

[文章编号] 1003-4684(2023)04-0076-06

基于改进 YOLOv5 的小龙虾品质检测方法

鲁濠¹, 王淑青¹, 鲁东林¹, 张子蓬², 汤璐¹

(1 湖北工业大学电气与电子工程学院, 湖北 武汉 430068; 2 武汉奋进智能机器有限公司, 湖北 武汉 430074)

[摘要] 小龙虾质量检测是其生产加工中的重要环节, 针对当前目标检测模型在不同数据集上存在拟合性能不佳、冗余错误等问题, 提出了一种基于改进 YOLOv5 网络的小龙虾质量检测方法。首先在主干网络采用 DP-Conv 卷积改进 CNN 卷积, 利用高维过度参数化提高拟合效果和检测速度。其次在残差块 Res_unit 中嵌入 SENet 模块加强上下文的语义联系, 减少冗余信息的干扰。最后设计一种小龙虾数据采集方法。与 3 种目标检测算法实验对比, 结果表明, 改进后的算法检测精度达到 97%, 速度为 60 帧/s, 模型性能优于其他 3 种算法, 具有高检测精度和高速度的应用效果。

[关键词] 目标检测; 小龙虾检测; YOLOv5 网络; 深度学习

[中图分类号] TP391.41 **[文献标识码]** A

近年来, 中国龙虾养殖产业发展迅猛, 人们对于优质小龙虾的食品需求也在逐步扩大, 我国小龙虾的消费市场增长十分火热。在龙虾生产过程中, 商户需要保证龙虾的新鲜程度, 确保市场上的小龙虾为合格产品。目前, 生产线上小龙虾质量检测通常由人工完成, 这需要消耗更多的人工成本, 并且由于人工的疏忽以及其他因素, 极易发生误判的情况, 因此小龙虾的质量检测已成为龙虾生产中一个急需改进的环节^[1-2]。小龙虾的质量检测分为两步: 首先从相机捕获的图像中提取小龙虾, 其次检测不同场景下的小龙虾是否合格^[3]。

随着硬件的提升以及深度学习理论迅速地发展, 越来越多经典的深度卷积网络被应用在食品科技领域, 如 Faster-RCNN, ResNest, YOLO 等^[4-7]。这些基于深度学习的目标检测方法充分展现了其快速、准确以及实用性。余伟聪等^[8]提出了一种轻量化深度学习 Monilenet-SSD 的网络模型对海珍品进行检测, 通过验证的检测 AP 达到了 83.87%, 该方法能检测复杂情况下的目标, 但是检测精度不高; 刘阳等^[9]采用高斯混合模型对青梅表面缺陷进行检测, 验证其对复杂的背景有比较强的适应能力, 但是模型复杂, 可行性较差; 陈斌等^[10]提出利用 Faster-RCNN 对自然环境下的油茶果进行检测, 准确率为 98.92%, 检测精度较高, 然而未解决查错率高的问题; 薛勇等^[11,12]采用 GoogLeNet 深度迁移学习对苹果进行缺陷检测, 测试样本的识别准确率达到了

91.91%, 有较好的泛化能力和鲁棒性, 但是网络训练速度不高。

目前利用深度卷积网络识别小龙虾缺陷方面的研究较少, 深度学习在目标定位和识别方面效果较好, 然而差异化的数据集会对模型的训练与调优存在影响。在上述相关学者的研究基础上, 对原 YOLOv5s 网络模型进行改进, 将其应用在小龙虾质量检测中^[13-14]。首先设置帧率截取工业相机在多场景下进行多角度拍摄的视频, 获得图片, 通过添加噪声, 高斯模糊抑制噪声等方法, 制作一个多类型小龙虾数据集^[15-16]。送入改进的 YOLOv5s 模型进行训练, 得到最优权重, 对验证集图片进行检测分析。实验结果表明, 本文所提出的研究方法, 检测精度和检测速度较高, 且满足小龙虾生产要求, 可以提高小龙虾生产检测效率。

1 系统方案及网络模型介绍

1.1 系统总体方案

生产质检会将小龙虾处理至半熟状态。小龙虾在被煮熟前为鲜活, 则肉质更佳, 反之肉质松散。煮熟前是否鲜活可通过判断小龙虾尾部是否蜷曲至胸前, 若蜷曲度 $<90^\circ$ 则为合格的鲜活小龙虾。本文对小龙虾的检测方法, 通过蜷曲度来判断其质量好坏^[17]。

本实验设计了基于 YOLOv5s 网络的生产线小龙虾质量检测。使用标注完毕的数据集对模型进行

[收稿日期] 2022-03-30

[第一作者] 鲁濠(1999-), 男, 湖北黄冈人, 湖北工业大学硕士研究生, 研究方向为自动化与图像处理。

[通信作者] 张子蓬(1968-), 男, 山东武城人, 工学博士, 湖北工业大学副教授, 研究方向为机器视觉与机器人优化算法。

$$D \in R^{(M \times N) \times D_{mul} \times C_{in}} \quad (6)$$

故 DP-Conv 卷积首先采用权重 D 对输入特征进行 Depthwise 卷积操作,然后对于输出结果采用权重为 W 的 CNN 操作,定义 DP-Conv 操作为 $\otimes \ddot{A}$,该操作可以表示为:

$$O = (D, W) \otimes P \quad (7)$$

通过计算可以得知,DP-Conv 卷积对特征进行操作,其感受野仍为 $M \times N$,与传统卷积相同。然而相比较传统卷积,DP-Conv 多使用了 2 个权重矩阵(4)和(6)来计算,传统卷积的卷积核参数为 $C_{out} \times (M \times N) \times C_{in}$,一般 $D_{mul} \geq M \times N$,假定 $D_{mul} = M \times N$,DP-Conv 操作的卷积核个数也远比传统卷积更多,故 DP-Conv 是一种过度参数化操作。实验佐证,过度参数化能够加速深层次网络的训练速度。

过度参数化由于参数更多,因此在训练时能够更加逼近真实特征,偏差(Bias)会变得更小。对于过拟合问题,到了高维度学习,当特征参数的数量远大于样本的数量时,偏差越来越小,方差(Variance)越来越大的问题并不会发生,不会出现 double descent(双重下降,误差随着参数的增加而先下降后增加)^[20]。由于大量特征中会掺杂噪声,加之引入正则化条件,单个特征所得到的系数绝对值会更小,泛化效果更佳。因此随着参数的增加,误差会小幅上升波动而后持续下降,能够避免过拟合的现象。在线性回归模拟中选取随机样本数为 100,包含 223 个特征,特征数目远大于样本数,此时满足过度参数化后的模型拟合误差效果见图 2。

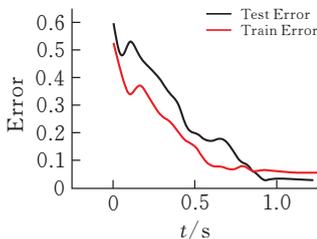


图 2 高维过度参数化的误差变化

1.4 残差块 Res_unit 改进

Res_unit 模块由两个 CBL 模块组成,如图 3a 所示,为跨尺度连接的 Bottleneck 结构,主要作用是降低网络的参数量,通过降维—卷积—升维的结构完成多尺度特征融合。同时该模块进行 shortcut 操作,形成残差网络,避免深度网络出现梯度爆炸与梯度消失的问题。通过跨尺度特征融合模块可以获得丰富的感受野信息,然而一些噪声信息会形成干扰,导致网络推理过程引向错误的方向。SENet (Squeeze-and-Excitation Networks) 模块通过对不同 channel 特征进行权重划分,使得模型在学习过程中更侧重于感兴趣的特征区域^[21-22]。因此在 Res

_unit 模块嵌入 SENet 模块可以学习特征权重并剔除无关信息,获取精准定位与强语义之间的融合关系。改进后的结构对比如图 3 所示。

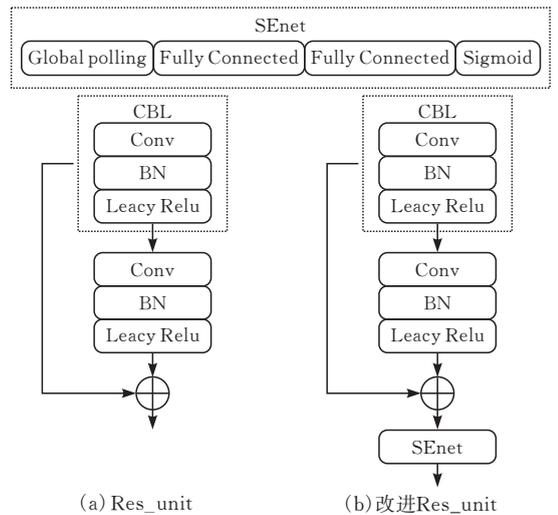


图 3 改进 Res_unit 模型对比

SENet 模块对上层输入卷积特征图采用 squeeze(压缩操作),其主要操作为将原来 $H \times W \times C$ 的特征维度压缩至 $1 \times 1 \times C$,压缩使得较小维度的参数某种程度上获得了全局的感受野,得到每个特征通道的全局特征。随后对全局特征采用 Excitation(激励操作),将压缩后的特征通过一个 FC 全连接层,对末一个通道进行权重分配,学习通道之间的相关性和重要性,最后通过 Reweight 操作,使用乘法加权至对应通道的特征上,在通道维度完成对于特征的重新标定。SENet 通过学习自动获取每个通道的重要程度,提升了对特征感兴趣区域的强语义效果,并抑制冗余特征,因此可以使模型更关注信息量大的通道信息,提高检测精度与模型收敛速度。

2 实验及结果讨论

2.1 数据集预处理

实验使用的数据集是自制数据集,来源于工业相机采集现场小龙虾分拣过程,设置频率进行视频截取,择优挑选得到 2500 张样本图片。由于相机采集的图像有限,为提升网络模型的泛化性和特征融合,对采集的图片添加高斯噪声,以高斯模糊、变换背景等方式,来对差异性较大,数量较少的小龙虾样本进行扩充^[23-24]。

经过变换增广后的小龙虾数据集总计 8000 张,包含大小不一,颜色各异的小龙虾样本。其中正负样本各 6000 个,正样本为合格,负样本为不合格。在训练数据集之前,采用 Labelmg 标注工具对不同蜷曲度的小龙虾进行人工标注与分类,设置蜷曲度

$<90^\circ$ 的合格小龙虾类别为 0, 标签为 qualified, 否则为不合格, 类别为 1, 标签为 unqualified。

2.2 实验配置及模型指标分析

本实验环境为 Ubuntu16.04 操作系统, 采用 pytorch 框架, GPU 为 Nvidia GeForce RTX 2070 SUPER, 内存为 16G 进行运算, 采用 CUDA 11.1.96 加速训练。选择预训练模型为改进的算法。优化采用 Adam 算法, Batch-size 设置为 32; 迭代次数设置为 800 次; 动量因子值为 0.9; 权重衰减系数设置为 0.0005; 采用预热重启更新学习率, 初始学习率设置为 0.001。根据训练日志绘制各评价参数的可视化曲线图^[25-27]。本文选取的评价指标为: 精确率 (Precision) 和边框损失 (Giuo_loss), 最终训练结果如图 4 所示^[28-29]。

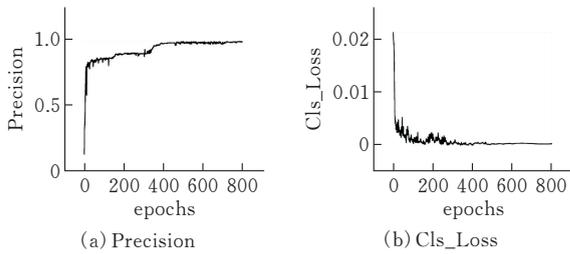


图 4 模型性能评估参数

精确率又被称为查准率, 表示预测真实的样本占模型预测该类样本的比例。精确率和召回率的计算方法见公式(8)。

$$\begin{cases} P = \frac{T_P}{T_P + F_P} \\ R = \frac{T_P}{T_P + F_N} \end{cases} \quad (8)$$

式中, TP 表示正类预测为正类; FN 表示正类预测为负类; FP 表示负类预测为正类。

图 4a 可以看出, 精确率总体呈现稳定上升趋势且震荡较小, 训练至 425 轮后趋于稳定, 达到 0.98, 算法检测精度高, 特征提取效果好; 图 4b 可以看出, 边框损失有轻微震荡过程, 但总体呈收敛下降趋势。迭代至 400 轮左右, 边框损失趋于稳定且仅为 0.0007, 表明改进后的算法误差小且拟合效果好。

2.3 不同优化模块的影响

使用 DP-Conv 卷积增强主干网络后, 使用两种模型分别训练小龙虾数据集, 验证两种卷积对主干网络特征提取的影响, 表 1 对比了原始模型以及新模型训练的精度和速度指标。

表 1 主干网络对比

主干网络	(mAP@: 0.5)/%	Imp/ %	训练时长/h (400 epochs)	Imp/ %
Focus+CNN	87.43	—	7.3	—
Focus+DP-Conv	90.75	3.8	6.2	15

从表 1 可以看出, 改进后的算法与原算法相比,

DP-Conv 卷积层获取的特征核更多, 加快了网络的推理速度, 模型训练时间提升了约 15%。

Res_unit 模块嵌入 SENet 的 CSP1_X 构建完成后, 在小龙虾数据集上进行训练与验证, 分析融合结构对于龙虾特征提取的影响, 表 2 为不同结构的影响。

表 2 残差网络对比

网络结构	(mAP@: 0.5)/%	Imp/ %	FPS	Imp/ %
Res_unit	89.63	—	45	—
Res_unit+SENet	91.47	2.1	47	4.4

表 2 表明, 嵌入 SENet 模块提高了网络的检测精度与检测速度^[30], 对于缺陷的精度提升了 2.1%, 速度提升了 4.4%, 说明融合结构能够加强网络对于重要特征的提取。

对主干网络和残差网络的改进, 兼顾了精度与检测速度的提升, 使得两方面更加平衡。表 3 给出了在同等配置、数据集的情况下, 与其他 3 种算法进行性能对比的结果。通过评价指标对比可知, 本文采用的改进后的算法进行训练与验证, 训练速度更快、精确度更高、收敛性更好, 检测帧率为 60FPS, 优于其他几种算法, 是较为理想的网络模型, 满足实际检测需求^[31]。

表 3 不同网络效果对比

算法模型	(mAP@: 0.5)/%	Precision/%	帧率/FPS
Faster RCNN	88.53	85.94	21
YOLOv4	91.46	90.73	29
YOLOv5s	94.23	96.62	52
本文算法	98.52	97.63	60

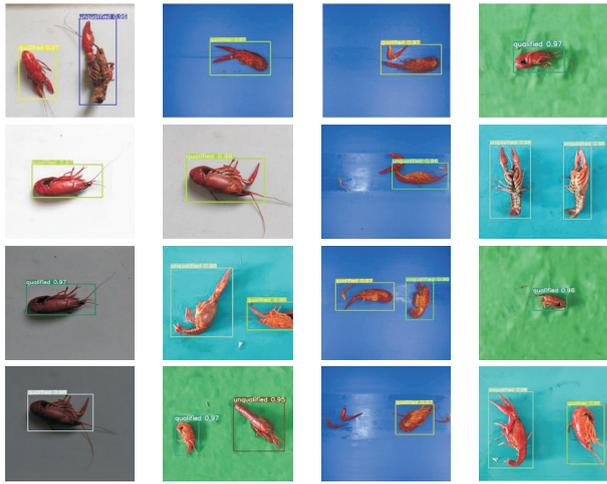
2.4 检测效果与分析

将最优权重喂入模型, 在不同场景下对小龙虾缺陷进行定位识别。采集图片可能因天气、镜头污渍等原因导致光照强度不均匀。分拣过程中小龙虾有断肢残留等情况, 会对网络浅层特征及深层特征提取造成影响。为了验证改进后模型的泛化能力, 在不同光照亮度、多背景、不同尺度以及包含断肢的情况下对模型进行效果验证(图 5)。

测试图片包含 1442 个合格样本和 1145 个不合格样本, 存在少量误检样本, 整体检测效果较好。测试结果见表 4。

表 4 训练测试结果

指标	合格样本	不合格样本
预测为合格/张	1407	38
预测为不合/张	35	1107
定位识别平均精确率/%	98.39	99.55
缺陷检测平均精确率/%	97.58	96.68



(a)不同光照 (b)不同背景 (c)包含断肢 (d)不同尺度

图5 实验验证结果

图5中检测框上的数值表示置信度,表示判定该缺陷隶属于这类缺陷的概率^[32-33]。在查准的情况下,置信度越高,代表检测效果越好。由检测结果可知,在不同背景,包含断肢和多尺度情况下,本文算法均能够准确定位出图片中的小龙虾,检测时间提升为14 ms,对缺陷检测的置信度均高于95%;在不同光照条件下,过暗导致的像素低伴随噪声会对检测产生影响,使得目标与背景分割定位困难,影响网络识别的精度。通过图5(a)可以看出,本文算法利用注意力机制加强对于特征区域的识别,加强上下信息的传递,使得检测过程受光照和噪声的影响大幅减小,提高了检测置信度,网络的检测能力和泛化能力表现良好。

3 结论

提出了一种基于改进的YOLOv5s网络的小龙虾质量检测方法,在小龙虾生产质检中引入深度学习的目标检测算法,相比较人工检测,解决了人为主观因素导致的效率低、成本高等问题。提供了一种多形态小龙虾数据集的制作方法,为后续小龙虾数据集开源提供一种思路。对YOLOv5s网络模型进行优化,由表3可知:改进后的模型整体性能优于Faster-RCNN等传统目标检测网络,总体识别准确率达到97.63%,检测速率达到60帧/s,同时系统鲁棒性好,可以作为小龙虾质量检测方法,进行推广使用。由于受时间限制,网络测试对比和数据集扩充工作还存在不足,后续工作将会继续优化对比实验、提升数据集的多样性,加强模型的泛化性。

[参 考 文 献]

[1] 罗艳,张安红,张芳.基于机器视觉技术的对虾主骨架

线提取[J].食品工业科技,2013,34(08):68-73.

- [2] 曹阳,卢军.基于改进分割决策网络的铝材表面凹坑缺陷检测[J].陕西科技大学学报,2021,39(02):139-145.
- [3] SU B, CHEN H Y, CHEN P, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network[J]. IEEE Transactions on Industrial Informatics, 2020, 17(06): 4084-4095.
- [4] LI C J, QU Z, WANG S Y, et al. A method of cross-layer fusion multi-object detection and recognition based on improved faster r-cnn model in complex traffic environment [J]. Pattern Recognition Letters, 2021, 145(08): 127-134.
- [5] LI C J, QU Z, WANG S Y, et al. A method of cross-layer fusion multi-object detection and recognition based on improved faster r-cnn model in complex traffic environment [J]. Pattern Recognition Letters, 2021, 145(08): 127-134.
- [6] WANG S, LIU Y, QING Y, et al. Detection of insulator defects with improved resnest and region proposal network[J]. IEEE Access, 2020, 8: 184841-184850.
- [7] 张凯,罗欣,孙志刚,等.基于轻量化YOLOv4的发电机定子表面缺陷检测算法[J].计算机与数字工程, 2021,49(04):686-691.
- [8] 俞伟聪,郭显久,刘钰发,等.基于轻量化深度学习 MobileNet-SSD 网络模型的海珍品检测方法[J].大连海洋大学学报,2021,36(02):340-346.
- [9] 刘阳,丁奉龙,刘英,等.基于高斯混合模型的青梅表面缺陷检测识别技术[J].林业工程学报,2020,5(04): 139-144.
- [10] 陈斌,饶洪辉,王玉龙,等.基于Faster-RCNN的自然环境下油茶果检测研究[J].江西农业学报,2021,33(01):67-70.
- [11] 薛勇,王立扬,张瑜,等.基于GoogLeNet深度迁移学习的苹果缺陷检测方法[J].农业机械学报,2020,51(07):30-35.
- [12] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021, 2021(10): 1-13.
- [13] SHI X, WU X. Tomato processing defect detection using deep learning[C]. // 2019 2nd World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM). IEEE, 2019: 728-732.
- [14] 谈世磊,别雄波,卢功林,等.基于YOLOv5网络模型的人员口罩佩戴实时检测[J].激光杂志,2021,42(02): 147-150.
- [15] 王年涛,王淑青,张鹏飞,等.一种EfficientNet网络下雾天道路能见度估测方法[J].湖北工业大学学报,2021, 36(05):42-46.
- [16] SA J, LI Z, YANG Q, et al. Packaging defect detection system based on machine vision and deep learning [C]. // 2020 5th International Conference on Computer

- and Communication Systems (ICCCS). IEEE, 2020; 404-408.
- [17] 郑煜飞,陈季旺,楚天奇,等.杀菌工艺对即食小龙虾品质的影响[J].武汉轻工大学学报,2021,40(04):1-7.
- [18] LUO H, WU Q, CHEN K, et al. Power equipment defect detection algorithm based on deep learning[C]. // Artificial Intelligence in China: Proceedings of the 2nd International Conference on Artificial Intelligence in China. Springer Nature, 2020, 653: 211-219.
- [19] FAN S, LI J, ZHANG Y, et al. On line detection of defective apples using computer vision system combined with deep learning methods[J]. Journal of Food Engineering, 2020, 286: 110102.
- [20] 周星光,靳华中,徐雨东,等.基于多尺度特征的图像描述生成模型[J].湖北工业大学学报,2020,35(02):61-66.
- [21] AMIN D, AkHTER S. Deep learning-based defect detection system in steel sheet surfaces[C].//2020 IEEE Region 10 Symposium (TENSYMP). IEEE, 2020; 444-448.
- [22] TASTIMUR C, KARAKOSE M, Aydin I, et al. Defect diagnosis of rolling element bearing using deep learning[C].//2018 International Conference on Artificial Intelligence and Data Processing (IDAP). IEEE, 2018; 1-5.
- [23] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021, 2021(10): 1-13.
- [24] ZHOU C, ZHOU J, YU C, et al. Multi-channel sliced deep rcnn with residual network for text classification [J]. Chinese Journal of Electronics, 2020, 29(05): 880-886.
- [25] ZHOU D X. Universality of deep convolutional neural networks[J]. Applied and computational harmonic analysis, 2020, 48(02): 787-794.
- [26] RAMACHANDRAN N, HONG S C, SIME M J, et al. Diabetic retinopathy screening using deep neural network[J]. Clinical & experimental ophthalmology, 2018, 46(04): 412-416.
- [27] SONG Y, KIM I. DeepAct: a deep neural network model for activity detection in untrimmed videos[J]. Journal of Information Processing Systems, 2018, 14(01): 150-161.
- [28] XIAO Y, TIAN Z, YU J, et al. A review of object detection based on deep learning[J]. Multimedia Tools and Applications, 2020, 79(33): 23729-23791.
- [29] ELMASRY W, AKBULUT A, ZAIM A H. Empirical study on multiclass classification-based network intrusion detection[J]. Computational Intelligence, 2019, 35(04): 919-954.
- [30] 亢洁,李思禹.基于注意力机制的卷积神经网络人脸表情识别[J].陕西科技大学学报,2020,38(04):159-165.
- [31] 郑鑫宇,崔旭晶,石征锦,等.基于深度学习的机械臂视觉抓取系统[J].信息技术与信息化,2021(08):226-228.
- [32] 陈辉东,丁小燕,刘艳霞.基于深度学习的目标检测算法综述[J].北京联合大学学报,2021,35(03):39-46.
- [33] 李福进,孟路达,任红格.基于双向融合 SSD 的目标检测算法[J].现代电子技术,2021,44(19):81-84.

Quality Detection Method of Crayfish based on Improved YOLOv5

LU Hao¹, WANG Shuqing¹, LU Donglin¹, ZHANG Zipeng², TANG Lu¹

(1 School of Electrical and Electronic Engin., Hubei Univ. of Tech., Wuhan 430068, China;

2 Wuhan Fenjin Intelligent Machine Co., Ltd, Wuhan 430074, China)

Abstract: The quality detection of crayfish is an important link in its production and processing. Aiming at the problems of poor fitting performance and redundant errors of the current target detection model on different data sets, a method for quality detection of crayfish based on the improved YOLOv5 network is proposed. First, the DP-Conv convolution is used in the backbone network to improve the CNN convolution, and high-dimensional over-parameterization is used to improve the fitting effect and detection speed. Secondly, the SENet module is embedded in the residual block Res_unit to strengthen the semantic connection of the context and reduce the interference of redundant information. Finally, a data collection method for crayfish is designed. Comparing the proposed algorithm with three kinds of target detection algorithms, the results show that the improved algorithm has a detection accuracy of 97%, a speed of 60 frames/s, and the model performance is better than the other three algorithms, having high testing accuracy and application effect.

Keywords: crayfish detection; target detection; yolov5 network; deep learning