果如表 2 所示, 由表 2 可知, 改进 YOLOv4 模型参数量最少、计算量最小、轻量化程度最高。

表 2 不同目标识别模型比较

Table 2 Comparison of different target recognition models

指标 Index	YOLO v7	EfficientNet Lite3- YOLOv4	ShuffleNet V2-YOLOv4	Mobilenet V3-YOLOv4	改进 YOLOv4
					Improved YOLOv4
参数量 Params/M	36.49	12.38	12.27	11.31	11.01
计算量 Calculated amount/ ( $10^9$ 次· $s^{-1}$ )	103.51	7.72	10.09	7.13	6.59

#### 3.2 试验平台与模型训练结果

试验训练集包含裸肉虾图像为 1 064 张, 带壳虾图像为 1 109 张, 两者共存 214 张。采用 Pytorch-GPU1.2 深度学习框架, 运行的深度学习处理器为 Intel Core-i5-12 400, 3.20 GHz, 显卡为 GeForce RTX 3 080, 操作系统为 Windows 10, NVIDIA 461.37 驱动, CUDA11 版本, CUDNN 神经网络加速库版本为 7.6.5。基于试验平台硬件运行性能设置迭代训练样本数为 8, 根据拟合效果选择迭代次数为 500 次。为提高模型稳定性避免训练后期震荡设置动量因子为 0.973, 衰减系数为 0.005, 初始学习率为 0.001, 优化器选择 sgd, 使用 Mosaic 数据增强与余弦退火算法。训练完成后根据后台日志信息记录绘制模型训练损失值变化趋势图, 如图 9 所示。由图 9 可知, 模型随迭代次数增加, 损失值逐渐减少。GhostNet-YOLOv4 模型经历 20 次迭代后, 模型损失值收敛到 2.5 以下, 至 350 次迭代后损失值趋于平稳, 趋于稳定后 GhostNet-YOLOv4 模型损失值为 1.2, 相比 YOLOv4 模型损失值减少了 1.2, 比 YOLOv3 模型损失值减少了 1.8, 比 MobilenetV3-YOLOv4 模型损失值减少了 0.2, 验证了 GhostNet-YOLOv4 模型识别准确性较优。

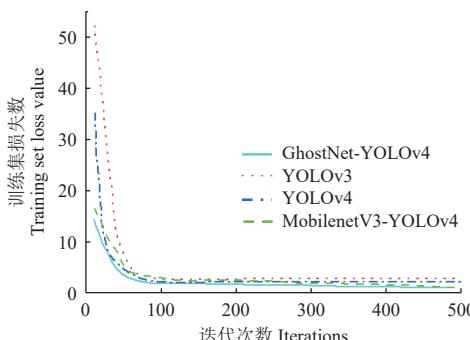


图 9 模型训练损失值变化趋势图

Fig.9 Model training loss value change trend diagram

#### 3.3 虾只肉壳辨识模型消融试验

为验证主干特征提取网络 GhostNet 替换、SE 注意力机制嵌入和 CIoU 损失函数设计的改进效果, 采用平均精度均值 (mAP)、参数量、权重作为模型性能评价指标进行消融试验, 结果如表 3 所示, 由表 3 可知, 模型经过 GhostNet 替换后 mAP 提升了 2.9 个百分点, 加入 SE 注意力机制后 mAP 提升了 1.8 个百分点, CIoU 损失函数设计后 mAP 提升了 1.4 个百分点。改进 YOLOv4 模型的平均精度均值为 92.8%, 而 YOLOv4 模型平均精度均值为 86.7%, 提高了 6.1 个百分点。模型改进后参数量和权重明显减少。

表 3 消融试验结果对比

Table 3 Comparison of ablation test results

GhostNet	SE	CIoU	平均精度均值 mAP/%	参数量 Params/M	权重 Weights/MB
—	—	—	86.7	63.94	243.92
√	—	—	89.6	11.43	43.54
√	√	—	91.4	11.48	43.71
√	√	√	92.8	11.48	43.71

注: “√”表示加入该模块, “—”表示不执行此操作。mAP 是交并比阈值取 0.5 时的平均精度均值。

Note: “√” indicates joining the module, and “—” means that this operation is not performed. mAP is the average accuracy mean when the intersection to union ratio threshold is taken as 0.5.

#### 3.4 虾只肉壳辨识效果

为验证 GhostNet-YOLOv4 模型在不同环境虾只肉壳辨识的有效性, 选择阴天及晴天傍晚等光照不足时段, 以及在传送带速度为 0.1 m/s 输送状态下进行辨识效果试验。本文以相同训练集、不同模型进行训练与测试, 基于 YOLOv3、YOLOv4、MobilenetV3-YOLOv4 和 GhostNet-YOLOv4 模型在相同测试集上进行测试, 虾只肉壳辨识测试集共 1 000 张照片, 部分结果如图 10 所示。

光照充足时, 各模型均可完成虾只肉壳辨识。然而, 光照不足时, YOLOv4 和 MobilenetV3-YOLOv4 检测准确率明显下降, YOLOv3 模型甚至无法辨识或辨识错误。与其他模型比较, 虾只输送时, GhostNet-YOLOv4 的检测准确率与置信度最高。

GhostNet-YOLOv4、YOLOv3、YOLOv4 和 Mobilenet V3-YOLOv4 模型的裸肉虾和带壳虾辨识准确率  $P$ 、召回率  $R$  曲线如图 11 所示, 由图 11 可知, GhostNet-YOLOv4 的  $P-R$  曲线包围面积最大, 说明虾只肉壳辨识准确率最高。

不同模型的裸肉虾和带壳虾辨识结果如表 4 所示, 与 YOLOv3、YOLOv4、MobilenetV3-YOLOv4 模型相比, GhostNet-YOLOv4 模型裸肉虾识别准确率分别提高了 6.9、3.5、1.1 个百分点, 带壳虾识别准确率分别提高了 9.2、3.8、2.7 个百分点, 模型总体识别准确率分别提高了 8.1、3.7、1.9 个百分点。与其他模型相比, GhostNet-YOLOv4 模型检测速度最高, 为 25 帧/s, 模型综合性能最优。

#### 3.5 不同剥壳方式虾只肉壳辨识效果

为验证不同剥壳方式虾只肉壳辨识的实际效果, 根据图 12 所示的虾只不同剥壳方式, 进行去尾虾、深切虾、带尾虾、蝴蝶虾的辨识性能试验, 测试集共 1 815 张图片, 其中去尾虾 422 张、深切虾 464 张、带尾虾 519 张、蝴蝶虾 410 张。结果如表 5 所示。

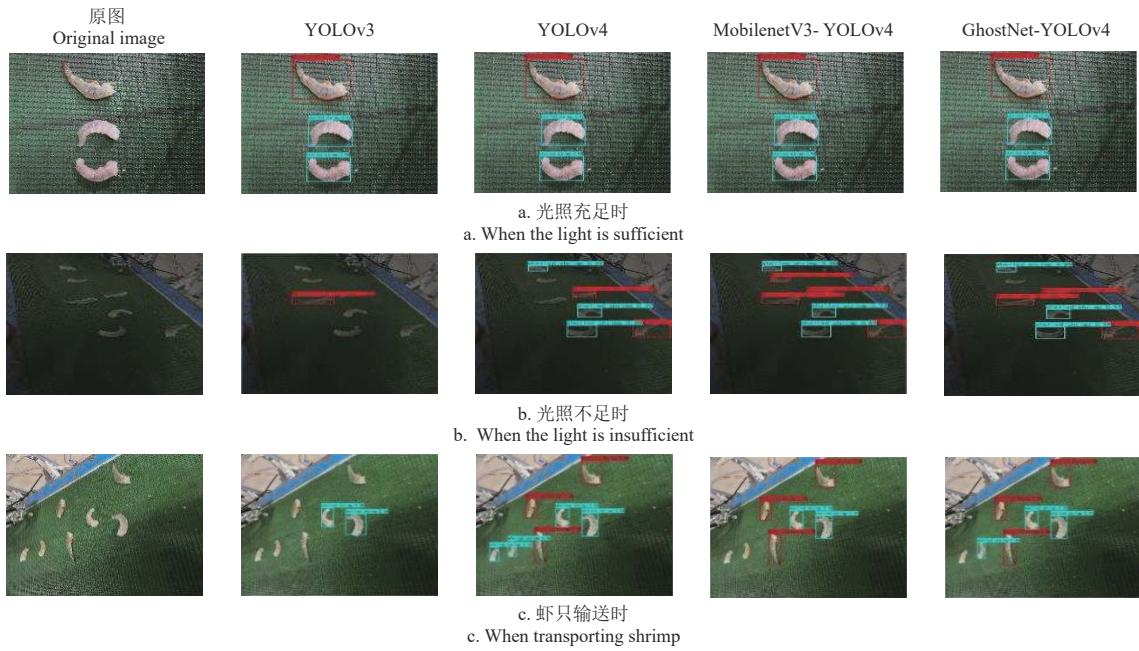


图 10 不同条件下各模型虾只肉壳检测效果

Fig.10 The detection effect of shrimp in different models under different conditions

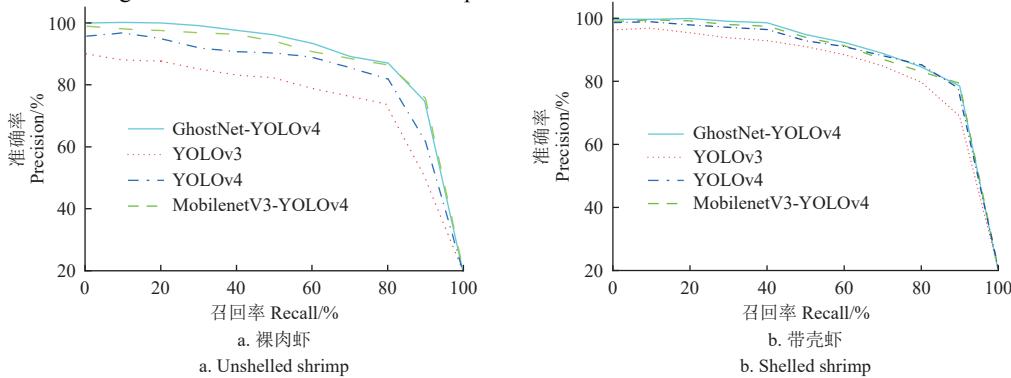


图 11 准确率-召回率曲线图

Fig.11 Precision- recall curve diagram

表 4 不同模型虾只肉壳检测结果

Table 4 Results of shrimp meat and shell detection with different training models

模型 Models	裸肉虾识别准确率 Unshelled shrimp recognition precision/%	带壳虾识别准确率 Shelled shrimp recognition precision/%	总体平均准确率 Overall average precision/%	帧率 FPS/(帧·s <sup>-1</sup> )
YOLOv3	88.4	87.2	87.8	15.7
YOLOv4	91.8	92.6	92.2	13.6
MobilenetV3-YOLOv4	94.2	93.7	94.0	23.4
GhostNet-YOLOv4	95.3	96.4	95.9	25.0

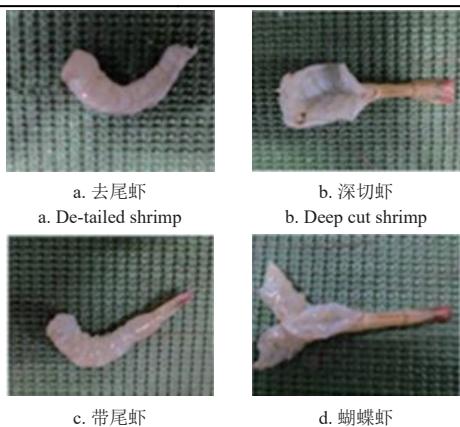


图 12 不同剥壳方式的虾只

Fig.12 Shrimps with different shelling methods

由表 5 可知, GhostNet-YOLOv4 模型辨识准确率平均值为 90.4%, 与 YOLOv3、YOLOv4、MobilenetV3-YOLOv4 模型相比, 辨识准确率平均值分别提高了 10.6、4.5、3.9 个百分点。但受剥壳方式影响, 深切虾和蝴蝶虾由于虾体面积大, 易造成肉壳相互遮挡, 模型辨识准确率较无遮挡的去尾虾和带尾虾略低, 但与其他模型相比, GhostNet-YOLOv4 模型辨识准确率降幅最小。

### 3.6 不同品种虾只肉壳辨识效果

为验证虾只肉壳辨识模型对不同品种虾的适应性, 选择图 13 所示的黑虎虾、罗氏虾、日本对虾 3 种常见虾只进行辨识性能试验, 测试集共 1432 张图片, 其中罗氏虾 437 张、黑虎虾 477 张、日本对虾 518 张。结果如表 6 所示。

由表 6 可知, GhostNet-YOLOv4 模型的虾只肉壳辨

识准确率最高，平均值为 87.2%，与 YOLOv3、YOLOv4、MobilenetV3-YOLOv4 模型相比，准确率平均值分别提高了 22.1、12、8 个百分点。受虾只品种影响，上述 3 个品种的虾只没有经过样本训练，但与其他模型相比，GhostNet-YOLOv4 模型辨识准确率降幅最小。

表 5 不同剥壳方式虾只肉壳辨识准确率

Table 5 Precision of shrimp meat and shell recognition for different shelling methods

剥壳方式 Shelling methods	YOLOv3	YOLOv4	Mobilenet V3-YOLOv4	GhostNet- YOLOv4	%
去尾虾 De-tailed shrimp	87.4	92.5	91.7	94.5	
深切虾 Deep cut shrimp	75.2	83.4	85.3	87.7	
带尾虾 Shrimp with tail	79.4	84.6	85.7	93.8	
蝴蝶虾 Butterfly shrimp	77.1	82.9	83.2	85.6	
平均值 Average	79.8	85.9	86.5	90.4	



图 13 不同品种的虾只

Fig.13 Shrimps of different species

表 6 不同品种虾只肉壳辨识准确率

Table 6 Precision of shrimp meat and shell recognition for different species

品种 Species	YOLOv3	YOLOv4	Mobilenet V3-YOLOv4	GhostNet- YOLOv4	%
罗氏虾 Roughy's shrimp	64.3	71.2	76.9	84.2	
黑虎虾 Black tiger shrimp	70.2	78.6	82.4	86.8	
日本对虾 Japanese shrimp	63.7	75.7	78.2	90.7	
平均值 Average	66.1	75.2	79.2	87.2	

## 4 结 论

1) 构建了改进轻量化 YOLOv4 模型，与 YOLOv7、EfficientNet Lite3-YOLOv4、ShuffleNetV2-YOLOv4、MobilenetV3-YOLOv4 模型对比，改进的模型参数量最少、计算量最小。消融试验表明改进的模型平均精度均值为 92.8%，比原 YOLOv4 模型提升了 6.1 个百分点。

2) 本文通过 GhostNet 主干特征提取网络替换、SE 注意力机制引入、CIoU 损失函数设计对 YOLOv4 网络模型进行改进，有效提高了虾只肉壳辨识性能，构建的 GhostNet-YOLOv4 模型总体平均识别准确率为 95.9%，检测速度为 25.0 帧/s。

3) 对构建的 GhostNet-YOLOv4 模型进行性能试验。结果表明，不同剥壳方式虾只肉壳辨识准确率平均值为 90.4%，不同品种虾只肉壳辨识准确率平均值为 87.2%。

## [参 考 文 献]

- CHANG Z Q, NEORI A, HE Y Y, et al. Development and current state of seawater shrimp farming, with an emphasis on integrated multi - trophic pond aquaculture farms, in China a review[J]. *Reviews in Aquaculture*, 2020, 12(4): 2544-2558.
- 刘子豪, 张素兰, 贾小军, 等. 基于自适应卷积神经网络的染病虾识别方法[J]. 农业机械学报, 2022, 53(5): 246-256.
- LIU Zihao, ZHANG Sulan, JIA Xiaojun, et al. Diseased shrimp identification method based on adaptive convolutional neural networks[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(5): 246-256. (in Chinese with English abstract)
- EINARSDÓTTIR H, GUÐMUNDSSON B, ÓMARSSON V. Automation in the fish industry[J]. *Animal Frontiers*, 2022, 12(2): 32-39.
- 张秀花, 赵庆龙, 赵玉达, 等. 对虾对辊挤压式剥壳工艺参数及预处理条件优化[J]. 农业工程学报, 2014, 30(14): 308-314. ZHANG Xiuhua, ZHAO Qinglong, ZHAO Yuda, et al. Parameter and pretreatment condition optimization of dual rollers extrusion peeling device for *Litopenaeus vannamei*[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2014, 30(14): 308-314. (in Chinese with English abstract)
- LEE D J, XIONG G M, LANE R M, , et al. An efficient shape analysis method for shrimp quality evaluation[C]//2012 12th International Conference on Control Automation Robotics & Vision (ICARCV). Guangzhou, China, 2012.
- 罗艳. 基于机器视觉技术的对虾规格检测方法研究 [D]. 杭州: 浙江大学, 2013.
- LUO Yan. Research On Shrimp Size Detection Method Based On Machine Vision Technology [D]. Hangzhou: Zhejiang University, 2013. (in Chinese with English abstract).
- HU W C, YANG C Y, HUANG D Y. Robust real-time ship detection and tracking for visual surveillance of cage aquaculture.[J]. *Journal of Visual Communication & Image Representation*, 2011, 22(6): 543-556.
- 洪辰, 刘子豪, 汪许倩, 等. 基于形态学特征的对虾完整性识别方法构建[J]. 食品安全质量检测学报, 2021, 12(22): 8666-8673.
- HONG Chen, LIU Zihao, WANG Xuqian, et al. Construction of completeness recognition method for shrimp (*Litopenaeus vannamei*) based on morphological characteristics[J]. *Journal of Food Safety & Quality*, 2021, 12(22): 8666-8673. (in Chinese with English abstract)
- LIU Z H. Soft-shell shrimp recognition based on an improved AlexNet for quality evaluations.[J]. *Journal of Food Engineering*, 2020, 266: 109698.
- LIU Z H, JIA X J, XU X S. Study of shrimp recognition methods using smart networks[J]. *Computers & Electronics in Agriculture*, 2019, 165: 104926.
- GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE Computer Society: Piscataway, 2014: 580-587.

- [12] 龚瑞. 基于计算机视觉的鱼虾识别和形态参数测量 [D]. 厦门: 厦门大学, 2018.
- GONG Rui. Computer Vision-Based Fish And Shrimp Identification And Morphological Parameter Measurement [D]. Xiamen: Xiamen University, 2018. (in Chinese with English abstract).
- [13] 孔维刚, 李文婧, 王秋艳, 等. 基于改进 YOLOv4 算法的轻量化网络设计与实现[J]. 计算机工程, 2022, 48(3): 181-188.
- KONG Weigang, LI Wenjing, WANG Qiuyan, et al. Design and implementation of lightweight network based on improved YOLOv4 algorithm[J]. Computer Engineering, 2022, 48(3): 181-188. (in Chinese with English abstract)
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//European Conference on Computer Vision. German: Springer, 2016: 21-37.
- [15] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society: Piscataway, 2017: 7263-7271.
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 779-788.
- [17] 刘雄. 基于深度学习的对虾剥壳识别与计数方法研究 [D]. 保定: 河北农业大学, 2020.
- LIU Xiong. Research on Shrimp Shelling Recognition and Counting Method Based on Deep Learning[D]. Baoding: Hebei Agricultural University, 2020.
- [18] 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 Shuqing, HUANG Jianfeng, ZHANG Pengfei, et al. A YOLOv4 neural network-based quality inspection method for crayfish[J]. Food and Machinery, 2021, 37(3): 120-124,194. (in Chinese with English abstract)
- [19] 周桂红, 马帅, 梁芳芳. 基于改进 YOLOv4 模型的全景图像苹果识别[J]. 农业工程学报, 2022, 38(21): 159-168.
- ZHOU Guihong, MA Shuai, LIANG Fangfang. Recognition of the apple in panoramic images based on improved YOLOv4 model[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2022, 38(21): 159-168. (in Chinese with English abstract)
- [20] 张伏, 陈自均, 鲍若飞, 等. 基于改进型 YOLOv4-LITE 轻量级神经网络的密集圣女果识别 [J]. 农业工程学报, 2021, 37(16): 270-278.
- ZHANG Fu, CHEN Zijun, BAO Ruofei, et al. Recognition of dense cherry tomatoes based on improved YOLOv4-LITE lightweight neural network[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2021, 37(16): 270-278. (in Chinese with English abstract).
- [21] 孙俊, 陈义德, 周鑫, 等. 快速精准识别棚内草莓的改进 YOLOv4-Tiny 模型[J]. 农业工程学报, 2022, 38(18): 195-203.
- SUN Jun, CHEN Yide, ZHOU Xin, et al. Fast and accurate recognition of the strawberries in greenhouse based on improved YOLOv4-Tiny model[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2022, 38(18): 195-203. (in Chinese with English abstract)
- [22] 张兆国, 张振东, 李加念, 等. 采用改进 YoloV4 模型检测复杂环境下马铃薯[J]. 农业工程学报, 2021, 37(22): 170-178.
- ZHANG Zhaoguo, ZHANG Zhendong, LI Jianian, et al. Potato detection in complex environment based on improved YoloV4 model[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2021, 37(22): 170-178. (in Chinese with English abstract)
- [23] BILANG J M D, BALBUENA P A A L, VILLAVERDE J F. Cactaceae detection using MobileNet architecture[C]//2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), Manila, Philippines: IEEE, 2021: 1-5.
- [24] KURIAKOSE B, SHRESTHA R, SANDNES F E. SceneRecog: a deep learning scene recognition model for assisting blind and visually impaired navigate using smartphones[C]//2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Melbourne, Australia: IEEE, 2021: 2464-2470.
- [25] FAN Z, HU W, GUO H, et al. Hardware and algorithm co-optimization for pointwise convolution and channel shuffle in ShuffleNet V2[C]//2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC) , Melbourne, Australia: IEEE, 2021: 3212-3217.
- [26] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, Seattle, USA: IEEE, 2020: 1580-1589.
- [27] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition, Seattle, USA: IEEE, 2020: 1-17.
- [28] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops, Seattle, USA: IEEE, 2020: 390-391.
- [29] 梁晓婷, 庞琦, 杨一, 等. 基于 YOLOv4 模型剪枝的番茄缺陷在线检测[J]. 农业工程学报, 2022, 38(6): 283-292.
- LIANG Xiaoting, PANG Qi, YANG Yi, et al. Online detection of tomato defects based on YOLOv4 model pruning[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(6): 283-292. (in Chinese with English abstract)
- [30] MIN K, LEE G H, LEE S W. Attentional feature pyramid network for small object detection[J]. Neural Networks, 2022, 155: 439-450.
- [31] 张日红, 区建爽, 李小敏. 基于改进 YoloV4 的轻量化菠萝苗心检测算法[J]. 农业工程学报, 2023, 39(4): 135-143.
- ZHANG Rihong, OU Jianshuang, LI Xiaomin, et al. Lightweight algorithm for pineapple plant center detection based on improved an YoloV4 model[J]. Transactions of the Chinese

- Society of Agricultural Engineering (Transactions of the CSAE), 2023, 39(4): 135-143. (in Chinese with English abstract)
- [32] 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.
- CHEN Dongpei. Research On Session Recommendation Algorithm Based On Graph Neural Network And Attention mechanism[D]. Guangzhou: South China University of Technology, 2021. (in Chinese with English abstract).
- [33] WANG J J, LUAN Z Y, YU Z S, et al. Superpixel segmentation with squeeze-and-excitation networks[J]. *Signal, Image and Video Processing*, 2022, 16(5): 1161-1168.
- [34] 顾宝兴, 刘钦, 田光兆, 等. 基于改进 YOLOv3 的果树树干识别和定位[J]. 农业工程学报, 2022, 38(6): 122-129. GU Baoxing, LIU Qin, TIAN Guangzhao, et al. Recognizing and locating the trunk of a fruit tree using improved YOLOv3[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2022, 38(6): 122-129. (in Chinese with English abstract)
- [35] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]// Proceedings of the AAAI Conference on Artificial Intelligence New York, USA, 2020: 12993-13000.

## Improved lightweight YOLOv4 model-based method for the identification of shrimp flesh and shell

CHEN Xueshen, WU Changpeng, DANG Peina, LIANG Jun, LIU Shanjian, WU Tao<sup>\*</sup>

(College of Engineering, South China Agricultural University, Guangzhou 510642, China)

**Abstract:** An improved lightweight YOLOv4 model was proposed to realize the accurate, real-time, and robust automatic sorting of bare and shelled shrimp in the shrimp mechanical shelling process under complex scenarios. The CSP-Darknet53 network was replaced by the GhostNet in the YOLOv4 structure. The ability of the model was then improved to extract the features adaptively. The calculation of model parameters was also simplified after improvement. The GhostNet network was used for the YOLOv4 backbone feature extraction, in order to reduce the network model complexity, and the model parameters for better storage capacity and detection efficiency. A lightweight attention mechanism was introduced into the Resblock module of the YOLOv4 backbone feature extraction network, in order to enhance the feature extraction capability of the backbone feature extraction network. The SE attention mechanism module was used to enhance the attention between feature channels. The attention of the network model was improved to the shrimp shell by fitting the relevant feature information to the target channel and suppressing invalid information. The model recognition accuracy was improved to reduce background interference. The original GIoU loss function was replaced with a CIoU loss function to improve the regression effect of the prediction frame. The CIoU loss function made the data obtained from non-maximal suppression more reasonable and efficient. Furthermore, the prediction frame was more accurate to minimize the distance between the centroids of the detection frame and the labelled frame. The lightweight GhostNet-YOLOv4 model was compared with the YOLOv7, EfficientNet Lite3-YOLOv4, ShuffleNetV2-YOLOv4, and MobilenetV3-YOLOv4 models. The results showed that the GhostNet-YOLOv4 model shared the lowest number of parameters and computational effort. An ablation comparison experiment was designed to verify that replacing the backbone feature extraction network and embedding the SE attention mechanism optimized for the module. The replacement of the CSP-Darknet53 backbone feature extraction network with the GhostNet resulted in a 2.9 percentage point improvement in the mAP and a significant reduction in the number of model parameters and output weights, compared with the original model. The addition of the SE attention mechanism improved the anti-interference and feature extraction ability, whereas the mAP was improved by 1.8 percentage points. After replacing the GIoU loss function with the CIoU one, the shrimp recognition accuracy was further improved, where the mAP was improved by 1.4 percentage points. According to the actual operating environment of the shrimp shell inspection test bed, two types of image datasets were produced, namely bare flesh shrimp and shelled shrimp. The GhostNet-YOLOv4, YOLOv3, YOLOv4, and MobilenetV3-YOLOv4 models were used for testing. The results show that the GhostNet-YOLOv4 model achieved detection accuracy and speed of 95.9% and 25 frames/s, respectively. The GhostNet-YOLOv4 model outperformed all other models in terms of detection speed under the condition of guaranteed detection accuracy. The performance of the GhostNet-YOLOv4 network model was evaluated to identify the shrimp shells for four treatments with the changes in light brightness, speed, shrimp posture, and shrimp species. The shrimp shell detection test showed that the average accuracy of shrimp shell recognition reached 90.4%, fully meeting the operational requirements. It indicates that the test bench was suitable for installation on mobile-embedded devices. The GhostNet-YOLOv4 network model still shared excellent generalization performance, when identifying other species of shrimp shells outside the sample set, with an average accuracy of 87.2%.

**Keywords:** machine vision; target detection; shrimp; deep learning; YOLOv4