

基于改进 YOLOv5 的港口集装箱损伤检测算法^{*}

裴晓芳^{1,2} 刘菁宇² 柏雪² 周进² 衡晓钰¹

(1. 无锡学院电子信息工程学院 无锡 214105;

2. 南京信息工程大学电子与信息工程学院 南京 210044)

摘要:针对港口复杂环境背景下,不同尺度间多种类集装箱损伤目标检测精度低的问题,提出一种基于改进 YOLOv5 的港口集装箱损伤检测算法。通过使用一维卷积改进卷积块注意力机制(CBAM)中空间注意力模块的池化操作,后设计残差结构,并验证在不同位置引入改进的 CBAM 基本块对模型性能的影响,探索尽量减小复杂背景对检测结果影响的最佳方案及融合位置;为有效解决不同集装箱损伤图像尺度特征变换较大的问题,依据双向特征融合网络(Bi-FPN)结构思想,对颈部特征融合网络进行改进,在不过多增加计算量的情况下,更好地增强网络对多尺度目标的特征融合能力;最后将 EIOU Loss 替换 GIOU Loss 作为算法的损失函数,在降低算法边界框回归损失的同时提高算法的检测精度。实验结果表明,改进 YOLOv5 算法的平均检测精度达到了 98.32%,较原 YOLOv5 目标检测算法提高了 4.28%,同时保证了检测速度,验证了所提出算法的有效性,对港口企业高精度验箱的工业部署有重要意义。

关键词:集装箱损伤;目标检测;YOLOv5;CBAM;Bi-FPN;EIOU

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Damage detection algorithm of port container based on improved YOLOv5

Pei Xiaofang^{1,2} Liu Jingyu² Bai Xue² Zhou Jin² Heng Xiaoyu¹

(1. School of Electronic & Information Engineering, Wuxi University, Wuxi 214105, China;

2. School of Electronic & Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China)

Abstract: Aiming at the problem of low detection accuracy of multiple types of container damage targets at different scales in the complex port environment, a port container damage detection algorithm based on improved YOLOv5 is proposed. By using one-dimensional convolution to improve the pooling operation of spatial attention module in CBAM attention mechanism, the residual structure was designed, and the influence of introducing improved CBAM blocks in different positions on the model performance was verified, to explore the best scheme and fusion location to minimize the influence of complex background on detection results. In order to solve the problem of significant change in feature transformation of different container damage images, the neck feature fusion network was improved based on the Bi-FPN network structure, it can enhance the feature fusion ability of the network to multi-scale targets without increasing the amount of calculation too much. Finally, EIOU Loss was used to replace GIOU Loss as the loss function of the algorithm, which reduced the regression loss of the bounding box and improved the detection accuracy of the algorithm. The experimental results show that the average detection accuracy of the improved YOLOv5 model have reached 98.32%, which is 4.28% higher than the original YOLOv5 algorithm. At the same time, it ensures the detection speed and verifies the validity of the algorithm proposed in this paper, which is of great significance to the industrial deployment of high-precision container inspection in port enterprises.

Keywords: container damage; target detection; YOLOv5; CBAM; Bi-FPN; EIOU

收稿日期:2023-09-07

^{*} **基金项目:**国家自然科学基金委青年基金(42205078)、高校哲学社会科学研究一般项目(2022SJYB0979)、苏高教会“高质量公共课教学改革研究”专项课题(2022JDKT138)、无锡学院教改课题(JGZD202107-3-11)、教育部产学研合作协同育人项目(220703806203838,220702116135122)、2022 江苏省大学生创新创业训练计划(202213982054Y)项目资助

0 引言

集装箱作为国际间大量货品运载的保护屏障,是现代物流不可或缺的一部分^[1]。然而,在航线较长的贸易路线上,集装箱往往需要经停较多的中转站,受到机械操作的反复承重和沿途天气环境变换的影响,箱体很容易受到损伤,且由于成本限制,集装箱的使用寿命往往长达数十年,多种损伤的积累严重威胁了集装箱结构及所运载货品的安全性。因此,港口企业需要在集装箱使用期间定期对箱体进行检查,来判断集装箱能否继续装载以及是否需要及时报修。在传统的集装箱损伤检测中,一般由专业的集装箱验箱员通过目视对集装箱进行检查,以判断箱体表面的损伤情况,存在检测效率低、主观性强等缺点,港口复杂的集装箱堆场环境^[2]甚至可能危及工作人员的安全。随着人工智能的高速发展,通过取代检查员以更加精确、高效、操作安全、成本节约的方式完成集装箱损伤检测,是推动传统港口向智慧港口、自动化港口及无人港口转型的积极力量^[3]。

大多数集装箱损坏反映在外观上。早期,国内外针对集装箱损伤检测的研究主要集中在计算机视觉领域,例如采用传统的图像分割算法,根据阈值设置分割孔洞和裂缝,实现损伤检测;还有使用相关系数方法组合集装箱图像、利用 Capsize-Gaussian-Function 函数方法,从函数的参数中直接获取损伤大小等信息。这些方法受环境因素影响大、泛化性差,不仅检测的种类单一,算法应用的局限性也较大,造成大量的误检、漏检。

近年来,基于卷积神经网络(convolutional neural network, CNN)^[4]的目标检测算法迅速发展,因其强大的检测分类效果、良好的鲁棒性和泛化能力,被大量应用于各个目标识别领域。基于深度学习的目标检测模型主要分为两大类:先对目标生成关注区域的二阶段检测算法,代表方法有 R-CNN(region based convolutional neural network)系列^[5];无需预先生成关注区域的一阶段检测算法,代表方法有 YOLO(you only look once)系列^[6]。其中两阶段算法整体检测精度较高但检测速度慢,单阶段算法检测速度快但精度较低。Kattainen^[7]基于 Faster R-CNN^[8]、MobileNet^[9]和 ResNet^[10],提出了一种集装箱边角铸件识别自动检测系统,但是用 Faster R-CNN 网络构建的模型比较大,参数量较多,检测速度较慢,不适用于实际的项目中。Wang 等^[11]提出一种基于迁移学习^[12]和 MobileNetv2^[13]的集装箱多类型破损检测模型,改进后的网络有效地提高了多类型集装箱损伤目标检测的速度,但检测精度较低。

随着机器学习领域研究发展的深入,以 YOLO 系列网络模型为基础的检测算法在表面缺陷检测领域得到了广泛的研究与应用。陈帅等^[14]基于 YOLOv5 网络模型融合 CA 注意力机制,使网络更多的关注到缺陷目标的特征信息上,提高了砂纸表面缺陷检测的准确率,但忽略了部

分输入特征的信息丢失问题;谢林森等^[15]在 YOLOv5 的特征融合层上引入 GhostNetV2 模块和改进的 DenseNet 密集网络模块,并加入注意力机制,以获得更加丰富的特征细节,有效解决了检测光伏电池电致发光缺陷时的漏检误检问题,但增加了模型的参数量和计算成本,且对小目标缺陷检测的精度不佳;胡欣等^[16]提出了一种基于 YOLOv5 算法的螺纹钢表面缺陷检测方法,通过利用 K-means++ 算法重聚类锚框,加强特征融合和改进注意力机制,使模型得到了良好的检测效果,然而模型在复杂背景下的抗干扰能力仍有待提升;丁伟利等^[17]通过在 YOLOv5 模型上增加目标检测层和改进的注意力机制,实现了高精度的陶瓷表面缺陷检测,但缺陷的分类仅有开裂和脏点两种,距满足实际应用中的检测需求还有较大距离。

综上所述,为解决集装箱多种类损伤图像样本少、实际港口集装箱堆场场景复杂背景、不同损伤类型间目标特征尺度变化大、检测精度低等识别难点,本文提出基于改进 YOLOv5 港口集装箱损伤检测算法,选择 YOLOv5 算法模型为基准模型,首先对现有数据集进行数据增强;然后引入改进的卷积块注意力模块(convolutional block attention module, CBAM)^[18],训练模型在复杂环境下对多种损伤定位和识别的精准能力;采用改进后具有双向特征融合网络(bidirectional feature pyramid network, Bi-FPN)^[19]代替原有的 PANet^[20]结构,快速进行多尺度特征融合;将 EIOU 损失函数^[21]作为本文算法的边界框回归损失函数,有利于目标检测网络模型的收敛,进一步提高目标的定位精度与检测精度。经实验证明,本文提出改进的 YOLOv5 算法对港口集装箱损伤检测效果良好,在满足实时检测的条件下,较原 YOLOv5 算法,对多种类集装箱损伤的检测效果均有明显提升。

1 YOLOv5 目标检测算法

YOLOv5 是基于边框回归的一阶段检测算法^[22]。其结合识别和定位于一体,官方发布的网络模型共包含 5 个版本,按照网络深度和宽度依次增加,分为 n、s、m、l、x 五个版本,它们的检测精度随模型参数量的增加而提升,但模型的网络训练和推理的时间也随之增加。为满足实时监测需求,本文选择检测精度与检测速度较为平衡的网络模型 YOLOv5s^[23],在此基础上进行改进,其网络结构如图 1 所示。

YOLOv5s 网络模型主要由输入端(Input)、主干网络(Backbone)、颈部(Neck)和输出端(Output)4 部分组成。其中,输入端将输入图像的大小统一为标准尺寸;主干网络包括切片结构(Focus)、卷积模块(Conv)、瓶颈层(C3)和空间金字塔池化(SPP),对输入的图像中进行关键特征提取;颈部网络主要利用特征金字塔结构与路径聚合网络结构,通过由顶至底传递语义特征和由底至上传递定位特征的强强结合,对提取到图像特征实现从不同的主干层对




图1 YOLOv5s 网络模型结构

不同检测层进行特征融合;输出端包含3个检测层,分别在各自尺度的特征图上生成锚框,通过非极大值抑制对上述产生的多个目标框进行筛选,得到其中置信度最高的预测目标的位置输出。

2 YOLOv5 算法改进

2.1 注意力机制改进

卷积注意力模块主要由通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)构成,其模块结构如图2所示。该模块合并了通道与空间之间的对应过程,采用混合型注意力机制,作为一种轻量级模块,在节约参数和计算力的同时,可以无缝集成至任何现有的网络架构中,实现即插即用。




图2 卷积注意力模块结构

CBAM 机制在经通道注意力模块输出特征 F' 后,将其在一个通道内的所有信息直接进行最大池化与平均池化,导致各个通道内信息无法进行交互,这在一定程度上限制了空间注意力中的重要特征表达;在实际港口集装箱堆场环境中,集装箱损伤检测的背景较为复杂,很大程度上局限了目标特征的识别。基于以上问题,本文对CBAM的空间注意力模块做出进一步改进,通过舍弃全局统一的最大池化与平均池化操作,采用一维卷积对特征

F' 进行两次降维处理,由卷积动态学习特征,加强不同通道内的信息交互,从而突出目标特征的位置信息,提升集装箱损伤特征表达的鲁棒性。本文改进后的 CBAM 模块结构如图3所示。




图3 改进的CBAM注意力模块结构

将输入的特征图 F 与通道注意力机制 M_c 卷积后的结果与原图相乘得到 F' , 再将 F' 经过相同操作,与空间注意力机制 M_s 卷积后的结果相乘,得到最终输出 F'' 。公式如下:

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

在通道注意力模块中,将输入的特征图并行通过最大池化层和平均池化层处理,然后经过由多层感知机构成的共享网络模块,将处理后的两个输出结果进行逐元素相加,最后通过一个 Sigmoid 激活函数与原图相乘后得到该通道注意力模块的输出结果。其公式为:

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) \quad (3)$$

式中: σ 为 Sigmoid 函数; MLP 为多层感知机模型; $AvgPool$ 、 $MaxPool$ 为平均、最大池化操作。

在改进后的空间注意力模块中,将通道注意力的输出结果连续经过 $Conv1$ 和 $Conv2$ 两次一维卷积处理特征信息,然后在 Concat 操作后经过一个 Sigmoid 激活函数与原图相乘后得到该空间注意力模块的输出结果。改进后公式为:

$$M_s(F) = \sigma(f^{7 \times 7} \cdot Conv2 \cdot (Conv1 \cdot (F))) \quad (4)$$

式中: f 为卷积核为 7×7 的卷积运算。

为进一步加强网络在复杂环境下对多种类集装箱损伤特征的识别能力,本文为改进的 CBAM 模块设计引入残差结构,得到的基本模块结构如图 4 所示。其中,残差层由一层卷积层和一层激活层组成,经过一个卷积层后为改进后的 CBAM 模块,两个卷积层通过交叉验证,使用的卷积核为 3×3 大小。




图4 改进的CBAM注意力基本块结构

基此,本文设计了两种注意力机制的引入方式。1)使用改进后的CBAM注意力基本块替换主干网络中的C3模块,将该改进网络命名为YOLOv5-C1;2)将其添加到主干网络的最后一层,命名为YOLOv5-C2。两种改进方式的结构如图5所示。




图5 引入CBAM的网络结构

2.2 特征融合网络改进

集装箱损伤图像经YOLOv5s主干网络提取损伤特征后进入颈部网络处理。在YOLOv5原有的网络结构中,使用FPN和PAN对提取到的特征进行融合,图6(a)所示为FPN结构,通过由顶至底的连接路线对特征进行融合,再将获得的具有更高语义信息的特征层进行预测,但这种信息流传递受单向限制。图6(b)所示为PAN结构,通过由顶至底与由底至顶的深浅层特征双向融合,保留了更多的特征信息,但在融合过程中,两部分信息只是简单的相加运算,并非特征融合的最优解。本文引入双向特征融合网络Bi-FPN,其结构如图6(c)所示。

Bi-FPN在PAN的基础上通过简化网络、采用跨尺度连接的方法,减小模型训练的参数量和计算量。基于该思想,本文提出一种在YOLOv5基础上融合Bi-FPN结构的网络模型,其结构如图7所示。

在本文提出的跨层融合连接图中,YOLOv5首先将输入网络的原集装箱图像进行3次下采样,其中8倍下采样用于检测较大的集装箱损伤目标;16倍下采样用于检测中等损伤目标;较小的集装箱损伤目标则由32倍下采样后获得的特征图进行检测。本文研究将经8倍及32倍下采样后得到的第1特征融合图和第3特征融合图与第2次下采样前的特征图及经上采样所得特征图中分别对应的两个图层进行跨层连接,在几乎不增加运算成本的前提

下,更好的融合到预测特征层的底层位置信息与顶层语义信息,然后将融合结果输出到各层特征输出图,卷积运算后得到改进后的集装箱损伤图像预测结果。改进的Bi-FPN更关注于集装箱图像中易忽略的过大或过小类特征信息,能有效解决由于集装箱损伤种类同种损伤间尺度差距较大、不同种损伤间尺度变化较大,引起的特征丢失问题。

此外,传统的特征融合会导致不同尺度特征图对特征融合做不同的贡献,为解决此问题,本文在引用Bi-FPN时,给不同尺度的集装箱损伤特征赋予不同的权重,并据此对各节点进行特征融合。通过权重调整后,不同尺度的特征可以兼具丰富的位置信息和较强的语义信息,进而弱化集装箱损伤目标间尺度变化较大对检测结果的影响。其带权特征融合公式为:

$$O = \sum_i \frac{w_i}{e + \sum_j w_j} \cdot I_i \quad (5)$$

式中: $i=j$, 是输入到节点的特征图数; I_i 是输入到节点的特征图矩阵; e 是一个极小数,保证式值有意义; w_i 、 w_j 是输入到节点的权重。

2.3 损失函数改进

为进一步提升集装箱损伤检测的精度,本文考虑改进网络模型的损伤函数。在原有的YOLOv5网络模型中,采用的是GIOW Loss^[24],GIOW是在交并比(IOW)函数的




图6 网络结构对比

基础上改进的损失函数^[25],解决了当预测框和真值框没有相交部分的情况下,IOU 损伤函数取值恒为 1,导致模型不能继续训练的问题。GIOU 损失函数的公式如下:

$$GIOU_{LOSS} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha \quad (6)$$

式中: IOU 是预测框与真实框的交集和并集之比; c 是两框最小外接矩形的对角线距离; $\rho^2(b, b^{gt})$ 是两框间的欧氏距离; α 为惩罚项,比较两框长宽比的相似性。然而,当预测框完全处于真实框内部时,如图 8 所示,会出现与 IOU 损失函数一样无法继续训练的问题。

针对边界框回归损失的问题,本文采用 EIOU Loss 替换原损失函数,其公式如下:

$$L_{EIOU} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt})}{c_w^2} + \frac{\rho^2(h, h^{gt})}{c_h^2} \quad (7)$$

式中: $\rho^2(w, w^{gt})$ 和 $\rho^2(h, h^{gt})$ 分别为两框宽和高之间的欧氏距离; c_w, c_h 分别为两框的最小外接矩形的宽和高。引入的 EIOU Loss 通过目标框的长度和宽度拆开计算,加速了模型训练的收敛,并提高回归的精度,从而提升集装箱损失数据样本回归的质量,提高集装箱损失检测的准确率。

3 实验与结果分析

3.1 数据集准备

由于关于集装箱损伤检测目前尚无公开的高质量数据集可供选择,本文采用自制数据集。为保证实验结果的有效性和可靠性,本文从数据公开性、开源性、真实性、通




图7 特征融合网络设计




图8 预测框与真实框位置关系

用性角度出发,进行实验数据集的制作与整理。实验数据一部分来自 Kaggle 平台公开的集装箱数据集(含集装箱图像 10 000 张),通过手动筛选不同损伤类型并进行整理分类;一部分来源于以集装箱和损坏特征为关键字的开源数据库中搜索,然后筛选出获得用作样本的图像;一部分

来源于某港口集装箱堆场现场拍摄采集,白天在自然光条件下拍摄,晚上在夜间补光条件下拍摄,进行整理挑选;一部分来源于港口端口正常运行期间的监控视频,通过选择、截取和提取视频流中包含集装箱屏幕的关键帧来获取和筛选损伤集装箱图像作为实验数据样本。

目前的集装箱检验主要基于由国际标准组织(ISO)发布的通用集装箱标准,本文基于此标准,结合港口企业集装箱验伤标准,将集装箱损伤分类进行整合;此外,除集装箱箱体受损外,集装箱在运输过程中经常发生损坏、跌落和倒塌的情况,从而产生其他类型的损伤,加重箱体伤害,因此,集装箱箱门打开和集装箱的堆垛塌陷同样应被视为集装箱损坏的类型种类。综合整理后的样本图

像分为锈蚀、凹凸磕碰、裂缝、箱体形变、破洞、箱门打开、集装箱堆垛坍塌 7 种类型,各种类损伤如图 9 所示。




图9 集装箱损伤图像示例

为增强训练模型对小尺度损伤目标的识别能力,实验对部分图像数据进行裁剪,最小图像规格为 200×200 ,筛选后原始的集装箱损伤图像样本集共 1 515 张。通过进行数据增强进一步提升数据集质量,如对原始图像数据进行旋转、水平翻转、添加噪声、平移、图像增强等预处理操作,扩充损伤图像数量,有助于模型从中学习到有效的区

分特征,防止模型过拟合;后通过图像批处理统一为 640×640 大小输入到网络模型,最终形成了包含 4 892 张图像的港口集装箱损伤数据集,各类损伤数量如表 1 所示。其中,针对部分损伤类型的原始样本数量较小,导致形成的数据集不同类型样本间数量差距较大的问题,实验采用加权策略,在模型的训练过程中对 7 类损伤样本分配适当的权重。根据每个样本数据所属的损伤类别计算相应权重,给予少量类型样本相对更高的权重,提高模型对少量损伤类型的关注度,从而有效缓解不平衡样本数据给实验带来的负面影响。所述集装箱损伤数据集统一采用 Labellmg 工具的矩形框标注法进行标注,并按照 7:2:1 的比例划分为训练集、验证集和测试集。

3.2 实验环境

本文实验的环境配置如下:Window11 操作系统,Py-Torch 1.8.0,Python 3.8.5;CPU 为 AMD Ryzen 7 5800 H 3.20 GHz;GPU 为 NVIDIA GeForce RTX 3060;显存 6 G;内存 16 G。

本文网络训练的超参数设置如下:初始学习率为 0.01;使用 SGD 优化器,动量为 0.937;权重衰减率为 5×10^{-5} ;Batch size 为 32;训练轮数 100。

表1 不同类型集装箱损伤图像数据集数量

数据集	锈蚀	凹凸磕碰	裂缝	箱体变形	破洞	箱门打开	堆垛坍塌	总数
训练集	1 565	1 075	161	91	91	301	140	3 424
验证集	447	307	46	26	26	86	40	978
测试集	224	154	23	13	13	43	20	490
总数	2 236	1 536	230	130	130	430	200	4 892

3.3 评估指标

本文采用精确率(P)、召回率(R)、平均精度(AP)、平均精度均值(mAP) 4 个指标对改进后的港口集装箱损伤检测网络模型性能进行评估及验证。上述评价指标的公式如下:

$$P = \frac{TP}{TP + FP} \quad (8)$$

$$R = \frac{TP}{TP + FN} \quad (9)$$

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum AP}{N} \quad (11)$$

式中:TP 为真阳性,即真正为集装箱损伤目标的数量;FP 为假阳性,即错误预测的集装箱损伤目标的数量;FN 为假阴性,即未正确预测出的集装箱损伤目标的数量;N 为集装箱损伤图片总数量;AP 为单种集装箱损伤类别的预测准确率均值。

3.4 实验结果分析

1)验证改进 YOLOv5 网络结构方案

为验证两种引入改进的 CBAM 注意力基本块方式对

本港口集装箱损伤检测系统的影响,探索其最佳融合位置,对所述两种方式进行对比试验。YOLOv5-C1 为将改进后的 CBAM 注意力基本块替换主干网络中的 C3 模块;YOLOv5-C2 是将其添加到主干网络的最后一层,使用自建的港口集装箱损伤数据集在基础 YOLOv5s 网络上进行测试,对比结果如表 2 所示。

表2 融合 CBAM 对比试验

网络模型	mAP/%	W_s /MB	GFLOPs
YOLOv5	94.04	14.15	23.8
YOLOv5-C1'	94.73	14.31	27.2
YOLOv5-C2'	95.02	14.23	26.6
YOLOv5-C1	95.30	14.34	27.6
YOLOv5-C2	95.46	14.28	26.7

其中,YOLOv5-C1'为使用原始未改进 CBAM 模块替换主干网络中的全部 C3 模块得到的网络模型,YOLOv5-C2'为将原 CBAM 模块添加到主干网络最后一层得到的网络模型。可以看出,两种 CBAM 注意力基本块的融合方式,在轻微增加网络规模与计算量的前提下,对网络平

均检测精度的提升都有明显的效果。使用融合方式 1 的 YOLOv5-C1 网络模型平均检测精度提升了 1.26%，较未改进 CBAM 模块方案提升了 0.57%；使用融合方式 2 的 YOLOv5-C2 网络检测模型平均检测精度提升了 1.42%，较未改进 CBAM 模块方案提升了 0.44%，且网络规模和

计算量增长代价更小，验证了本文提出注意力机制改进方式的优越性。因此，研究采用第 2 种方式引入改进的 CBAM 注意力基本块。

综上所述，本文改进后的 YOLOv5 总体网络结构如图 10 所示。




图 10 改进后的 YOLOv5 网络结构

2)消融实验

为验证本文提出的改进 YOLOv5 算法对于港口集装箱损伤检测效果提升的有效性,将对本文提出的 3 方面改进方法进行多组消融实验。实验结果如表 3 所示。

表 3 消融实验结果对比

实验序号	CBAM	BiFPN	EIOU	$P/\%$	$R/\%$	mAP/%	W_s/MB
1				92.60	88.32	94.04	14.15
2	✓			93.79	90.12	95.46	14.28
3		✓		92.93	91.71	95.06	14.27
4			✓	91.66	90.02	94.63	14.19
5	✓	✓		96.25	93.41	97.51	14.32
6	✓		✓	96.15	93.62	97.15	14.25
7		✓	✓	95.39	92.67	96.70	14.30
8	✓	✓	✓	97.15	94.37	98.32	14.35

注：“✓”表示采用了该方法

可以发现，本文提出的 3 种改进策略均对网络模型检测港口集装箱损伤能力的提升有正向作用，但不同策略的组合并不是单纯的线性相加效果。本文采用的算法与原集装箱损伤检测网络相比，虽在一定条件下削弱了单种改进策略的提升能力，但在权重文件占比仅增加了 0.2 MB 的条件下，改进后的算法检测准确率提升了 4.55%，召回

率提升了 6.05%，mAP 提升了 4.28%，检测效果明显优于原始和其他模型，取得了检测精确率、召回率、平均精度均值的最优协同效果。对原模型加入改进的 CBAM 注意力基本块后，提高了检测模型对复杂港口环境下集装箱损伤目标的特征提取能力；在改进特征融合网络 Bi-PFN 后，更多的提取到不同尺度的集装箱损伤图像融合后的特

征信息,提高了损伤目标检测的鲁棒性;将原损失函数替换为 EIOU Loss,更精准地回归预测框,进一步提升港口集装箱损伤检测模型的检测精度。实验结果表明改进的

YOLOv5 算法模型在港口复杂背景下对不同尺度的集装箱损伤目标均有良好的识别效果,每种损伤类型的 AP 值如表 4 所示。

表 4 不同损伤类型的 AP 值

指标	锈蚀	凹凸磕碰	裂缝	箱体变形	破洞	箱门打开	堆垛坍塌
AP	0.953	0.986	0.995	0.994	0.978	0.995	0.982

为了更加直观的体现改进后 YOLOv5 模型检测的效果,下面给出其与传统 YOLOv5 模型和其他先进算法模型的可视化检测结果对比,如图 11 所示。

根据以上可视化结果对比可以发现,原始 YOLOv5 模型在检测中易受港口复杂检测背景干扰,产生错检现象,在相同条件下对一处目标进行反复多次检查、错误识别周遭环境为损伤类型,并且原始的 YOLOv5 模型针对小目标的集装箱损伤,易发生漏检现象;改进后的模型对损伤目标的判断更加可靠,不仅能够成功识别出各类损伤目标,且定位准确,无错检漏检现象;且由图 11(c)~(e)可以看到,与两种先进的 YOLOv5 改进算法相比,本文提出

的改进算法在不同场景、不同尺度损伤目标的条件下,对于相同的图像数据,整体检测率都要更高,且对损伤目标的框定更加准确。充分体现了本文改进后 YOLOv5 模型检测效果的优越性。

3)对比试验

为进一步验证本文提出算法的检测精度,下面与现阶段的主流检测算法进行对比实验,实验结果如表 5 所示。

由表 5 可见,本文提出的改进 YOLOv5 模型在一系列优秀算法前表现优异,在不过多增加网络模型权重文件内存占比的情况下,mAP 达到了 98.32%,与其他算法相比具有明显的优势。虽然在网络结构上增加了针对性的




图 11 检测效果对比

表 5 检测算法性能比较

网络模型	mAP/%	Ws/MB	帧率/fps
SSD	75.80	24.18	58.45
Faster-RCNN	82.27	136.57	17.60
YOLOv5s	94.04	14.15	80.37
YOLOv5-EB ^[26]	96.34	14.34	74.06
YOLOv5s-FCC ^[27]	97.94	14.38	75.64
YOLOv7	97.11	73.11	94.28
改进 YOLOv5	98.32	14.35	74.71

修正导致一定程度上时间成本的牺牲,但检测速度仍能达到 74.71 fps,完全满足实时检测的需求,验证了本文提出的港口集装箱损伤检测算法模型改进的优越性。

4 结 论

针对港口集装箱损伤问题展开目标检测,本文基于 YOLOv5s 网络模型进行改进;引入改进 CBAM 注意力机制,在增强集装箱损伤目标特征的同时抑制无关区域特征,使模型获取更多的损伤特征信息,从而弱化港口复杂背景对检测结果的干扰和影响;改进双向融合特征网络 Bi-FPN 的连接结构,通过跨层特征连接融合及引入权值,解决不同尺度的特征图对特征融合贡献不同的问题;使用 EIOU Loss 替换原损失函数,解决原网络收敛缓慢与不稳定等问题。实验结果表明,本文的改进算法相比原网络模型,准确率提升了 4.55%,召回率提升了 6.05%,平均精度提升了 4.28%,且达到了 98.32% 的准确率,符合实际港口作业中对智能验箱的高精度要求。但由于集装箱表面的结构特性,部分损伤图像受光线、角度影响,不能满足识别的需求,下一步将继续结合改进方法,通过提升被检测集装箱图像数据的质量,进一步提高港口集装箱损伤检测精度。

参 考 文 献

[1] 竺新海. 集装箱物流行业市场与发展趋势[J]. 船舶物资与市场, 2022, 30(1): 78-80.

[2] 宓超, 黄世凤, 张钰洁, 等. 自动化集装箱码头装卸目标三维测量系统设计[J]. 电子测量与仪器学报, 2023, 37(2): 160-170.

[3] 王信龙, 王子萌. 基于 5G 的智慧港口应用研究[J]. 数据通信, 2021(5): 4-6.

[4] 崔国宁, 杨理践, 耿浩, 等. 基于卷积神经网络的管道缺陷量化识别方法[J]. 仪表技术与传感器, 2022(10): 99-103.

[5] 叶飞, 骆星智, 宋永春, 等. 基于双特征融合的改进 R-CNN 电力小金具缺陷检测方法研究[J]. 电子测量与仪器学报, 2023, 37(7): 213-220.

[6] 霍超, 谷晓钢, 黄玲琴, 等. 基于 YOLO v4 优化的航拍绝缘子缺陷图像检测模型[J]. 电子测量技术, 2023,

46(9): 175-181.

[7] KATTAINEN E. Object detection for container corner detection[D]. Tampere: Tampere University, 2019.

[8] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.

[9] 孙长迪, 潘志松, 张艳艳. 基于低开销可变形卷积的 MobileNet 再轻量化方法[J]. 计算机科学, 2022, 49(12): 312-318.

[10] 李学威, 薛占熬. 基于 ResNet 及损失函数的模糊图像复原算法[J]. 国外电子测量技术, 2023, 42(5): 27-34.

[11] WANG Z X, GAO J, ZENG Q CH, et al. Multitype damage detection of container using CNN based on transfer learning [J]. Mathematical Problems in Engineering, 2021(2): 1-12.

[12] KORA P, OOI C P, FAUST O, et al. Transfer learning techniques for medical image analysis: A review[J]. Biocybernetics and Biomedical Engineering, 2022, 42(1): 79-107.

[13] 严春满, 张翔, 王青朋. 基于改进 MobileNetV2 的人脸表情识别[J]. 计算机工程与科学, 2023, 45(6): 1071-1078.

[14] 陈帅, 李焕锋, 沙杰, 等. 基于 YOLOv5 的砂纸表面缺陷检测方法研究[J]. 电子测量技术, 2023, 46(14): 73-79.

[15] 谢林森, 朱文忠, 谢康康, 等. 基于改进 YOLOv5s 的光伏电池 EL 缺陷图像检测模型[J]. 国外电子测量技术, 2023, 42(6): 93-102.

[16] 胡欣, 周运强, 肖剑, 等. 基于改进 YOLOv5 的螺纹钢表面缺陷检测[J]. 图学学报, 2023, 44(3): 427-437.

[17] 丁伟利, 张志鹏, 雷子琦, 等. 深度学习陶瓷表面缺陷检测算法研究[J/OL]. 电子测量与仪器学报: 1-10 [2023-11-04]. <http://kns.cnki.net/kcms/detail/11.2488.TN.20231010.1154.006.html>.

[18] 胡丹丹, 张忠婷, 牛国臣. 融合 CBAM 注意力机制与可变形卷积的车道线检测[J/OL]. 北京航空航天大学学报: 1-14 [2023-09-05]. <https://doi.org/10.13700/j.bh.1001-5965.2022.0601>.

[19] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.

[20] 张倩, 刘紫燕, 陈运雷, 等. 融合 Transformer 和改进 PANet 的 YOLOv5s 交通标志检测[J]. 传感技术学报, 2023, 36(2): 232-241.

[21] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-

- 157.
- [22] ZHANG R, XIE C, DENG L W. A fine-grained object detection model for aerial images based on YOLOv5 deep neural network[J]. Chinese Journal of Electronics, 2023, 32(1):51-63.
- [23] 项融融, 李博, 赵桥. 基于改进 YOLOv5s 的口罩佩戴检测算法[J]. 国外电子测量技术, 2022, 41(7):39-44.
- [24] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [25] 侯志强, 刘晓义, 余旺盛, 等. 使用 GIoU 改进非极大值抑制的目标检测算法[J]. 电子学报, 2021, 49(4): 696-705.
- [26] 王昕, 董琴, 杨国宇. 基于优化 CBAM 改进 YOLOv5 的农作物病虫害识别[J]. 计算机系统应用, 2023, 32(7):261-268.
- [27] ZHANG Y, MA R G, LIANG C. Road target detection algorithm based on improved YOLOv5 in UAV images [J/OL]. Journal of Measurement Science and Instrumentation: 1-13 [2023-09-05]. <http://kns.cnki.net/kcms/detail/14.1357.TH.20230703.1842.002.html>.

作者简介

裴晓芳(通信作者), 硕士, 副教授, 主要研究方向为信号处理与应用、嵌入式系统设计。

E-mail: xiaofangpei@163.com

刘菁宇, 硕士研究生, 主要研究方向为深度学习、图像处理。

E-mail: 20211249645@nuist.edu.cn