DOI: 10.13382/j.jemi.B2306476

改进 YOLOv5 的 PDC 钻头复合片缺损识别*

代啟亮[1] 熊 凌[1] 陈琳国[1] 李姝凡[2]
(1. 武汉科技大学信息科学与工程学院 武汉 430081;2. 中石化江钻石油机械有限公司 武汉 430200)

摘 要:PDC 钻头复合片的缺损情况是影响钻进效率的重要因素,检测 PDC 钻头复合片是否缺损是修复 PDC 钻头的前提。为了减少对 PDC 钻头复合片的误检,提升检测准确率,提出了一种基于改进 YOLOv5 的目标检测算法。该方法以 YOLOv5 网络为基础,融合 RepVGG 重参数化模块增强网络的特征提取能力;在 C3 模块中引入坐标注意力机制,在通道注意力机制中嵌入位置信息,提升对缺损复合片的目标检测能力;将边界框回归损失函数改进为 WIoU 损失函数,制定合适的梯度增益分配策略。实验结果表明,改进后的网络的精确率提升 2%,召回率提升 0.9%,平均精度均值(mAP)提升了 1.3%,达到了 98%,能够实现对 PDC 钻头复合片的缺损识别。

关键词: PDC 钻头复合片;YOLOv5;RepVGG;坐标注意力机制;WIoU 损失函数
中图分类号: TP399 **文献标识码**: A **国家标准学科分类代码**: 520.2060

PDC drill bit defect recognition by improved YOLOv5

Dai Qiliang[1] Xiong Ling[1] Chen Linguo[1] Li Shufan[2]
(1. School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081, China;
2. Sinopec Jiang Diamond Oil Machinery Co., Ltd., Wuhan 430200, China)

Abstract: The defect of the PDC bit compact is an important factor affecting the drilling efficiency, and detecting whether the PDC bit compact is defective is a prerequisite for repairing the PDC bit. In order to reduce the false detection of PDC drill bit composites and improve the detection accuracy, a target detection algorithm based on improved YOLOv5 is proposed. This method is based on the YOLOv5 network, and integrates the RepVGG reparameterization module to enhance the feature extraction ability of the network; introduces the coordinate attention mechanism in the C3 module, embeds the position information in the channel attention mechanism, and improves the target detection ability of the defective composite film. Improve the bounding box regression loss function to the WIoU loss function, and formulate a suitable gradient gain allocation strategy. The experimental results show that the precision rate of the improved network increased with 2%, the recall rate increased with 0.9%, and the mean average precision (mAP) increased with 1.3%, reaching 98%, which can realize the defect recognition of PDC drill bit composites.

Keywords: PDC drill bit composite; YOLOv5; RepVGG; coordinate attention mechanism; WIoU loss function

0 引 言

聚晶金刚石复合片钻头(polycrystalline diamond compact bit, PDC)已经在地质勘探、石油开采等领域得到了广泛的应用[1]。在钻进过程中 PDC 钻头复合片会产生磨损,由于 PDC 钻头成本较高,对于磨损的 PDC 钻头复合片进行修复,可以很大程度降低生产成本,为企业带来经济效益,且修复后的钻头仍然具有不低于出厂效果的良好性能[2]。在修复之前需要查看 PDC 钻头复合片的失效情况,根据钻头的失效情况制定相应的修复方案。目前,查看钻头的磨损情况主要靠人工观测,效率较低,基于计算机视觉目标检测技术的复合片缺损识别能够显著提升效率。

收稿日期: 2023-04-26 Received Date: 2023-04-26
*基金项目:国家自然科学基金(62173261)、湖北省重点研发计划项目(2020BAB021)资助

传统的目标检测算法存在计算复杂度高及鲁棒性差等缺点,将深度学习技术应用到目标检测能够显著提高算法性能[3]。基于深度学习的目标检测算法可以分为单阶段检测和两阶段检测两种算法。两阶段目标检测算法先产生一系列候选框,然后对这些候选框样本进行分类和候选框位置修正,两阶段目标检测算法有 R-CNN[4]、Faster R-CNN[5]等算法。单阶段目标检测算法只需要一次处理就能得到目标检测结果,代表性的算法有 SDD[6]、YOLO[7-10]系列等算法。随着计算机视觉的发展,基于深度学习的目标检测算法在缺陷检测和智能制造等领域得到了大量应用[11-14]。对于钻头复合片失效识别,也有很多专家和学者将目标检测算法应用在该领域,Lu 等[15]对比 Fast R-CNN、YOLO 等其他钻头检测算法性能,最终选择 Blendmask 对钻头进行全景分割,同时研究了基于多视图和结构光模式的三维钻头图像重建和对三维重建后的钻头图像进行分割的方法。Ashok 等[16-17]使用 YOLOv3 目标检测算法检测出钻头的所有复合片,通过图像处理提取复合片轮廓并拟合椭圆,计算复合片轮廓与椭圆的面积占比,量化每个复合片的损失程度,最后定位复合片的位置并计算各个位置的平均损失程度。

随着 YOLO 目标检测算法的发展,YOLOv5 具有更小的计算量,同时,为了能够准确地识别出有缺损的 PDC 钻头复合片,减少误检情况的出现,本文提出了一种改进 YOLOv5s 的钻头复合片缺损识别算法,检测出复合片的同时,识别缺损和未缺损复合片。该方法在 YOLOv5s 网络的基础网络结构上,使用 RepVGG 重参数化模块替换主干网络和 C3 模块中的 3×3 卷积;同时加入坐标注意力机制模块来提升网络捕捉位置信息和通道之间的关系的能力;最后,改进边界框回归损失函数为 WIoU,使模型聚焦于普通质量的锚框,提升检测的准确性。实验结果表明改进后的 YOLOv5s 能够准确识别出有缺损和未缺损的 PDC 钻头复合片,识别精度优于改进之前的 YOLOv5s 算法。

1　YOLOv5 算法及改进

1.1　YOLOv5 算法

YOLO 系列算法属于目标检测中的单阶段算法,YOLOv1 算法在 2016 年出现,该算法比之前的两阶段目标检测算法计算速度快,准确率高。该算法直接使用回归的方法得到目标的位置信息和类别信息,大大减少了计算量,提升了目标检测性能。随着不断地对 YOLO 目标检测算法地创新与完善,YOLOv7[18]算法在 2022 年被提出,在检测准确度上都有显著提升。与 YOLOv5 相比,YOLOv7 的计算量较大,对硬件性能要求较高。本文选用计算量较小的 YOLOv5 作为 PDC 钻头复合片缺损检测算法。

YOLOv5[19]网络模型有多个版本,其中 YOLOv5s 模型计算量小,对硬件的性能要求相对较低,所以本文实验选择使用 YOLOv5s 为基础网络模型,改进 YOLOv5s 网络模型,提升模型对 PDC 复合片失效识别的准确率。如图 1 所示为 YOLOv5s 网络模型架构。

YOLOv5s 包括 Backbone 结构、Neck 结构和 Output 结构 3 个部分。首先,输入图像大小为 640×640 的三通道彩色图像;将输入图像输入到 Backbone 中的 CBL、C3 和空间金字塔(SPPF)等模块中进行主要特征提取;将 Backbone 阶段提取到的多尺度特征输入到 Neck 阶段中的特征金字塔结构(feature pyramid networks,FPN)和路径聚合网络结构(path aggregation network,PAN),完成网络结构中从深层向浅层的特征传递和从网络浅层到深层的特征传递,最终完成多尺度特征融合;将融合之后的特征传入 Output 层,输出大小为 20×20、40×40 和 80×80,通道数为(目标类别数 N+5)×3 的 3 个特征图,分别进行大、中、小 3 种不同目标大小的检测,在每个网格中产生 3 个不同大小和纵横比的候选框,经过非极大值抑制输出置信度较高的候选框,即为最后的目标检测结果。

1.2　改进 YOLOv5 算法

为了减少对于部分缺损的复合片识别出错的情况,进一步提升 YOLOv5s 网络模型对 PDC 钻头复合片特征的提取能力,在 C3 内部的 BottleNeck 模块中融合 CA 坐标注意力机制,用来捕捉位置信息和通道之间的关系;同时将带有残差连接的 BottleNeck 中的卷积核大小为 3×3 的 CBL 结构替换为 RepVGG 结构;最后使用 WIoU 损失函数替换 CIoU 损失函数,提升模型检测缺损 PDC 复合片的准确率。如图 2 所示为更改后的主干网络结构、C3_CA 和 BottleNeck_CA 结构。

1)结构重参数化

RepVGG[20]模块在训练阶段和推理阶段是两种不同的网络结构,在训练阶段有 3 个分支结构分别为 3×3 卷积、1×1 卷积分支和 identity 连接分支,每个分支后都会有一个归一化层,将 3 个分支的计算结果相加输入到 SiLU 激活函数并输出。在训练时 3 个分支分别使用不同的卷积核大小以获得不同大小的感受野,将不同感受野中获取到的信息相加,提升网络对特征信息的提取能力。RepVGG 模块在推理阶段通过结构重参数化将训练阶段的 3×3 卷积、1×1 卷积和 identity 残差连接分支融合为一个 3×3 卷积,经过 SiLU 激活函数输出。RepVGG 训练和推理结构图如图 3 所示。

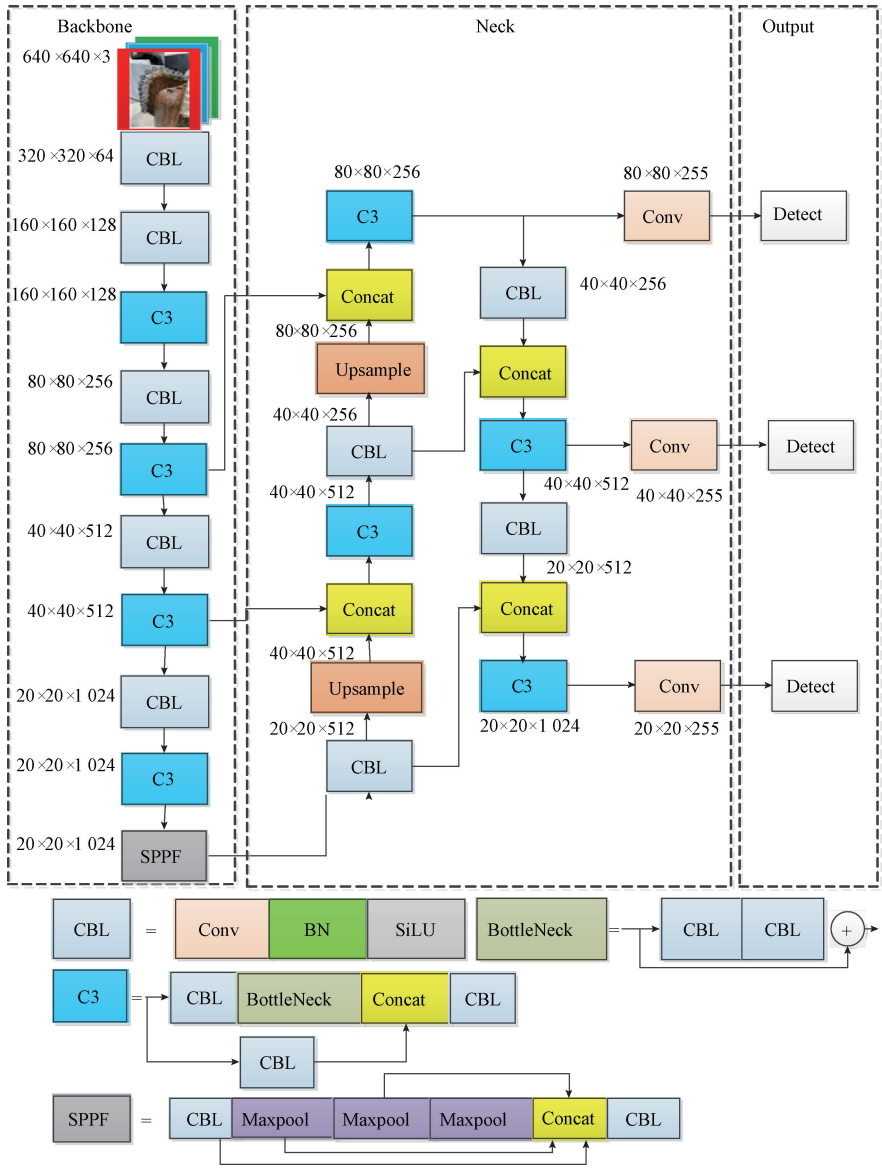

图 1　YOLOv5s 网络结构

Fig. 1　YOLOv5s network structure diagram

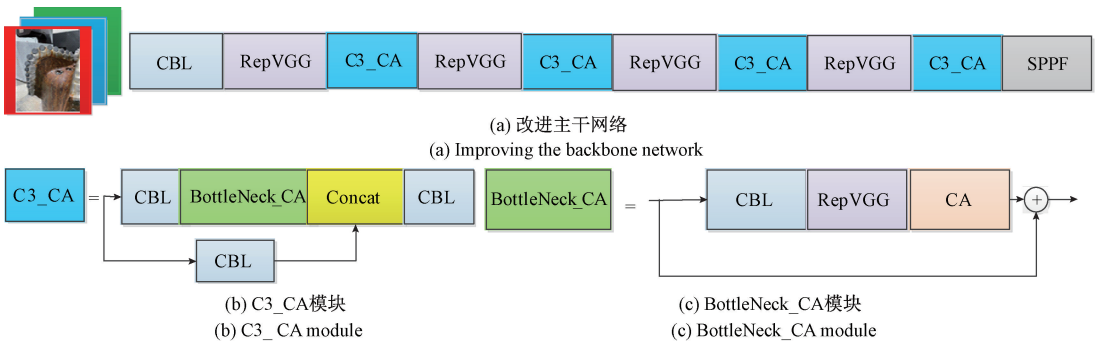

(a) 改进主干网络

(a) Improving the backbone network

(b) C3_CA模块

(b) C3_ CA module

(c) BottleNeck_CA模块

(c) BottleNeck_CA module

图 2　改进模块

Fig. 2　Improvement module

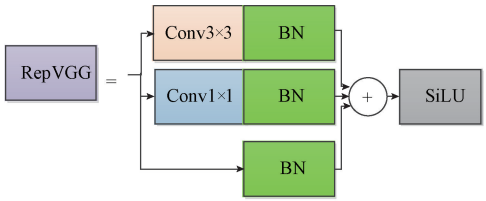

(a) 训练结构图
(a) Training structure diagram

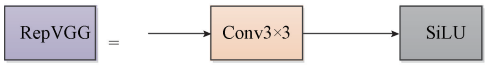

(b) 推理结构图
(b) Inference structure diagram

图 3　RepVGG 模块结构

Fig. 3　RepVGG module structure diagram

RepVGG 从训练阶段的结构转换到推理阶段的结构分为 3 步，首先，将卷积层和归一化层合并，对于恒等分支可以看成是卷积核大小为 1×1 的单位矩阵，恒等映射经过转换后，就得到了 1 个 3×3 卷积、两个 1×1 卷积和 3 个偏置向量。然后，将 3 个偏置向量相加获得最终的偏置向量。最后，将两个 1×1 卷积核用零填充为两个 3×3 卷积核，填充后就得到了 3 个 3×3 卷积核，对这 3 个 3×3 卷积核相加便得到了最终的单个的 3×3 卷积。在进行 RepVGG 重参数化时要求 1×1 卷积核和 3×3 卷积核具有相同的步长。当输入输出通道不一致或者需要降采样的时候，使用去除 identity 连接分支的 RepVGG 结构。

2）坐标注意力机制

通道注意力机制使用全局池化使网络关注全局信息，对网络性能有显著提升，但是通道注意力机制忽略了对生成空间注意力特征图很重要的位置信息，针对这一问题，Hou 等[21]提出了一种新的注意力机制，称之为坐标注意力机制（coordinate attention，CA）。坐标注意力机制同时获取通道信息和位置信息，将位置信息嵌入到通道中注意力中，使网络能够提取到和位置有关的特征信息。CA 注意力机制模块结构如图 4 所示。

通道注意力机制采用全局池化的方式处理输入，将全局空间信息压缩到通道中，因此导致了位置信息的丢失。CA 注意力机制采用先嵌入位置信息，然后再生成坐标注意力的方式。CA 注意力机制将全局池化分解成水平方向和垂直方向池化两个部分。假定输入尺寸为 $C \times H \times W$ 的特征图，使用大小为 $(H, 1)$ 和 $(1, W)$ 的池化核分别沿垂直坐标方向和水平坐标方向对每个通道进行处理，处理之后高度为 h 和宽度为 w 的第 c 个通道的输出如式（1）和（2）所示。

$$z_c^h(h) = \frac{1}{W}\sum_{0\leqslant i<W} x_c(h,i) \tag{1}$$

$$z_c^w(w) = \frac{1}{H}\sum_{0\leqslant j<H} x_c(j,w) \tag{2}$$

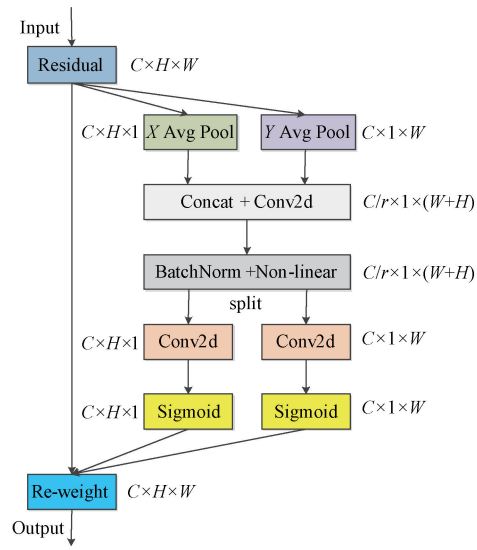

图 4　CA 注意力机制结构

Fig. 4　CA attention mechanism structure diagram

接着将池化之后产生的两个特征图级联起来，然后共享到一个卷积核大小为 1×1 的卷积变换函数中，最后经过 Sigmoid 函数输出，如式（3）所示：

$$f = \delta(F_1([z^h, z^w])) \tag{3}$$

其中，z^h 和 z^w 分别表示为输入的两个特征图，F_1 表示 1×1 卷积核，符号 δ 表示非线性激活函数 Sigmoid，$f \in \mathbb{R}^{C/r\times(H+W)}$ 是经过水平和垂直方向编码后产生的中间特征图，r 表示通道缩放比率。将 f 沿通道方向划分 $f^h \in \mathbb{R}^{C/r\times H}$ 和 $f^w \in \mathbb{R}^{C/r\times W}$ 两个部分，用两个 1×1 卷积分别将它们的通道数增加为与输入特征图相同的通道数，转换后经过 Sigmoid 激活函数产生两个注意力权重值，如式（4）和（5）所示：

$$g^h = \delta(F_h(f^h)) \tag{4}$$

$$g^w = \delta(F_w(f^w)) \tag{5}$$

其中，g^h 和 g^w 表示注意力权重值，F_h 和 F_w 表示 1×1 卷积变换。最后将输入特征图与注意力权重值 g^h 和 g^w 相乘，得到坐标注意力加权特征图，如式（6）所示：

$$y_c(i,j) = x_c(i,j) \times g_c^h(i) \times g_c^w(i) \tag{6}$$

3）WIoU 损失函数

YOLOv5 网络的损失函数包括置信度损失、分类损失和边界框损失函数，边界框损失函数反应了真实框和预测框的误差。边界框损失函数的设计对于目标检测性能有很大的影响，好的边界框损失函数能提升目标检测精度。对于目标检测数据集中会有低质量的示例，如果过多的强调对低质量示例边界框的回归，就会影响网络检测性能的提升，为了解决这一问题 Wise-IoU（WIoU）[22]损失函数被提出，WIoU 是一种基于动态非单调聚焦的机制的边界框定位损失函数。对于低质量示

例,预测框和真实框的纵横比、距离等几何度量会增加对低质量示例的惩罚影响模型的泛化能力,当预测框和真实框能够很好的重合时应当降低几何度量的惩罚。WIoU 共有 3 个版本,v1 构造了基于注意力的边界框损失,v2 和 v3 在 v1 的基础上附加聚焦机制,其中 v3 的性能更好。WIoU 根据距离度量构建得到了 WIoUv1,如式(7)所示:

$$\mathcal{L}_{WIoUv1} = \mathcal{R}_{WIoU}\,\mathcal{L}_{IoU}$$
$$\mathcal{R}_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \tag{7}$$

式中:W_g 和 H_g 表示最小包围框的宽和高,$\mathcal{R}_{WIoU} \in [1,e)$ 会在一定程度上扩大普通质量锚框的 IoU 损失函数值 $\mathcal{L}_{IoU}$,$\mathcal{L}_{IoU} \in [0,1]$ 会明显降低高质量锚框的 $\mathcal{R}_{WIoU}$,在目标框和锚框匹配度重叠度较高的情况下重点关注两个框的中心点距离,* 表示将 W_g 和 H_g 从计算图中分离。

WIoUv2 边界框回归损失函数设计了能够减少简单样本对损失值的贡献,同时使模型能够聚焦于困难样本的单调聚焦系数,提升模型目标检测性能。WIOU v2 损失函数的公式如式(8)所示:

$$\mathcal{L}_{WIoUv2} = \mathcal{L}_{IoU}^{\gamma^*}\,\mathcal{L}_{WIoUv1}, \gamma > 0 \tag{8}$$

式中:$\mathcal{L}_{IoU}^{\gamma^*}$ 在训练时会随着 $\mathcal{L}_{IoU}$ 的减小会越来越小,会产生在模型训练后期收敛慢的问题,针对这一问题,引入移动平均值 $\overline{\mathcal{L}_{IoU}}$ 使 $\left(\frac{\mathcal{L}_{IoU}^*}{\overline{\mathcal{L}_{IoU}}}\right)^{\gamma}$ 整体能保持在相对较高的水平,如式(9)所示:

$$\mathcal{L}_{WIoUv2} = \left(\frac{\mathcal{L}_{IoU}^*}{\overline{\mathcal{L}_{IoU}}}\right)^{\gamma}\mathcal{L}_{WIoUv1} \tag{9}$$

WIoUv3 损失函数使用离群度来描述锚框的质量,离群度低表示高质量锚框,离群度高表示低质量锚框,离群度的定义如式(10)所示:

$$\beta = \frac{\mathcal{L}_{IoU}^*}{\overline{\mathcal{L}_{IoU}}} \in [0, +\infty) \tag{10}$$

对离群度低的锚框分配一个小的梯度增益,使普通锚框得到更多的关注;对离群度高的锚框分配一个小的梯度增益,防止低质量锚框产生较大的有害梯度,构造一个聚焦系数并应用到 WIoUv1 得到 WIoUv3,如式(11)所示:

$$\mathcal{L}_{WIoUv3} = r\,\mathcal{L}_{WIoUv1}, r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{11}$$

因为 $\overline{\mathcal{L}_{IoU}}$ 是动态的,锚框的质量划分标准也是动态的,这就使得 WIoU v3 能够做出最适合每一时刻情况的梯度分配策略,提升模型性能。

2　实验结果与分析

2.1　实验环境

实验中 YOLOv5s 模型的搭建、训练和测试都是在深度学习框架 Pytorch 中完成的,使用 CUDA 和 CUDNN 进行加速。实验环境基于 Windows10 操作系统,CPU 型号为 Intel Core i9-11900K,运行内存为 64 GB,GPU 型号为 NVIDIA GeForce RTX 3080 Ti,显存为 12 GB。Pytorch 版本为 1.10.1,Python 版本为 3.9.1。

2.2　实验参数和数据集

本文模型的输入图像尺寸为 640×640×3,batch size 设置为 16,epoch 设置为 200,使用带动量的随机梯度下降 SGD 优化器对网络参数进行更新,初始学习率设置为 0.01,动量设置为 0.937,权重衰减系数设置为 0.000 5。

由于没有 PDC 钻头公开数据集,实验所用 PDC 钻头数据集为自行构建。本文所使用的 PDC 钻头数据集主要来源于工厂现场拍摄的 PDC 钻头图像。对采集到的图像进行筛选和整理,挑选出质量较高的图像制作数据集,共计 492 张图片。使用图像标注软件 LabelImg 对图像进行标注,标注未缺损的和有缺损的复合片的位置,并生成目标的标签信息。本文采用翻转、旋转、随即缩放、亮度变换和添加噪声等图像增强方式对原始数据集的进行扩充。扩充后的数据集总共 1 292 张图片,其中检测目标包括缺损和未缺损复合片两类,分别使用 NG 和 OK 表示。原始数据集中总共的目标有 4 859 个,其中缺损的复合片个数为 2 422,未缺损的复合片有 2 437;扩充之后数据集中目标总共有 12 409 个,其中缺损复合片目标个数为 6 224,未缺损复合片个数为 6 185。如图 5 所示为扩充后的部分数据集。

2.3　评价指标

为了验证模型性能,选用多种目标检测评价指标,包括召回率(recall, R)、精确率(precision, P)、平均精度(average precision, AP)和平均精度均值(mean average precision,mAP)。召回率表示模型的查全率,评估模型对目标检测的全不全;精确率表示模型的查准率,评估模型预测的准不准。精确率和召回率的计算公式如式(12)、(13)所示:

$$Precision = \frac{TP}{TP + FP} \tag{12}$$

$$Recall = \frac{TP}{TP + FN} \tag{13}$$

式中:TP 表示能被模型正确预测的正样本数量,FP 表示实际是负样本被模型错误预测为正样本的数量,FN 表示实际为正样本模型预测为负样本的数量。使用同一类别的召回率和精确率分别为横纵坐标轴,绘制的曲线称之为精确率-召回率(P-R)曲线,P-R 曲线和坐标轴围成的面积即为该类别的平均精度 AP,对所有类别的 AP 求平均值即可得到平均精度均值 mAP,AP 和 mAP 的计算公式如式(14)和(15)所示:

(a) 原图 (a) Original image　(b) 旋转 (b) Rotation

(c) 翻转 (c) Flipping　(d) 亮度变换 (d) Brightness transformation

图 5　部分数据集

Fig. 5　Partial dataset

$$AP = \int_0^1 p(r)\,\mathrm{d}r \tag{14}$$

$$mAP = \frac{\sum_{i=1}^{N} AP_i}{N} \tag{15}$$

式中：N 表示训练集中总的类别数量，i 表示第 i 个类别，本文实验所用的 PDC 钻头复合片数据集类别数量为两类，即 $N = 2$。

2.4　消融实验

为了确定 WIoU 边界框损失函数的哪一个版本在本文数据集上有更好的性能，使用 YOLOv5s 进行对比试验，根据实验结果最后确定使用性能更好的 WIoUv3，对比实验结果如表 1 所示。

表 1　不同版本 WIoU 对比试验

Table 1　Comparison test of different versions of WIoU

(%)

损失函数	Precision		P	Recall		R/%	mAP/%
	OK	NG		OK	NG		
CIoU	94.6	95.3	95	93.6	91.3	92.5	96.7
WIoUv1	94.9	96.5	95.7	93.3	90.7	92	96.8
WIoUv2	96	95.5	95.8	92.8	93	92.9	96.5
WIoUv3	95.3	96.8	96.1	92.3	90.8	91.6	97.1

图 6 所示为训练过程中边界框损失值变化图，结合表 1 中的对比实验结果可知，加入 WIoUv3 的效果最好，与原始的 YOLOv5s 相比精确率提升了 1.1%，mAP 提升了 0.4%。

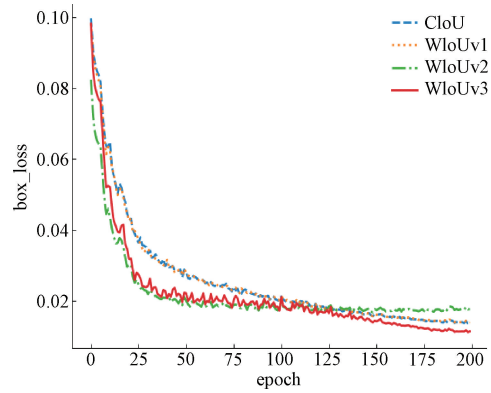

图 6　边界框损失值变化图

Fig. 6　Changes in bounding box loss values

为了探讨 RepVGG 模块、CA 注意力机制和 WIoUv3 定位损失函数 3 个改进对目标检测性能的影响，以 YOLOv5s 为基础模型，在自制的 PDC 钻头数据集上进行消融实验。首先，在 YOLOv5s 网络的 C3 模块的残差中添加 CA 注意力机制；然后，使用 RepVGG 结构替换主干网络的卷积 CBL 和 C3 模块中卷积核大小为 3×3 的卷积；最后，改进边界框损失函数为 WIoUv3，记录实验结果，实验结果如表 2 所示。

表 2　消融实验结果

Table 2　Results of ablation experiment

模型	Precision/%		P/%	Recall/%		R/%	mAP/%	模型大小/M
	OK	NG		OK	NG			
YOLOv5s	94.6	95.3	95	93.6	91.3	92.5	96.7	13.7
YOLOv5s+CA	95.4	95.4	95.4	93.6	93.4	93.5	97.4	13.8
YOLOv5s+CA+RepVGG	96.6	97	96.8	93.2	93.4	93.3	97.8	14.4
YOLOv5s+CA+RepVGG+WIoUv3	96.1	97.9	97	94.4	92.3	93.4	98	14.4

由表 2 分析实验结果可知，原始的 YOLOv5s 网络模型在 PDC 钻头数据集上的 mAP 为 96.7%；加入 CA 注意力机制之后，精确率和召回率分别增加了 0.4%和 1%，平均精度均值增加 0.7%，对缺损复合片的查全率提升了

2.1%,验证了 CA 注意力机制对网络性能提升的有效性;继续加入 RepVGG 模块后,精确率上升至 96.8%,mAP 上升至 97.8%;将损失函数改进为 WIoUv3 后,精确率上升到 97%,mAP 上升至 98%,对缺损复合片检测的精确率提升了 2.6%,达到 97.9%。实验结果表明加入 CA 注意力机制、RepVGG 模块和 WIoUv3 损失函数后,精确率、召回率和平均精度均值都有所提升,有效地提升了 YOLOv5s 对 PDC 钻头复合片缺损检测的准确率,减少了对 PDC 钻头复合片的误检。

如图 7 所示为检测效果对比图,对比图 7(b)和(c)中的效果图,图 7(b)中的两张图存在将未缺损(OK)复合片识别为缺损(NG)或者缺损(NG)复合片识别为未缺损(OK)的情况,而图 7(c)中的两张检测图上均能够被正确识别。

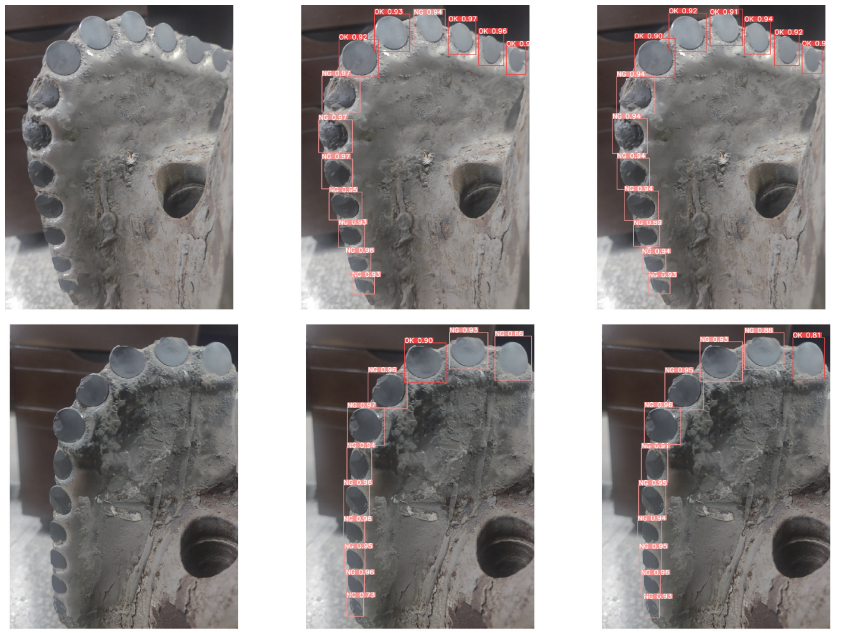

(a) 原图
(a) Original image

(b) YOLOv5s检测效果
(b) YOLOv5s detection effect

(c) 改进算法检测效果
(c) Improved algorithm detection effect

图 7　检测效果对比

Fig. 7　Comparison of detection effects

2.5　与其他算法比较

为了验证本文所改进的 YOLOv5s 算法的综合性能,选择两阶段目标检测算法 Faster R-CNN,单阶段算法 YOLOv3、YOLOv4 和 YOLOv7 做对比实验。选择相同的实验参数,在同样的 PDC 钻头数据集下对这几种目标检测算法进行训练,得到了每种算法的召回率、精确率、mAP、IoU、检测速度和模型大小对比如表 3 和图 8 所示。

由实验结果可知,本文所改进的 YOLOv5s 模型与几种主流的目标检测算法相比在检测精度上有优势。相比两阶段的 Faster R-CNN,精确率和召回率分别提升了 26.7%和 3.9%,同时显著提升了检测速度。与 YOLOv3 和 YOLOv4 相比,改进后算法的精确率分别提升了 2%和 13.9%,同时 YOLOv3 和 YOLOv4 模型体积和计算量大。与 YOLOv7 相比,改进后的 YOLOv5s 算法的 mAP 降低了 0.4%,召回率 Recall 降低了 0.9%,但是改进的 YOLOv5s 的模型体积和计算量较小。改进的 YOLOv5s 模型交并比达到了 92.1%,与原模型相比精确率、召回率和 mAP 均有所提升。

表 3　各算法检测性能对比

Table 3　Comparison of detection performance of various algorithms

模型	Precision/%	Recall/%	mAP/%	IoU/%	计算量/GFLOPS	Speed/fps	模型大小/M
Faster R-CNN	70.3	89.5	87.6	79.9	369.7	25	108.0
YOLOv3	95.0	92.5	96.4	91.8	155.0	69	117.0
YOLOv4	83.1	95.7	96.9	92.7	142.0	43	244.0
YOLOv5s	95.0	92.5	96.7	91.3	16.0	98	13.7
YOLOv7	96.9	94.3	98.4	94.0	105.1	84	71.3
Improved YOLOv5s	97.0	93.4	98.0	92.1	16.9	67	14.4

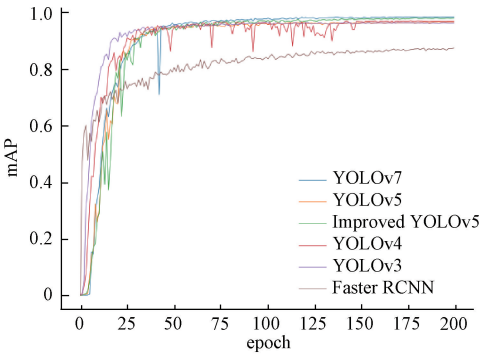

(a) mAP对比图
(a) Comparison chart of mAP

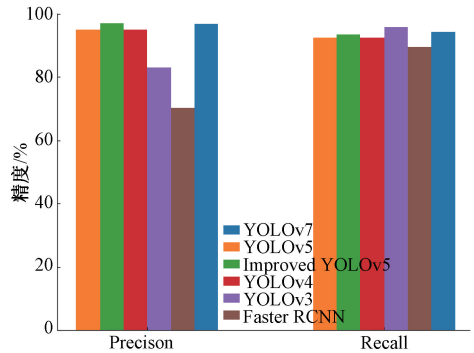

(b) Precison和Recall对比图
(b) Comparison chart of Precision and Recall

图 8　评价指标对比

Fig. 8　Evaluation index comparison chart

3　结　论

为了实现对 PDC 钻头复合片的缺损检测,提升目标检测的准确性,本文在 YOLOv5s 目标检测算法的基础上提出了一种 PDC 钻头复合片缺损检测模型。在 C3 模块中融入坐标注意力机制,将位置信息融入通道注意力机制中;主干网络融合 RepVGG 结构重参数化模块,增强对 PDC 钻头复合片的特征提取能力;改进边界框损失函数 CIoU 为 WIoUv3,在训练的每一时刻都提供合适的梯度增益分配策略,降低高质量锚框的竞争力和低质量锚框的影响,使模型聚焦于普通质量的锚框,提升模型的性能。实验结果表明,在自制的 PDC 钻头数据集上,与原来的 YOLOv5s 网络相比,改进后的 YOLOv5s 网络在没有显著增加计算量的情况下,mAP 提升了 1.3%,达到了 98%,基本满足对 PDC 钻头复合片的缺损识别要求。

参考文献

[1] 杨丽,陈康民. PDC 钻头的应用现状与发展前景[J]. 石油机械,2007(12):70-72.
YANG L, CHEN K M. Application status and development prospect of PDC bit [J]. Petroleum Machinery, 2007(12):70-72.

[2] 陈楠. 浅析钢体 PDC 钻头修复与应用[J]. 西部探矿工程,2022, 34(9):112-114.
CHEN N. Analysis on the repair and application of steel body PDC bit [J]. Western Exploration Engineering, 2022, 34(9):112-114.

[3] 李柯泉,陈燕,刘佳晨,等. 基于深度学习的目标检测算法综述[J]. 计算机工程,2022, 48(7):1-12.
LI K Q, CHEN Y, LIU J CH, et al. A review of object detection algorithms based on deep learning [J]. Computer Engineering,2022, 48(7):1-12.

[4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Conference on Computer Vision& Pattern Recognition. IEEE Computer Society, Columbus, OH, USA,2014: 580-587.

[5] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems,2015, 28.

[6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Proceedings of European Conference on Computer Vision. Amsterdam, Netherlands, Oct 10-16,2016: 21-37.

[7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA, June 26-July 1,2016: 779-788.

[8] REDMON J, FARHADI A. YOLO9000: Cetter, faster, stronger[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Hawaii, USA, July 21-26, 2017: 7263-7271.

[9] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. arXiv preprint arXiv: 1804.02767, 2018.

[10] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934, 2020.

[11] 马燕婷,赵红东,阎超,等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报,2022, 36(8):150-157.
MA Y T, ZHAO H D, YAN CH, et al. Improved YOLOv5 network strip surface defect detection method[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8):150-157.

[12] 吴一全,赵朗月,苑玉彬,等. 基于机器视觉的 PCB 缺陷检测算法研究现状及展望[J]. 仪器仪表学报, 2022, 43(8):1-17.

WU Y Q, ZHAO L Y, YUAN Y B, et al. Research status and prospect of PCB defect detection algorithm based on machine vision [J]. Chinese Journal of Scientific Instrumentat, 2022, 43(8): 1-17.

[13] 马进,王超. 基于改进 YOLOv4-tiny 的印刷电路板缺陷检测研究[J]. 电子测量技术,2022,45(23):99-106.
MA J, WANG CH. Research on printed circuit board defect detection based on improved YOLOv4-tiny [J]. Electronic Measurement Technology, 2022, 45(23): 99-106.

[14] 单明陶,高玮玮,杨亦乐,等. 基于改进 Faster R-CNN 的刹车零件缺陷检测算法[J]. 国外电子测量技术,2022,41(4):22-28.
SHAN M T, GAO W W, YANG Y L, et al. Brake part defect detection algorithm based on improved faster R-CNN [J]. Foreign Electronic Measurement Technology, 2022,41(4):22-28.

[15] LU B, XU T, HUANG Y, et al. Applications of computer vision and deep learning in visual features extraction of drill bits [C]. International Petroleum Technology Conference. OnePetro, 2022.

[16] ASHOK P, VASHISHT P, KONG H, et al. Drill bit damage assessment using image analysis and deep learning as an alternative to traditional IADC dull grading[C]. SPE Annual Technical Conference and Exhibition. OnePetro, 2020.

[17] ASHOK P, CHU J, WITT-DOERRING Y, et al. Drill bit failure forensics using 2D bit images captured at the rig site[C]. SPE/IADC International Drilling Conference and Exhibition. OnePetro, 2021.

[18] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. arXiv preprint arXiv: 2207.02696, 2022.

[19] JOCHER G. YOLOv5 release v6.1. https://github.com/ultralytics/YOLOv5/releases/tag/v6.1,2022.

[20] DING X, ZHANG X, MA N, et al. Repvgg: Making vgg-style convnets great again [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13733-13742.

[21] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,2021: 13713-13722.

[22] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. arXiv preprint arXiv:2301.10051, 2023.

作者简介

代啟亮,2021 年于南阳师范学院获得学士学位,现为武汉科技大学硕士研究生,主要研究方向为机器视觉、深度学习。
E-mail: 1971127195@qq.com

Dai Qiliang received the B. Sc. degree from Nanyang Normal University in 2021. He is now a M. Sc. candidate at Wuhan University of Science and Technology. His main research directions are machine vision and deep learning.

熊凌(通信作者),2010 年于华中科技大学获得博士学位,现为武汉科技大学信息科学与工程学院教授,主要研究方向为模式识别与智能系统。
E-mail: xiongling@wust.edu.cn

Xiong Ling (Corresponding author) received the Ph. D. from Huazhong University of Science and Technology in 2010. She is now a professor at the School of Information Science and Engineering, Wuhan University of Science and Technology. Her main research interests include pattern recognition and intelligent systems.