

基于改进YOLOv5的退役轴类零件表面损伤检测方法

刘伟崑, 邱佳鹤, 胡光大, 刘泽远

(大连理工大学 高性能精密制造全国重点实验室, 辽宁 大连 116024)

摘要: 针对传统检测方法在对退役轴类零件进行损伤检测时存在效率低、结果一致性差等问题, 提出了一种基于改进YOLOv5的退役轴类零件表面损伤检测方法. 首先, 将注意力机制嵌入检测算法中, 增强了损伤在图像中的特征表示; 然后, 采用重复加权双向特征融合方法改进了检测模型的网络结构, 有效提升了网络特征提取能力; 最后, 使用Ghostconv卷积模块代替普通卷积, 大幅度降低了模型参数量. 实验结果显示, 改进后的算法模型精度比原始YOLOv5提升了6.9%, 达到88.4%, 同时模型参数量减少了6.1%, 保证了检测速度与YOLOv5持平. 与YOLOv3, SSD, Faster-RCNN等主流检测方法相比, 在保证较高检测速度的同时, 检测精度也有着明显优势.

关键词: YOLOv5; 表面损伤检测; 注意力机制; 多路特征融合; Ghostconv

中图分类号: TP 391.4 文献标志码: A 文章编号: 1005-3026(2024)07-1002-09

Surface Damage Detection Method for Retired Shaft Parts Based on Improved YOLOv5

LIU Wei-wei, QIU Jia-he, HU Guang-da, LIU Ze-yuan

(State Key Laboratory of High-Performance Precision Manufacturing, Dalian University of Technology, Dalian 116024, China. Corresponding author: LIU Wei-wei, E-mail: liuww@dlut.edu.cn)

Abstract: Aiming at the existing problems of low efficiency and poor consistency in the damage detection of retired shaft parts by traditional detection methods, an improved YOLOv5-based surface damage detection method for retired shaft parts is proposed. Firstly, the attention mechanism is embedded into the detection algorithm to enhance the feature representation of damage in the image. Then the network structure of the detection model is improved by using the repeated weighted bidirectional feature fusion method to effectively enhance the network feature extraction capability. Finally, Ghostconv convolution module is used instead of normal convolution, which drastically reduces the number of model parameters. The experimental results show that the accuracy of the modified algorithm model has improved by 6.9% compared to the original YOLOv5, reaching 88.4%, while the number of model parameters has reduced by 6.1%, ensuring the detection speed is on par with YOLOv5. Compared with such mainstream detection methods as YOLOv3, SSD and Faster-RCNN, its detection accuracy has a significant advantage while ensuring a higher detection speed.

Key words: YOLOv5; surface damage detection; attention mechanism; multiplex feature fusion; Ghostconv

金属轴类工件是各类设备的重要零部件, 主要起着连接传动系统和承受载荷等作用^[1], 随着我国装备机械的不断发展, 产生了大量退役轴类

零件. 经过一次或多次服役周期, 这些轴表面易形成凹坑、划痕、锈蚀等不同类型的损伤, 这些损伤在轴再次服役过程中容易破坏原有应力结构,

加速损伤扩散过程,影响再制造性能,易造成设备故障^[2],因此损伤检测是保证轴类零件再制造质量的重要环节.现有的轴表面损伤检测方式主要依靠人工完成,检测效率难以保证,检测结果一致性差,同时易发生错检、漏检等情况,而且检测过程可能会产生二次损伤,轴的质量难以得到保障.因此,研究一种准确且高效的退役轴类零件表面损伤检测方法以弥补人工的疏漏,有着重要现实意义.

面向结构件的无损检测主要可分为:基于声发射的检测方法、基于涡流的检测方法以及基于表面损伤图像的检测方法. Joen 等^[3]开发一种非接触式旋转钢轴疲劳裂纹检测装置,对不同频率的输入信号执行相关性分析,实现亚毫米基本的疲劳裂纹检测; Neslušan 等^[4]研究磁性巴克豪森噪声在无损检测中的应用,研究表明在一定腐蚀深度内,磁性巴克豪森噪声能对钢索的腐蚀程度进行评估. Sha 等^[5]使用涡流信号对热处理引起的微观组织变化进行分析,提取材料的电导率和渗透率为特征信号,通过对组织和机械性能的分析筛选合格的轴承外圈; Xie 等^[6]提出了一种新型的频带选择脉冲涡流检测方法,对交叉升空点和过零时间进行仿真和实验分析,结果表明该方法对局部壁变薄缺陷有着很好的适应性.上述无损检测方式有着一定的优势,但其仅能针对特定损伤类型和受环境影响较大的检测特点,以及由于设备结构复杂而导致检测过程较为繁琐,都限制了这些方法的应用.

Dai 等^[7]提出了一种基于自选种子点的区域生长算法,并将其应用于YOLOv4中,对工业CT图像中晶粒缺陷区域进行分割,测量误差小于10%的缺陷尺寸,在检测隐形眼镜缺陷方面有着很好的检测效果. Tang 等^[8]在Faster-RCNN中加入多尺度最大池化操作,逐步增强感受野,可区分重要的上下文缺陷信息,在带钢缺陷检测中与单阶段目标检测算法YOLOv4和SSD相比,有着更好的检测性能. Huang 等^[9]选用带有边缘注意力融合机制的轻量级目标检测网络,并将主干网络替换为基于内卷积的特征金字塔结构,在检测速度和检测精度之间达到了很好的平衡.尽管上述方法证明了基于深度学习的表面损伤检测的可行性,但是在复杂的检测环境(例如遮挡、不同光照和多种损伤重叠等)及对比度较低的背景中,实现退役轴类零件表面典型损伤的准确检测仍具有挑战性.

YOLOv5已被证明可以显著地改善深度卷

积网络的处理时间. Guo 等^[10]提出了一种基于YOLOv5的面具佩戴检测算法,实现了复杂场景下的实时检测,大大提高了检测速度. 李鑫等^[11]在YOLOv5算法中添加坐标注意力模块,同时采用EIoU损失函数,提高了模型的回归精度,高效且准确地检测航空发动机的4种常见缺陷.然而退役轴类零件表面损伤图像中存在背景复杂、损伤对比度较低等问题,导致提取特征困难、识别效果不佳.同时,由于轴类零件在服役过程中易产生种类繁多、分布密集且尺度跨度较大的损伤,YOLOv5这种单通道检测网络在特征提取过程中会丢失大量特征信息.此外,为实现更强大的检测效果,不可避免地增加了YOLO模型的数量,这就使计算量对系统硬件的要求较高.针对上述问题,本文对4种典型的退役轴类表面损伤(凹坑、变形、划痕、锈蚀),提出了一种改进的YOLOv5模型,结合注意力机制与重复加权双向特征融合方法,实现对多种损伤目标的定位与分类,提高难识别损伤目标的特征提取效果,提高退役轴类零件表面损伤检测的效率与精度.同时将普通卷积模块替换为Ghostconv模块,在保证检测性能的同时,大大减少了模型计算量.

1 基于改进YOLOv5的退役轴类零件表面损伤检测方法

1.1 YOLOv5网络结构

本文以YOLOv5为基准模型对采集的退役轴类零件表面损伤进行检测. YOLOv5网络模型主要包括主干网络、颈部网络和预测端三部分,其结构如图1所示.

主干网络由卷积模块、C3模块和快速空间池化金字塔模块(spatial pyramid pooling-fast, SPPF)组成.其中Conv模块和C3模块是组成YOLOv5的基本单元. Conv模块依次对输入图像进行二维卷积操作、批量归一化操作以及非线性激活操作. C3模块则分为两个类型,它们均是由多个瓶颈(Bottleneck)模块构成.区别在于位于主干网络中的C3模块,其内部的瓶颈模块为残差结构,而颈部网络中的瓶颈模块则是直接经过两个卷积模块作为输出.此外, SPPF模块执行多个5×5的最大池化操作,并通过连接它们来融合特征.颈部网络通过特征金字塔网络自顶向下传递高级语义信息,低级的定位信息则通过路径聚合网络自底向上传递,将不同层级的特征信息融合在一起,尽可能减少特征信息丢失.预测端输出

一个向量,其中包含损伤目标的类别概率、损伤对象分数和损伤目标边界框的位置.预测端由 3

个检测网络组成,它们具有不同大小的特征层来检测不同大小的损伤目标.

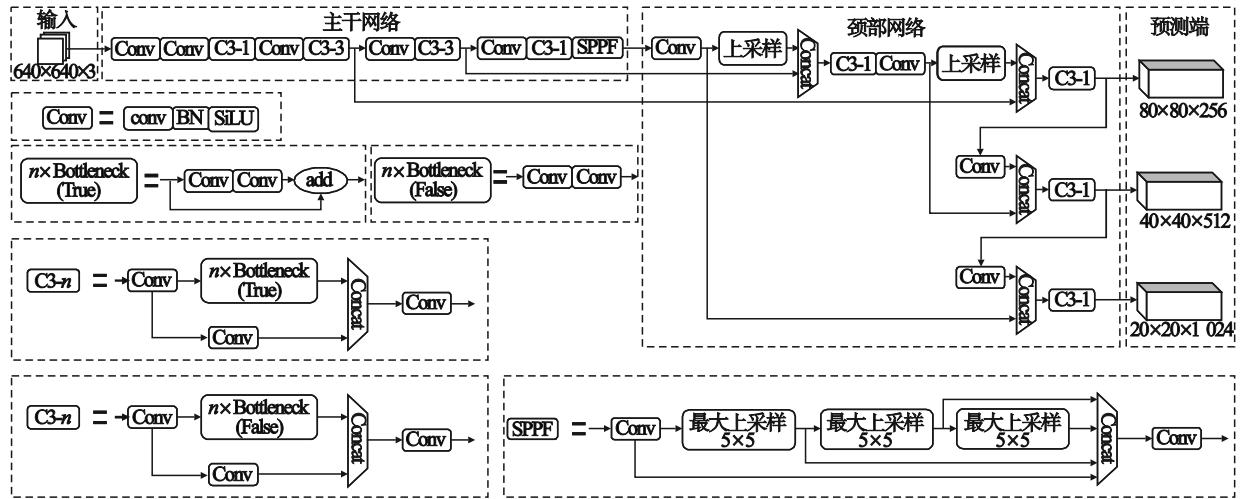


图1 YOLOv5网络结构

Fig. 1 YOLOv5 network structure

1.2 注意力机制模块

由于获取的退役轴类零件表面损伤图像有着较为复杂的背景,因此图像中损伤特征的位置信息对于正确识别表面损伤类别极其重要.注意力机制消除了多余的背景信息,增强了损伤在图像中的特征表示,并提高模型的识别性能.

在过去的注意力机制研究中仅关注各通道间的信息编码,往往忽略了特征图中的位置信息,这使得其不适用于背景信息复杂的检测任务中.本文将 Coordinate Attention(CA)^[12]注意力模

块嵌入 YOLOv5 检测网络中,通过将水平和垂直方向的权重重新分配组合的方法,沿一个空间方向关注损伤的特征信息,沿另一个空间方向保留精确的位置信息,有效地增强了包含损伤信息的特征通道,抑制包含复杂背景信息的通道.最后生成的特征图进行单独编码,形成对方向感知和位置敏感的特征图.

CA 模块的结构如图 2 所示,给定输入特征图 x ,特征图 x 沿水平和垂直空间方向分别以 $(h, 1)$ 或 $(1, w)$ 为池化核执行平均池化操作:

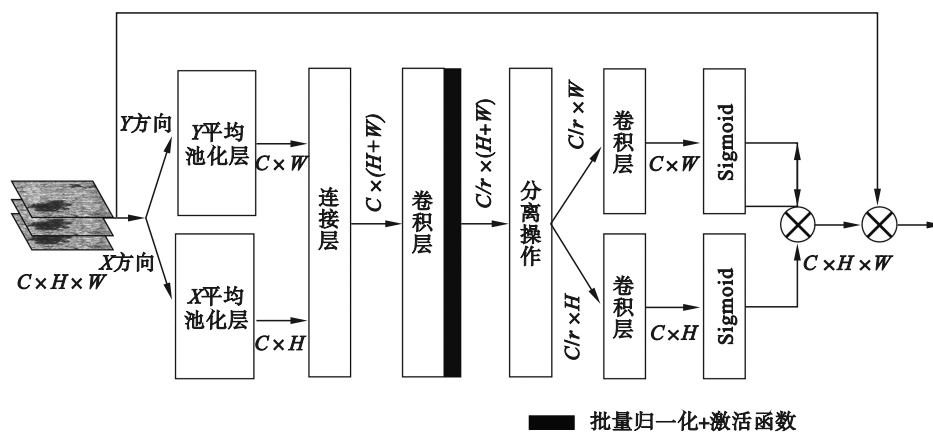


图2 CA模块结构

Fig. 2 Structure of CA module

$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j). \quad (1)$$

$$Z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i). \quad (2)$$

因此,特征图 x 在 c 通道上水平坐标 H 的 c 通道的输出为

类似地,特征图 x 在 c 通道上垂直坐标 W 的 c 通道的输出为

$$Z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < W} x_c(j, w). \quad (3)$$

两个输出进行连接操作,再通过 1×1 卷积层 F_1 和 非线性操作 δ (批量归一化操作和非线性激活函数)

$$f = \delta(F_1(\text{concat}\{z^h; z^w\})). \quad (4)$$

其中: $f \in \mathbf{R}^{C \times r \times (W+H)}$ 表示水平和垂直方向上对空间信息进行编码的中间特征图; r 为缩减率.

根据空间维度 f 分解为两个输出: $f^h \in \mathbf{R}^{C \times r \times (W+H)}$ 和 $f^w \in \mathbf{R}^{C \times r \times (W+H)}$. f^h 和 f^w 分别通过一个 1×1 的卷积层转换为与输入特征图 x 具有相同通道数的张量. 这两个输出可以表示为

$$g^h = \sigma(F_h(f^h)), \quad (5)$$

$$g^w = \sigma(F_w(f^w)). \quad (6)$$

其中: $F_h(\cdot)$ 和 $F_w(\cdot)$ 表示两个卷积变换; σ 表示

Sigmoid 函数; g^h 和 g^w 分别表示在水平和垂直方向的权重.

CA 模块的输出 y_c 记作

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j). \quad (7)$$

1.3 多路特征融合模块

在损伤检测任务中,往往是通过增加主干网络的深度来获取单个高级特征,但高级特征由于含有的像素信息较少,无法有效地从复杂的背景中区分出. YOLOv5 的 FPN+PANet 结构在进行特征融合时,对所有尺度的特征均采用相同的权重,这使得其效果具有局限性. Tan 等^[13] 提出一种重复加权双向特征融合方法 BiFPN. BiFPN 根据不同特征图的重要性分配权重,平衡各尺度间的特征信息. 本文采用 BiFPN 作为特征提取网络,由图 3 可见其结构.

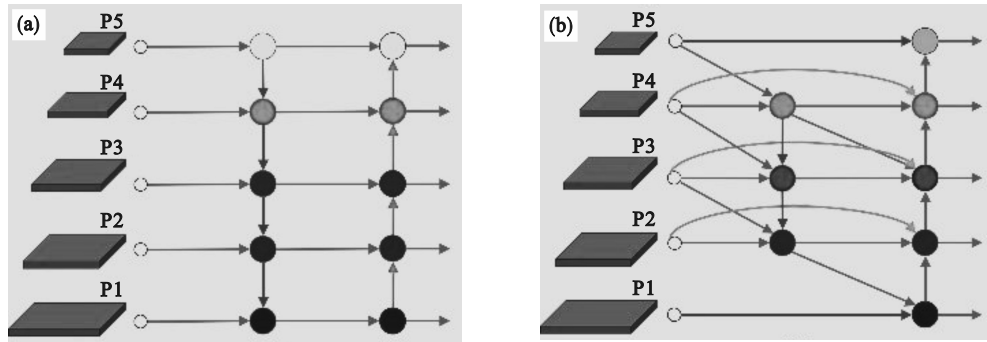


图 3 网络结构

Fig. 3 Network architecture

(a)—FPN+PANet; (b)—BiFPN.

在进行不同尺度特征图信息融合时,要将其调整为相同的分辨率. 由于这些特征图以不同程度来构成输出要素,因此要将每个输入添加额外的权重来使得输入特征发挥更大的作用. 加权的方法为

$$O = \sum_i \frac{w_i}{\varepsilon + \sum_j w_j} \cdot I_i. \quad (8)$$

其中: I_i 是输入特征; w_i 是一个可学习的权重,每次更新都会使用 ReLU 函数来确保其值大于 0; ε 是一个较小的实数,其主要作用是防止分母为 0.

以第 4 级的两个融合特征为例,两个特征融合表示为

$$P_4^{\text{id}} = C \left(\frac{w_1 \cdot P_5^{\text{in}} + R(P_5^{\text{in}}) + w_3 \cdot R(P_5^{\text{id}})}{w_1 + w_2 + w_3 + \varepsilon} \right), \quad (9)$$

$$P_4^{\text{out}} = C \left(\frac{w'_1 \cdot P_4^{\text{in}} + w'_2 \cdot P_4^{\text{id}} + w'_3 \cdot R(P_5^{\text{id}}) + w'_4 \cdot R(P_3^{\text{out}})}{(w'_1 + w'_2 + w'_3 + w'_4 + \varepsilon)} \right). \quad (10)$$

其中: C 表示深度卷积可分离操作; R 表示该分辨率的特征图上匹配的上采样或者下采样操作.

1.4 卷积操作的轻量化改进

本文将 Ghostconv^[14] 纳入损伤检测网络,以便在不影响网络性能的情况下最大限度地减少训练模型使用的参数和计算资源的数量. Ghostconv 将标准卷积过程分为两个部分:第一部分是深度卷积操作,它通过常规卷积操作获取本征特征图;第二部分是分组卷积操作,将获得的本征特征图进行二倍压缩,分成若干组分别进行卷积操作,再通过一个类似于残差网络的结构进行线性组合,构建新的特征. 由于采用了分组卷积的思想,将 Ghostconv 纳入损伤检测网络,在保持原有检测精度的同时,使整个模型的参数量大大降低,有效地减少了训练过程的计算成本.

假设 h, w, c 是输出特征的高度、宽度和通道数, k 和 n 代表公共卷积核的大小和数量,那么一个公共卷积的浮点运算数 (FLOP) 为

$$FLOP = x \times h \times w \times c \times k \times k. \quad (11)$$

其中 n 和 c 通常非常大,例如 256 或者 512. 假设 Ghostconv 运算得到 s 个特征图,恒等映射得到 m 个特征图,总共 $n = m \times s$ 特征图,当一个 Ghostconv 产生一个恒等映射时需要进行 $m(s-1) = n(s-1)/s$ 次线性运算,而每次线性运算的平均内核大小为 $d \times d$,那么使用 Ghostconv 的理论加速比为

$$r_s = \frac{n \cdot h \cdot w \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot h \cdot w \cdot c \cdot k \cdot k + \frac{n}{s} \cdot (s-1) \cdot h \cdot w \cdot d \cdot d} = \frac{c \cdot k \cdot k}{\frac{1}{s} \cdot c \cdot k \cdot k + \frac{s-1}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s. \quad (12)$$

从式(12)可以知道,用 Ghostconv 代替普通卷积可以带来参数和计算次数的减少,大大加快了计算速度.

1.5 改进后的网络结构

本文将 CA 注意力模块添加在主干网络末尾,消除冗余的背景信息,获得干扰更少的特征图;然后针对锈蚀等难识别对象,修改模型结构,采用 BiFPN 结构可以更好地平衡不同尺度的特征信息,有利于难识别损伤的检测;最后,将原有的普通卷积块全部更换为 Ghostconv 卷积块,大幅度减少模型参数的同时,保证损伤检测的精度和效率.改进后的网络结构如图 4 所示.

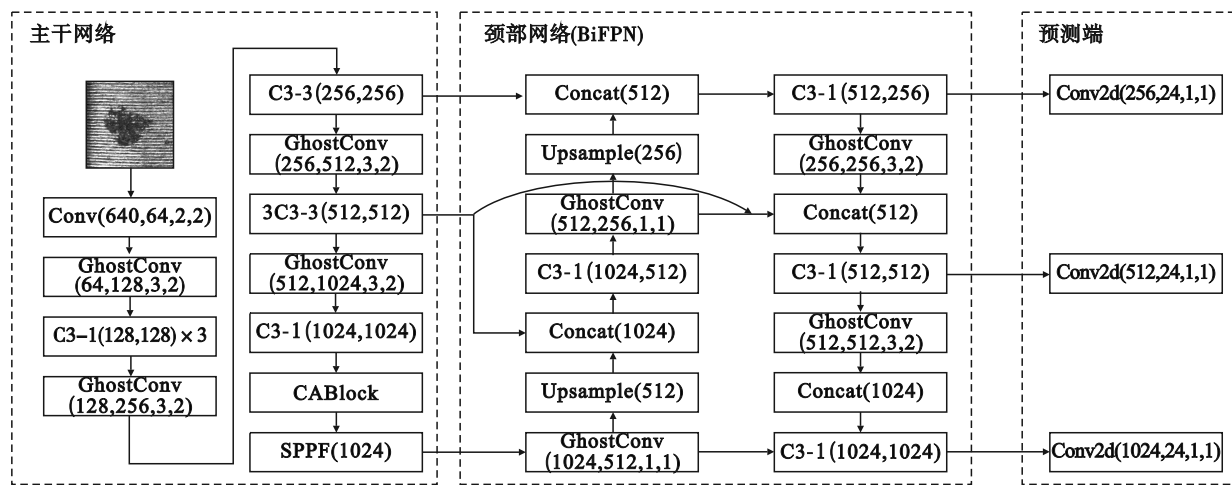


图 4 改进的 YOLOv5 的结构

Fig. 4 Structure of the improved YOLOv5

2 分析与讨论

2.1 实验环境及参数

Adam 算法能够通过保留每个参数的学习率来提高稀疏梯度的性能来加速学习过程,同时可以基于每个参数权重梯度的最接近幅度的平均值,自适应地保持学习率,有效地缓解了 SGD 算法收敛速度慢和收敛效果差等问题.因此在训练模型时,本文采用 Adam 算法对每次迭代后的网络参数进行优化更新,权重衰减和动量分别为 0.000 1 和 0.936. 学习率衰减策略为固定步长衰减,初始学习率为 0.01. 每批次的训练图像数目为 8,共训练 150 个循环. 训练结果如图 5 所示,模型的精度和召回率在 40 次训练后逐步达到极值并趋于稳定,训练损失曲线逐渐趋于平稳且波动较小,拟合效果较好,没有出现欠拟合和过拟合的情况. 实验环境:深度学习开源框架 PyTorch 1.11.0, Windows 10 操作系统, Python 3.9, 英特尔

酷睿 I7-8700CPU 和具有 16 GB 内存的 Quadro RTX 5000 图形处理单元 GPU.




图 5 模型训练结果

Fig. 5 Model training results

2.2 数据集获取

在退役轴类零件表面损伤检测中,并没有公开的数据集可以使用,本研究使用图像捕获系统收集尺寸一致的退役轴类零件表面损伤图像.

退役电机轴表面损伤图像包括凹坑、变形、划痕、锈蚀4种损伤类型,如图6所示,保存为jpg格式,大小为 400×400 像素,共计1200张图像构建起退役轴类零件表面损伤数据集.数据集包含:①同一损伤不同角度拍摄的退役电机轴图像;②同一电机轴上拍摄多种不同损伤的图像;③同一类损伤在不同电机轴上拍摄的图像;④同一电机轴上拍摄多个同类别损伤的图像等,各类型损伤数量如图7所示.每张图像在主体突出度、背景复杂性、照明条件和图像清晰度方面都有着一定的差异.




图6 损伤类型

Fig. 6 Type of damage

(a)—凹坑;(b)—变形;(c)—锈蚀;(d)—划痕.




图7 数据集各缺陷样本数统计

Fig. 7 Statistics on the number of samples for each defect in the data set

本文将整个数据集划分为训练集、验证集以及测试集,其比例为7:2:1.

2.3 评价标准

在缺陷检测的任务中,通常采用平均精度均值(mAP)来量化算法模型的性能.假设要检测的

损伤类型为 K ,mAP使用最常见的统计数据(精度 P 和召回率 R)来计算,而 $F1$ 分数结合了精度和召回率,客观地反映了分类方法的泛化性能.具体计算公式为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (13)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (14)$$

$$AP = \int_0^1 P(R) dR, \quad (15)$$

$$mAP = \frac{1}{K} \sum_{i=1}^K AP_i, \quad (16)$$

$$F1 = \frac{2 \times P \times R}{P + R}. \quad (17)$$

式中: N_{TP} 表示正确分类的退役轴类零件表面损伤的数量; N_{FP} 表示预测为背景的退役轴类零件表面损伤的个数; N_{FN} 表示标识为缺陷的正常样本的个数;AP表示平均精度.

2.4 消融实验及对比实验

2.4.1 改进方法对模型性能的影响

本文采用消融实验来验证网络结构变化带来的检测性能变化.本文共训练了5组实验,采用5种改进的YOLOv5算法与原始的YOLOv5算法进行对比,具体结果如表1所示.从表1可以看出,原始的YOLOv5算法的mAP评分为80.0%.将CA注意力模块和BiFPN分别赋予YOLOv5网络结构后,改进模型的平均检测处理时间略有增加,而模型的mAP评分分别提升了4.7%和4.9%;将CA注意力模块和BiFPN同时赋予YOLOv5网络结构后,模型的整体检测精度提升了6.6%.将所有Conv模块替换为Ghostconv模块后,平均检测时间比更改之前略有减少,改进模型中的参数量比YOLOv5减少了6.1%,同时模型的检测精度提升至88.4%.消融实验中各方法的 $P-R$ 曲线如图8所示,可以看出本文所提改进的YOLOv5退役轴类零件表面损伤检测方法的总体识别精度明显优于其他方法.改进前后算法检测结果如图9所示,可以看到改进后的YOLOv5算法有着更好的检测效果,同时避免了许多错检、漏检情况的发生.

2.4.2 注意力机制模块性能对比

为验证本文所采用的注意力机制模块对于检测性能提升的有效性,本文将所提出的改进的YOLOv5算法中CA注意力模块分别替换为SE(Model 1)和CBAM(Model 2)注意力模块作为对比实验,具体结果如表2所示.与本文所提方法相

比,三个模型的 F1 评分和参数量并没有很大差异;而对于 mAP 评分,嵌入 SE 模块和 CBAM 模块的算法均小于本文所提方法,即本文所提方法所采用的 CA 注意力模块对目标检测网络识别性能的提升效果优于 SE 和 CBAM 注意力模块.这是因为 CA 注意力模块会利用退役轴类零件损伤

图像中位置信息,形成对位置更加敏感的特征图,提升损伤的识别精度.3 种检测方法的 P-R 曲线如图 10 所示,带有 CA 注意力模块的总体识别精度明显优于其他两种方法,进一步表明 CA 注意力模块更加适用于有复杂背景的损伤检测任务.

表 1 YOLOv5 的消融实验
Table 1 Ablation experiments of YOLOv5

算法	CA	BiFPN	Ghostconv	精度	召回率	mAP/%	参数量	F1	检测速度/(帧·s ⁻¹)
YOLOv5				0.840	0.91	80.0	7 030 417	0.76	31
Improved 1	√			0.885	0.94	84.7	7 045 521	0.82	29
Improved 2		√		0.907	0.93	84.9	7 169 402	0.84	28
Improved 3	√	√		0.917	0.96	86.6	7 112 097	0.83	24
Improved 4		√	√	0.875	0.96	86.0	6 665 946	0.83	30
Improved 5	√	√	√	0.873	0.98	88.4	6 679 601	0.84	33




图 8 消融实验中各方法的 P-R 曲线

Fig. 8 P-R curves of each method in the ablation experiment

(a)—YOLOv5; (b)—Improved 1; (c)—Improved 2; (d)—Improved 3; (e)—Improved 4; (f)—Improved 5.

2.4.3 与主流目标检测模型性能对比

为验证本文所改进的 YOLOv5 算法的检测性能,使用几种广泛应用的目标检测算法进行对比,包括单阶段检测算法 SSD^[15]和 YOLOv3^[16],双阶段检测算法 Faster-RCNN^[17]和 Faster-RCNN (FPN).采用相同的退役轴类零件表面损伤数据集进行训练,得到各个算法的检测速度、mAP 评分以及各类别损伤的检测精度.如表 3 所示,可以

看到本文所改进的 YOLOv5 算法,在检测速度方面与双阶段目标检测算法相比有着明显优势,与单阶段目标检测算法 (YOLOv3, SSD, YOLOv5) 相比,在嵌入了 CA 注意力模块与重复加权双向特征融合功能后,检测速度并没有因此而变得缓慢;检测精度有着明显优势(整体检测识别率最高可达 88.4%),尤其是对于锈蚀这类难识别目标,检测精度可达 77.7%.

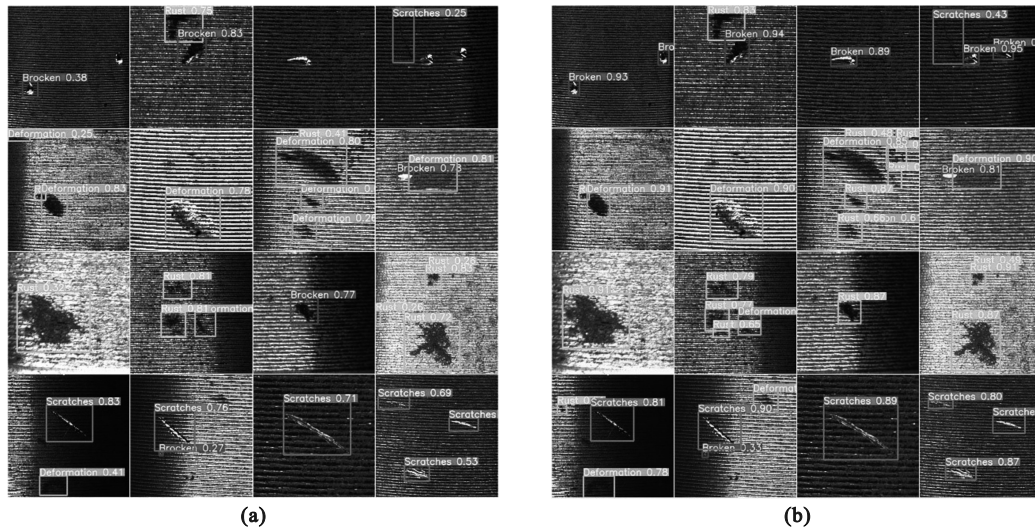


图 9 改进前后检测结果对比

Fig. 9 Comparison of detection results before and after improvement
(a)—原始YOLOv5; (b)—改进的YOLOv5.

表 2 注意力机制模块性能对比

Table 2 Comparison of the attention mechanism module performance

算法	SE	CBAM	CA	精度	召回率	mAP/%	参数量	F1	检测速度/(帧·s ⁻¹)
Model 1	√			0.884	0.97	85.9	6 671 377	0.84	32
Model 2		√		0.907	0.95	86.8	6 671 475	0.85	33
本文			√	0.873	0.98	88.4	6 679 601	0.84	33

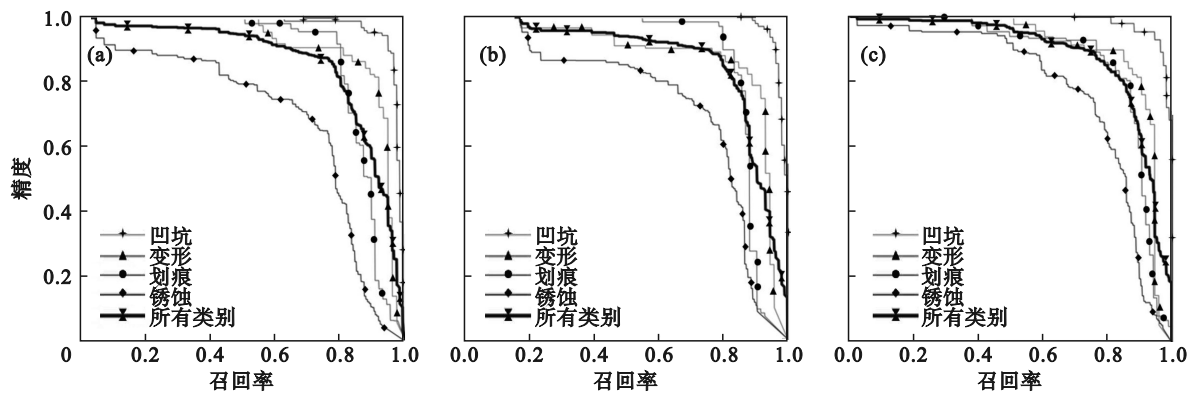


图 10 三种检测方法的 P-R 曲线

Fig. 10 P-R curves of three detection methods
(a)—Model 1; (b)—Model 2; (c)—本文.

表 3 不同模型性能对比

Table 3 Performance comparison of different models

算法	速度/(帧·s ⁻¹)	mAP/%	AP/%			
			凹坑	变形	划痕	锈蚀
YOLOv3	29	69.7	83.3	69.9	64.6	51.4
SSD	18	76.2	76.2	93.4	73.1	62.4
Faster-RCNN	<10	64.6	77.6	67.3	59.3	54.5
Faster-RCNN(FPN)	<10	80.3	87.4	85.5	83.9	64.4
YOLOv5	32	80.0	90.5	97.0	81.3	51.1
Improved YOLOv5	33	88.4	98.4	90.3	87.3	77.7

3 结 论

1) 本文提出一种改进的 YOLOv5 算法应用于退役轴类零件表面损伤检测. 首先将注意力机制引入检测模型中, 消除了多余的背景信息, 增强了损伤在图像中的特征表征; 然后采用多路特征融合模块, 更好平衡多尺度特征图的上下文信息; 最后使用 Gostconv 模块代替模型原有的普通卷积, 在不影响网络性能的情况下最大限度地减少训练模型使用的参数和计算资源的数量. 与原始的 YOLOv5 模型相比, 改进的 YOLOv5 模型平均检测精度有着明显提升, 可达 88.4%; 模型整体的参数量减少了 6.1%.

2) 分别使用 SE 注意力模块和 CBAM 注意力模块来替换 CA 注意力模块, 模型整体检测精度分别下降 2.5% 和 1.6%, 进一步表明 CA 注意力模块更适用于有着复杂背景的损伤检测任务.

3) 对比 4 种主流的目标检测算法, 本文提出的算法针对 4 种退役轴类零件表面损伤能够实现智能高效检测, 平均检测速度可达 $33 \text{ 帧} \cdot \text{s}^{-1}$, 对于锈蚀这类难识别目标, 检测精度可达 77.7%, 能够在保证精度的同时实现高效损伤检测.

参考文献:

- [1] Syed R, Wang J G, Jing D Y, et al. Case study: optimization of case depth in induction-hardened 42CrMo steel shaft[J]. *IOP Conference Series: Materials Science and Engineering*, 2020, 831(1):012004.
- [2] 孙斌. 金属轴类零件表面缺陷成像与判识技术研究[D]. 南京: 南京理工大学, 2017.
(Sun Bin. Research on surface defect imaging and identification technology of metal shaft parts[D]. Nanjing: Nanjing University of Science and Technology, 2017.)
- [3] Jeon I, Lim H J, Liu P P, et al. Fatigue crack detection in rotating steel shafts using noncontact ultrasonic modulation measurements [J]. *Engineering Structures*, 2019, 196: 109293.
- [4] Neslušán M, Bahleda F, Minárik P, et al. Non-destructive monitoring of corrosion extent in steel rope wires via Barkhausen noise emission [J]. *Journal of Magnetism and Magnetic Materials*, 2019, 484: 179–187.
- [5] Sha J W, Fan M B, Cao B H, et al. Noncontact and nondestructive evaluation of heat-treated bearing rings using pulsed eddy current testing [J]. *Journal of Magnetism and Magnetic Materials*, 2021, 521: 167516.
- [6] Xie S J, Zhang L, Zhao Y, et al. Features extraction and discussion in a novel frequency-band-selecting pulsed eddy current testing method for the detection of a certain depth range of defects [J]. *NDT & E International*, 2020, 111: 102211.
- [7] Dai J J, Li T P, Xuan Z L, et al. Automated defect analysis system for industrial computerized tomography images of solid rocket motor grains based on YOLO-V4 model [J]. *Electronics*, 2022, 11(19): 3215.
- [8] Tang M, Li Y Y, Yao W, et al. A strip steel surface defect detection method based on attention mechanism and multi-scale maxpooling [J]. *Measurement Science and Technology*, 2021, 32(11): 115401.
- [9] Huang Z Y, Hu H J, Shen Z Y, et al. Lightweight edge-attention network for surface-defect detection of rubber seal rings [J]. *Measurement Science and Technology*, 2022, 33(8): 085401.
- [10] Guo S Y, Li L L, Guo T Y, et al. Research on mask-wearing detection algorithm based on improved YOLOv5 [J]. *Sensors*, 2022, 22(13): 4933.
- [11] 李鑫, 李香蓉, 汪诚, 等. 基于改进 YOLOv5 的航空发动机表面缺陷检测模型 [J]. *激光与光电子学进展*, 2023, 60(16): 1615007.
(Li Xin, Li Xiang-rong, Wang Cheng, et al. Aero-engine surface defect detection model based on improved YOLOv5 [J]. *Laser & Optoelectronics Progress*, 2023, 60(16): 1615007.)
- [12] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 13713–13722.
- [13] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 10781–10790.
- [14] Han K, Wang Y H, Tian Q, et al. Ghostnet: more features from cheap operations [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 1580–1589.
- [15] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector [C]// Proceedings of 14th European Conference on Computer Vision–ECCV 2016. Cham: Springer, 2016: 21–37.
- [16] Redmon J, Farhadi A. YOLOv3: an incremental improvement [EB/OL]. (2018–04–08) [2023–03–01]. <https://arxiv.org/abs/1804.02767>.
- [17] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137–1149.