

基于改进 YOLOv8 的燃气轮机涡轮叶片 表面缺陷检测算法

刘忠强,王 岩,郝晟功,杨岸宁

(中国船舶集团有限公司第七〇三研究所,黑龙江 哈尔滨 150078)

摘 要:针对采用工业内窥镜对燃气轮机涡轮叶片进行表面缺陷检测效率较低的问题,提出一种基于改进 YOLOv8 模型的涡轮叶片表面缺陷检测算法。在主干网络中引入可变形卷积,设计了 C2f_DCNv3 模块,以提高模型的特征提取能力。加入 Shuffle Attention 注意力模块,进一步提升模型检测精度。在特征融合部分设计了 GSCSP 模块,降低模型的计算量并提高对小目标的检测能力。建立了涡轮叶片表面缺陷数据集,用于模型的训练与测试。仿真实验结果表明:改进后的模型对缺陷检测的平均精度均值达到 92.3%,比 YOLOv8 原始模型提升了 2.1%,且参数数量和计算量分别下降了 13% 和 17%;与其他算法相比,本研究算法的检测效果更好,更适用于对涡轮叶片表面缺陷的检测。

关 键 词:缺陷检测;YOLOv8;注意力机制;可变形卷积;特征融合

中图分类号:TK478

文献标识码:A

DOI:10.16146/j.cnki.rndlgc.2024.12.019

[引用本文格式]刘忠强,王 岩,郝晟功,等.基于改进 YOLOv8 的燃气轮机涡轮叶片表面缺陷检测算法[J].热能动力工程,2024,39(12):168-175. LIU Zhongqiang, WANG Yan, HAO Shenggong, et al. Gas turbine blade surface defect detection algorithm based on improved YOLOv8[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(12):168-175.

Gas Turbine Blade Surface Defect Detection Algorithm based on Improved YOLOv8

LIU Zhongqiang, WANG Yan, HAO Shenggong, YANG Anning

(No. 703 Research Institute of CSSC, Harbin, China, Post Code: 150078)

Abstract: In order to solve the issue of low efficiency in surface defect detection of gas turbine blades by using industrial endoscope, an algorithm based on improved YOLOv8 model was proposed for turbine blade surface defect detection. The deformable convolutions were introduced into the backbone network, and the C2f_DCNv3 module was designed to enhance the model's feature extraction capability. The Shuffle Attention module was added to further improve the detection accuracy of the model. The GSCSP module was designed in the feature fusion part to reduce the model's computation and enhance its detection capability for small targets. A dataset for turbine blade surface defects was established for model training and testing. Simulation experimental results show that the improved model achieves a mean value of average precision of 92.3% for defect detection, which is a 2.1% improvement over the original YOLOv8 model. Moreover, the number of parameters and computation are reduced by 13% and 17% respectively. In comparison with other algorithms, the proposed algorithm in this study achieves better detection results and is more suitable for detecting surface defects on turbine blades.

Key words: defect detection, YOLOv8, attention mechanism, deformable convolution, feature fusion

引 言

涡轮叶片是燃气轮机的重要组成部件,其工作环境中存在高温、高压、高速的燃气,长时间运行后可能会造成涡轮叶片损伤,形成裂纹、划痕、凹坑及锈蚀等表面缺陷,及时发现上述缺陷对于保证燃气轮机可靠运行具有重要意义^[1]。目前,对于燃气轮机内部涡轮叶片的检测主要依赖工业内窥镜,由现场技术人员将工业内窥镜的镜头从小孔伸入到燃气轮机内部特定区域,从传输至屏幕上的图像来观察叶片表面是否存在缺陷。此种方法对技术人员的经验和水平有较高要求,且检测耗时较长,效率不高^[2]。

近年来,基于深度学习的目标检测算法发展迅速,将其应用于叶片表面缺陷检测可以提高检测效率和准确率。按照检测过程可将当前目标检测算法分为两阶段检测算法和单阶段检测算法两大类。两阶段检测算法先在输入图像上获取候选区域,再在候选区域上做分类和边框回归,得到检测结果。具有代表性的两阶段检测算法包括 Faster RCNN^[3]、Cascade RCNN^[4]等,文献[5-6]采用 Faster RCNN 算法对航空发动机叶片表面缺陷进行检测,取得了

较高的检测准确率。但两阶段检测算法在生成候选区域时计算开销较大,导致检测速度较慢,难以满足实时检测的需求。单阶段检测算法省略了获取候选区域的步骤,只需一次提取特征即可直接生成检测物的类别概率及位置坐标,检测速度更快。典型的单阶段检测算法包括 YOLO 系列算法^[7-9]、单次多框检测器(Single Shot Multibox Detector, SSD)^[10]等。文献[11-12]采用改进的 YOLOv4 和 YOLOv5 算法对发动机叶片表面缺陷进行检测,准确率相比原算法均有所提升。

YOLOv8 算法是在 YOLO 系列算法的基础上通过改进和引进新的模块而得到的新算法,在检测精度和速率上均有提升。针对燃气轮机涡轮叶片表面缺陷检测任务的特点,本文对 YOLOv8 算法做了进一步改进,以提升对叶片表面缺陷检测的准确率和效率,并自建了燃气轮机涡轮叶片表面缺陷数据集,用于模型的训练和性能验证。

1 改进的 YOLOv8 检测算法

1.1 网络结构

改进后的 YOLOv8 网络结构如图 1 所示。




图 1 改进后的 YOLOv8 网络结构

Fig. 1 Network structure of improved YOLOv8

YOLOv8 的网络结构包括主干网络、颈部网络和检测头等几个主要组成部分。对于输入模型的待检测图像,由主干网络提取图像特征,颈部网络可在 3 个不同尺度上对主干网络提取的特征进行融合,从而提高对不同尺寸目标的检测效果,再将融合后的特征分别输入 3 个检测头,获得目标分类和定位的预测结果。

YOLOv8 在主干网络和颈部网络中采用 C2f 模块替换了之前模型中使用的 C3 模块,相比 C3 模块,C2f 加入了分割操作并在模块内部的瓶颈层间增加了更多的跨层连接,使其获得更丰富的梯度流,从而提高特征提取的能力。在检测输出部分采用了解耦的检测头,按照分类和回归两个分支分别预测结果,并且不再基于锚框进行预测,而是采用无锚框的方法。

针对燃气轮机涡轮叶片表面缺陷的特点,为了进一步提高检测的准确率和效率,对 YOLOv8 的网络结构进行了改进。为了提升主干网络提取叶片表面缺陷特征的能力,引入可变形卷积算子 (Deformable Convolutional Networks version 3, DCNv3)^[13],将 C2f 模块替换为 C2f_DCNv3。在主干网络后添加注意力机制,增强对小尺度缺陷目标的检测能力。在颈部网络设计了更轻量型的卷积模块,替换原有网络结构,在提高检测效率的同时使检测精度进一步提升。

1.2 主干网络的改进

传统卷积神经网络通常采用 3×3 的规则卷积核,但对于较深层的网络结构,其获取的有效感受野较小,难以获得长程依赖关系。为解决此问题,文献[14]提出一种可变形卷积 DCNv2,在规则卷积核的基础上增加 1 组偏移量,形成可变形的卷积核,增强了对同一物体及其不同形态的检测能力。但 DCNv2 中的不同神经元具有与一般卷积相似的独立线性投影权重,使其参数和内存复杂度与采样点数成线性关系,影响了模型的计算效率。DCNv3 在 DCNv2 基础上进行了改进,将原始的卷积权重分解为逐通道卷积和逐点卷积两部分,并引入分组机制,其卷积过程为:

$$y(p_0) = \sum_{g=1}^G \sum_{k=1}^K w_g m_{gk} x_g(p_0 + p_k + \Delta p_{gk}) \quad (1)$$

式中: p_0 —当前像素点; $y(p_0)$ —卷积输出值; G —空

间聚合分组的数量; K —采样点的总数量; w_g —第 g 组中与位置无关的投影权重; m_{gk} —第 g 组第 k 个采样点的调制标量,其通过 softmax 函数进行归一化; x_g —第 g 组经过切片后的输入特征图; p_k —预定义网络采样的第 k 个位置; Δp_{gk} —在第 g 组中与 p_k 相对应的偏移量。

DCNv3 继承了 DCNv2 在规则卷积的基础上引入长程依赖关系和自适应空间聚合的优点,并且由于在卷积神经元之间共享权重,使其计算量大幅下降,提高了效率。DCNv3 引入的分组机制与自适应空间聚合相结合,使网络能够学习到更丰富的特征信息,提高了模型的特征提取能力。

为提升模型对不同形状涡轮叶片表面缺陷的检测效果并提高检测效率,在 YOLOv8 主干网络的 C2f 模块中采用 DCNv3 代替了传统卷积,记为 C2f_DCNv3 模块,其结构如图 2 所示。




图 2 C2f_DCNv3 模块结构

Fig. 2 The structure of C2f_DCNv3 module

1.3 注意力机制

注意力机制被广泛使用在神经网络中,以提升网络在图像分类、目标检测等视觉任务方面的表现性能。常用的注意力机制包括通道注意力和空间注意力两类,分别用于获得通道依赖关系和捕获像素级的成对关系。卷积块注意力模块 (Convolutional Block Attention Module, CBAM)^[15]、全局上下文网络 (Global Context Network, GCNet)^[16]和高效通道注意力模块 (Efficient Channel Attention, ECA)^[17]等方法将空间注意力和通道注意力进行了整合,使检测效果取得了明显提升。但这些方法未充分利用空间注意力和通道注意力之间的相关性,并且增加了较大的计算负担,降低了检测效率。

为了能够在进一步提升涡轮叶片表面缺陷检测效果的同时不显著增加计算开销,对比分析了几种注意力模块后,在 YOLOv8 的主干网络中加入了轻量化的通道混洗注意力模块 (Shuffle Attention, SA)^[18],其结构如图 3 所示。




图 3 通道混洗注意力模块结构

Fig. 3 The structure of shuffle attention module in passage

该模块首先将输入特征图 x 按通道维度划分为 g 组,然后将每个子特征 x_k 再分割为 x_{k1} 和 x_{k2} 两个分支,分别通过通道注意力和空间注意力模块获得特定的语义信息。

对于 x_{k1} 分支,可通过全局平均池化来嵌入全局信息,并通过空间维度上的收缩来得到通道统计量 s_1 ,其计算过程为:

$$s_1 = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{k1}(i, j) \quad (2)$$

式中: H 和 W —输入特征图的高度和宽度; $x_{k1}(i, j)$ — x_{k1} 在 (i, j) 处的元素值。

再经过 sigmoid 函数 $\sigma(\cdot)$ 获得通道注意力的最终输出 x'_{k1} :

$$x'_{k1} = \sigma(F_c(s_1)) \cdot x_{k1} = \sigma(w_1 s_1 + b_1) \cdot x_{k1} \quad (3)$$

式中: $F_c(s_1)$ —对 s_1 进行缩放和平移的函数, $F_c(s_1) =$

$w_1 s_1 + b_1$; w_1, b_1 —用来缩放和平移 s_1 的具有相同维度的参数。

对于 x_{k2} 分支,首先通过组归一化 (Group Normalization, GN) 来获得空间统计量 s_2 ,然后再经过式 (3) 中的 $F_c(\cdot)$ 函数增强特征表示,并同样经过 sigmoid 函数来获得空间注意力的输出 x'_{k2} :

$$x'_{k2} = \sigma(F_c(s_2)) \cdot x_{k2} = \sigma(w_2 \cdot s_2 + b_2) \cdot x_{k2} \quad (4)$$

式中: w_2, b_2 —与 s_2 维度相同的参数。

最后,将两个分支的输出特征进行拼接,使其通道数与输入特征相同,并将 g 组子特征进行聚合,再经过通道混洗,得到最终的输出结果。

1.4 特征融合部分的改进

YOLOv8 的颈部网络部分仍延续了前一系列算法的结构,将特征金字塔网络 (Feature Pyramid Network, FPN)^[19] 与路径聚合网络 (Path Aggregation Network, PAN)^[20] 相结合,分别将主干网络提取的 3 个不同层级的特征送入颈部网络中。通过上采样、拼接及下采样等操作,从自底向上和自顶向下两条路径来融合 3 种不同尺度的特征,使网络能够同时获取低层的细节特征和高层的语义特征,从而提高网络模型的鲁棒性,使其能够适应针对不同尺度目标的检测任务。

对燃气轮机涡轮叶片表面缺陷进行检测时,由于采用的输入是工业内窥镜探头回传的实时视频图像,且转子叶片在不断转动,对检测的实时性要求较高。为提高网络的检测效率,在颈部网络引入了 1 种新的轻量型卷积 GSCnv^[21],并设计了 GSCSP 模块,代替 YOLOv8 颈部网络中原来的 C2f 模块。

GSCnv、GS Bottleneck 及 GSCSP 的结构如图 4 所示。GSCnv 在标准卷积 Conv 层的基础上加入了深度可分离卷积 (Depth-wise Separable Convolution, DW Conv),并通过残差连接将 Conv 层与 DW Conv 层的输出进行拼接,再由通道混洗算子将 Conv 层的通道信息均匀地混合到 DW Conv 层的输出中,使局部特征信息得以在不同通道间交换,提高了模型的特征提取能力。用 GSCnv 替换瓶颈层中的 Conv 层后即得到 GS Bottleneck 结构,由 GS Bottleneck 堆叠并加入跨越连接可构成 GSCSP 模块。




图 4 GSConv,GS Bottleneck 及 GSCSP 结构图

Fig.4 Structure diagram of GSConv, GS Bottleneck and GSCSP

本文在 YOLOv8 的颈部网络采用 GSConv 和 GSCSP 分别替换了原来的 Conv 和 C2f 模块,可在减少网络计算开销的同时,提高检测精度。

2 仿真实验结果及分析

2.1 仿真实验数据集

为验证算法的有效性,需要燃气轮机涡轮叶片表面缺陷数据集来对模型进行训练和测试。当前尚未有公开的相关数据集信息,从某型燃气轮机内窥镜检查的视频及图像记录中筛选出包含裂纹 (break)、划痕 (scratch)、凹坑 (pit) 和锈斑 (rust) 4 类涡轮叶片表面缺陷的图片作为数据样本来验证算法的有效性,样本如图 5 所示。为扩充数据集样本的数量,以提高模型的鲁棒性,对采集的样本进行了水平翻转、角度旋转、调节亮度和加入噪声 (椒盐噪声、高斯噪声) 等数据增强方式,将缺陷样本量扩充至 5 726。




图 5 涡轮叶片表面缺陷样本示例

Fig.5 The samples of turbine blade surface defects

将扩充后的样本按照 6:2:2 的比例随机划分为训练集、验证集和测试集,包含的 4 类缺陷目标数量如表 1 所示。可以看到,其中裂纹和划痕的数量较

多,凹坑和锈斑的数量较少。

表 1 数据集中各类缺陷的目标数量

Tab.1 Target number of various defects in dataset

缺陷类型	缺陷目标数量			总计
	训练集	验证集	测试集	
裂纹	2 342	728	695	3 765
划痕	2 246	713	741	3 700
凹坑	1 437	463	476	2 376
锈斑	1 168	379	384	1 931

2.2 实验配置

实验在深度学习平台服务器上进行,操作系统为 Ubuntu 20.04,采用 pytorch1.10.0 深度学习框架,所用显卡为 NVIDIA GeForce RTX 4090,24GB 显存,CUDA 版本为 11.3。

训练时以 YOLOv8n 作为基础模型,输入图像尺寸设为 640×640,批量大小设为 32,采用 SGD 优化器,每个模型训练 150 轮,其余超参数采用默认值。

2.3 评价指标

本文使用的评价指标包括平均精度均值 (mean Average Precision,mAP)、参数量、10 亿次浮点运算数 (Giga Floating point Operations,GFLOPs) 等。其中 mAP 值用于衡量模型检测结果的准确性,由各类别的平均精度 (Average Precision,AP) 取平均值计算得到,mAP 值越高说明模型的检测效果越好,本文中 mAP 取交并阈值为 0.5 时的计算值。参数量和 GFLOPs 用于评价模型的复杂度及计算量,其中参数量通常以 M 为计量单位,1 M 即 100 万个参数。这两个指标越高,代表模型越复杂,计算开销越大。

2.4 消融实验

为验证针对 YOLOv8 模型进行改进的有效性,设计了消融实验。分别在 YOLOv8n 模型的基础上对网络结构进行了改进,包括在主干网络中采用 DCNv3 代替 C2f 模块中的标准卷积、在主干网络之后加入 SA 注意力模块,以及在特征融合部分将 Conv 层和 C2f 模块分别替换为 GSConv 和 GSCSP。分别在本文实验数据集上对原模型及各改进后的模型进行了训练和测试,实验结果如表 2 所示。

表 2 消融实验结果

Tab. 2 The results of ablation experiment

改进方法			mAP _{0.5} /	参数量/	计算量/
DCNv3	SA	GSCSP	%	M	GFLOPs
—	—	—	90.2	3.0	8.2
✓	—	—	91.6	2.8	7.7
—	✓	—	91.3	3.0	8.2
—	—	✓	90.7	2.8	7.4
✓	✓	—	91.9	2.8	7.7
—	✓	✓	91.8	2.8	7.4
✓	✓	✓	92.3	2.6	6.8

注:“—”表示不采用。

表 2 中的实验结果表明,在主干网络中采用可变形卷积 DCNv3 后,mAP 值提升了 1.4%,且计算量下降了 0.5 GFLOPs;加入 SA 注意力模块后,可在不增加参数量的情况下将检测的 mAP 值提升 1.1%;在特征融合部分引入 GSCSP 模块后,可使模型计算量减少 0.8 GFLOPs,并使 mAP 值提升 0.5%。将 3 种改进方式进行融合后,相比原始的 YOLOv8n 模型,改进后模型的 mAP 值达到 92.3%,提升了 2.1%;参数量和计算量分别降低至 2.6 M 和 6.8 GFLOPs,减少了 13% 和 17%。说明改进后的模型提升了检测精度,同时有效降低了计算开销,提高了检测的效率。

此外,为研究各改进方法对叶片缺陷检测效果的影响,分别测试了 YOLOv8 原模型及加入各改进方法后对 4 种叶片表面缺陷的检测精度,结果如表 3 所示。

表 3 各类缺陷的检测结果

Tab. 3 Detection results of each defect

模 型	mAP _{0.5} /%			
	裂纹	划痕	凹坑	锈斑
YOLOv8n	93.1	89.5	87.8	90.4
YOLOv8n + DCNv3	94.2	91.1	89.6	91.5
YOLOv8n + SA	93.9	90.8	89.5	91.0
YOLOv8n + GSCSP	93.2	89.9	89.0	90.7
YOLOv8n + DCNv3 + SA + GSCSP	94.6	91.7	90.8	92.1

可以看出,各模型对于裂纹缺陷的检测效果最好,而对于凹坑的检测精度相对较低,这是由各样本的训练数量及样本的尺度不同导致的,其中凹坑和

划痕这两类缺陷样本中的小目标数量较多,增加了检测的难度。而在主干网络中加入 DCNv3 以及在其后加入 SA 注意力模块后,均可提升对于各类缺陷的检测精度,说明这两种改进方式能够有效提升模型的特征提取能力,获取更丰富的特征信息,从而使检测精度获得提升。在特征融合部分引入 GSConv 和 GSCSP 模块后,降低了模型的参数量,同时检测精度相比原模型略有提升,尤其对凹坑缺陷的检测效果较好,可见对特征融合部分的改进能够有效提升模型对小目标的检测精度。融合 3 种改进方法后,对于 4 类缺陷的检测精度相比原模型分别提升了 1.5%、2.2%、3.0% 和 1.7%。

2.5 对比实验

为进一步验证本文改进模型的检测性能,将改进后的 YOLOv8n 模型与其他几种轻量级的目标检测模型在本文自建实验数据集上进行了对比实验,包括 EfficientDet-D1^[22]、YOLOv5-s、YOLOX-s 和 YOLOv7-tiny,这些模型均具有轻量级的网络结构,适用于对实时性要求较高的检测任务。所有模型训练相同轮数,实验结果如表 4 所示。

表 4 不同模型的检测性能对比

Tab. 4 Comparison of detection performance of different models

模 型	mAP _{0.5} /	参数量/	计算量/
	%	M	GFLOPs
EfficientDet-D1	86.7	6.5	12.1
YOLOv5-s	87.2	7.2	16.5
YOLOX-s	89.3	9.0	26.8
YOLOv7-tiny	89.1	6.2	13.8
YOLOv8n + DCNv3 + SA + GSCSP	92.3	2.6	6.8

实验结果表明,本文改进后的 YOLOv8 模型相比其他轻量级检测模型具有更高的检测效率,参数量和计算量分别比 YOLOv7-tiny 降低了 58.1% 和 50.7%,且具有最高的 mAP 值。

为进一步比较不同模型的检测效果,将各模型的缺陷检测结果可视化,如图 6 所示。图中从左至右每列图片分别对应裂纹、凹坑、锈斑、划痕 4 种缺陷的检测结果。从不同模型的检测结果对比可知,EfficientDet-D1 对裂纹存在漏检,对锈斑存在误检,YOLOv5-s 对裂纹和锈斑这两种缺陷均存在漏检,而

本文模型对 4 类缺陷均能准确检出,减少了漏检和误检现象。此外,从被检出的缺陷目标来看,本文模型的检测结果相比其他模型具有更高的目标分类置

信度,且检测框的定位更为准确,尤其针对小目标缺陷的检测效果更好,更适合用于对燃气轮机涡轮叶片表面缺陷进行实时检测。




图 6 不同模型可视化检测结果对比

Fig. 6 Comparison of visualization detection results for different models

3 结 论

针对目前燃气轮机涡轮叶片表面缺陷检测方法效率不高的问题,在 YOLOv8 模型的基础上进行改进,提出一种叶片表面缺陷检测算法,并建立涡轮叶片表面缺陷数据集,用于验证模型的有效性,结论如下:

(1) 在 YOLOv8 的主干网络中引入可变形卷积,将 C2f 模块中的标准卷积替换为 DCNv3,提高了

模型对于不同形状缺陷的检测能力;加入 SA 注意力机制模块,使模型更关注关键区域信息,可在不增加计算量的情况下提升模型检测性能;设计了 GSCSP 结构,用于特征融合部分的改进,大幅降低了模型的计算量,并提升了对于小目标缺陷的检测能力。

(2) 改进后的模型参数量为 2.6 M,计算量为 6.8 GFLOPs,相比原模型分别降低了 13% 和 17%。实验表明,改进模型对于涡轮叶片表面缺陷检测的 mAP 值达到 92.3%,比原模型提高了 2.1%,验证

了改进方法对于提高检测精度与效率的有效性。

(3) 将本文算法与其他算法进行了对比实验,结果表明,本文算法具有更好的检测效果,相比其他算法减少了漏检误检现象,并且检测效率更高,适合用于对燃气轮机涡轮叶片表面缺陷的实时检测。

参考文献:

[1] 孙远伟. 某燃气轮机低压涡轮叶片断裂故障分析[J]. 燃气轮机技术,2021,34(3):57-62.
SUN Yuanwei. Failure analysis of low pressure turbine blade fracture of a gas turbine[J]. Gas Turbine Technology,2021,34(3):57-62.

[2] 李彬,汪诚,吴静,等. 改进 YOLOv4 算法的航空发动机部件表面缺陷检测[J]. 激光与光电子学进展,2021,58(14):414-423.
LI Bin,WANG CHENG,WU Jing,et al. Surface defect detection of aeroengine components based on improved YOLOv4 algorithm[J]. Laser & Optoelectronics Progress,2021,58(14):414-423.

[3] REN S,HE K,GIRSHICK R,et al. Faster R-CNN:Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2017,39(6):1137-1149.

[4] CAI Z,VASCONCELOS N. Cascade R-CNN:Delving into high quality object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition,Salt Lake City,USA,2018.

[5] JANG J,AN H,LEE J H,et al. Construction of faster R-CNN deep-learning model for surface damage detection of blade systems[J]. Journal of the Korea Institute for Structural Maintenance and Inspection,2019,23(7):80-86.

[6] 李龙浦. 基于孔探数据的航空发动机叶片损伤识别研究[D]. 天津:中国民航大学,2020.
LI Longpu. Research on damage identification of aeroengine blades based on borescope data[D]. Tianjin:Civil Aviation University of China,2020.

[7] REDMON J,DIWALA S,GIRSHICK R,et al. You only look once: Unified, real-time object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,Piscataway,USA,2016.

[8] REDMON J,FARHADI A. YOLOv3: An incremental improvement [C]//IEEE Conference on Computer Vision and Pattern Recognition,Salt Lake City,USA,2018.

[9] BOCHKOVSKIY A,WANG C Y,LIAO H. YOLOv4: Optimal speed and accuracy of object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,Seattle,USA,2020.

[10] LIU W,ANGUELOV D,ERHAN D,et al. SSD:single shot multi-box detector[C]//Proceedings of European Conference on Computer Vision,Berlin,Germany,2016.

[11] 蔡舒妤,闫子砚. 基于改进 YOLOv4 的航空发动机小目标损伤检测研究[J]. 航空动力学报,2023,38(2):445-452.
CAI Shuyu,YAN Ziyen. Research on small target damage detection of aero-engine based on improved YOLOv4 [J]. Journal of Aerospace Power,2023,38(2):445-452.

[12] 刘宜轩,程志江,吴动波,等. 基于改进 YOLOv5 的航空发动机叶片表面缺陷检测方法研究[J]. 激光杂志,2023,44(7):57-61.
LIU Yixuan,CHENG Zhijiang,WU Dongbo,et al. Research on surface defect detection method of aero-engine blade based on improved YOLOv5 [J]. Laser Journal,2023,44(7):57-61.

[13] WANG Wenhai,DAI Jifeng,CHEN Zhe,et al. InternImage: Exploring large-scale vision foundation models with deformable convolutions [C]//IEEE Conference on Computer Vision and Pattern Recognition,Vancouver,Canada,2023.

[14] ZHU X,HU H,LIN S,et al. Deformable convnets v2: More deformable,better results [C]//IEEE Conference on Computer Vision and Pattern Recognition,Los Angeles,USA,2019.

[15] WOO S,PARK J,LEE J Y,et al. CBAM: Convolutional block attention module [C]//Proceedings of European Conference on Computer Vision,Munich,Germany,2018.

[16] CAO Y,XU J,LIN S,et al. GCNet: Non-local networks meet squeeze-excitation networks and beyond [C]//IEEE International Conference on Computer Vision,Seoul,Korea,2019.

[17] WANG Q,WU B,ZHU P,et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//IEEE Conference on Computer Vision and Pattern Recognition,Seattle,USA,2020.

[18] ZHANG Q L,YANG Y B. SA-Net: Shuffle attention for deep convolutional neural networks [C]//IEEE International Conference on Acoustics, Speech and Signal Processing, Toronto, Canada,2021.

[19] LIN T Y,DOLLAR P,GIRSHICK R,et al. Feature pyramid networks for object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,Honolulu,USA,2017.

[20] LIU S,QI L,QIN H,et al. Path aggregation network for instance segmentation [C]//IEEE Conference on Computer Vision and Pattern Recognition,Salt Lake City,USA,2018.

[21] LI H,LI J,WEI H B,et al. Slim-neck by GSConv: A better design paradigm of detector architectures for autonomous vehicles [EB/OL]. <https://arxiv.org/abs/2206.02424>,2022-08-17/2024-02-01.

[22] TAN M,PANG R,LE Q. EfficientDet: Scalable and efficient object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition,Seattle,USA,2020.