

DOI:10.16356/j.2097-6771.2026.02.013

BD-YOLO: 一个基于深度学习的航空发动机孔探图像 叶片损伤检测模型

徐超¹, 王文哲¹, 蒋增华², 冷晟¹, 王静秋¹

(1. 南京航空航天大学机电学院, 南京 210016; 2. 中国航发湖南动力机械研究所, 株洲 412002)

摘要: 针对航空发动机孔探图像叶片损伤方向任意且细长损伤易引入过多背景干扰、导致定位精度下降的问题, 本文提出一种基于改进 You only look once version 8 (YOLOv8) 的旋转目标检测模型 BD-YOLO。首先, 设计融合跨阶段连接 (Cross stage partial, CSP) 与密集连接扩张卷积模块 (Receptive field enhancement module, RFEM) 的小目标检测跨阶段局部感受野增强模块 (Cross stage partial receptive field enhancement module, CSRFE), 增强对细小损伤的特征提取能力。其次, 在颈部网络引入改进的双向特征金字塔网络 SimBiFPN, 实现多尺度特征的高效融合。最后, 在头部网络增设专用小目标检测头, 提升小尺寸损伤的识别精度。实验结果表明, BD-YOLO 的平均精度均值 (Mean average precision, mAP)50、mAP75 和 mAP50~95 分别达到 98.6%、84.3% 和 63.3%, 检测速度为 34 帧/s, 能够实现叶片损伤的高精度实时检测。

关键词: 航空发动机; 孔探检测; YOLOv8; 叶片损伤; 目标检测

中图分类号: V263.6; TP391.4 **文献标志码:** A **文章编号:** 1005-2615(2026)02-0372-08

BD-YOLO: A Deep Learning-Based Model for Blade Damage Detection in Aero-engine Borescope Images

XU Chao¹, WANG Wenzhe¹, JIANG Zenghua², LENG Sheng¹, WANG Jingqiu¹

(1. College of Mechanical and Electronic Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China; 2. Hunan Aviation Powerplant Research Institute, Aero Engine Corporation of China, Zhuzhou 412002, China)

Abstract: To address the issues in aero-engine borescope images, such as the arbitrary orientation of blade damage and the tendency for slender damage to introduce excessive background interference, leading to reduced localization accuracy, this paper proposes a rotated object detection model, BD-YOLO, based on an improved You Only Look Once version 8 (YOLOv8). Firstly, a small object detection module named cross stage partial receptive field enhancement module (CSRFE), which integrates the cross stage partial (CSP) and receptive field enhancement module (RFEM), is designed to enhance feature extraction capabilities for minor damages. Secondly, an improved bidirectional feature pyramid network, SimBiFPN, is introduced into the neck network to achieve efficient multi-scale feature fusion. Finally, a dedicated small object detection head is added to the head network to improve the recognition accuracy of small-sized damages. Experimental results demonstrate that BD-YOLO achieves mean average precision (mAP) 50, mAP75, and mAP50-95 values of 98.6%, 84.3%, and 63.3%, respectively, with a detection speed of 34 frames per second, enabling high-precision real-time detection of blade damage.

Key words: aeroengine; borescope detection; you only look once version 8 (YOLOv8); blade damage; object detection

基金项目: 直升机动力学全国重点实验室 2024 年度科技创新基金 (KY-1003-2024-0027)。

收稿日期: 2025-08-19; **修订日期:** 2025-12-19

通信作者: 王静秋, 女, 教授, 博士生导师, E-mail: meejqwang@nuaa.edu.cn。


引用格式: 徐超, 王文哲, 蒋增华, 等. BD-YOLO: 一个基于深度学习的航空发动机孔探图像叶片损伤检测模型[J]. 南京航空航天大学学报(自然科学版), 2026, 58(2): 372-379. XU Chao, WANG Wenzhe, JIANG Zenghua, et al. BD-YOLO: A deep learning-based model for blade damage detection in aero-engine borescope images[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2026, 58(2): 372-379.

随着航空事业的蓬勃发展,飞行安全已成为首要任务。航空发动机长期处在高温、高压、高转速且载荷多变的恶劣工作环境中,其核心构件如发动机叶片,容易产生烧蚀、裂纹、刻口和撕裂等损伤^[1-3],对航空发动机的运行安全构成严重威胁。在航空发动机维护领域,孔探检测是评估内部关键部件(如涡轮叶片、燃烧室)损伤的核心手段。然而,传统人工判读却面临很大挑战:海量孔探图像分析耗时费力;人眼识别易受疲劳、经验差异和主观性影响,难以在复杂背景和微米级损伤(如细微裂纹、烧蚀)中保持高精度和一致性;且经验丰富的专家资源始终稀缺。引入人工智能(特别是深度学习和计算机视觉技术^[4-5])成为解决上述问题的必然选择。

深度学习中的卷积神经网络模型(Convolutional neural network, CNN)可以完成多种图像视觉任务,例如,运用CNN模型进行图像分类和目标检测等。卷积神经网络具有模仿生物视觉的特点,以及优异的特征提取能力,近几年,研究者们也将其引入到孔探检测技术中。旷可嘉^[6]将基于快速区域卷积神经网络(Faster region-based convolutional neural network, Faster R-CNN)和单次多框检测器(Single shot multibox detector, SSD)网络模型应用在孔探图像损伤自动检测,实现了对烧蚀、凹痕、边缘缺口3种损伤的检测。曹斯言等^[7]提出了一种基于自注意力的语义分割模型(Self-attention semantic segmentation, SA-SS)用于检测孔探图像,通过对模型轻量化和引入自注意

力机制,以较低的计算成本实现对叶片损伤的识别与分割。何宇豪等^[8]基于YOLOv5模型提出了针对孔探视频检测的SW-YOLO模型,在YOLOv5模型的基础上,通过引入空间通道注意力机制和优化颈部特征融合结构,提高了模型对叶片损伤的检测精度。黄睿等^[9]为了解决使用相同参数目标检测模型的性能会受损伤位置影响的问题,提出了一种自适应参数的孔探图像损伤检测方法,根据不同损伤区域动态设置网络参数,提高了模型检测的准确率。Shang等^[10]针对由光照不佳和背景噪声导致的损伤信息较弱问题,以Transformer网络和图神经网络(Graph convolutional network, GCN)为子网络构建了全局先验变换器网络(Global prior transformer network, GPTNet)用于孔探叶片损伤检测,其中两个子网络分别提取图像特征和标签特征,并采用融合后的特征进行损伤识别。

如上所述,深度学习已经被引入航空发动机叶片损伤检测中。然而,如图1(a)所示,语义分割模型虽然可以实现像素级的检测,但由于用掩码进行显示,检测复核人员难以分辨是否出现误检,且由于语义模型通常参数量大、复杂度高,难以实现对孔探视频的实时检测。此外,现有孔探图像目标检测模型都是基于水平边界框进行检测,如图1(b)所示,面对实际检测中经常出现的任意方向的叶片和损伤,会引入过多背景,不利于对损伤的定位与参数提取。因此,本文提出了一个基于改进YOLOv8的航空发动机旋转目标叶片损伤检测模型(Blade damage YOLO, BD-YOLO)。



(a) Semantic segmentation results of blade damage

(b) Object detection results based on horizontal bounding boxes

图1 基于经典CNN模型的叶片损伤检测

Fig.1 Detection of leaf damage based on classical CNN

1 基于改进YOLOv8的BD-YOLO检测算法

YOLOv8模型包括主干网络、颈部网络和头部网络3部分。输入图像经过骨干网络CSPDarknet进行特征提取,生成多尺度的特征图。随后,将其传递至颈部路径聚合网络(Path aggregation network, PANet)多尺度特征融合模块,聚合浅层和深层信息。最终,头部网络根据输出的特征,对目

标对象及其边界框进行预测。

YOLOv8-obb通过在YOLOv8头部网络中添加一个角度分支,并将损失函数替换为概率交并比(Probabilistic intersection over union, ProbIoU^[11])来对旋转边界框进行预测。本文提出的BD-YOLO模型以YOLOv8-obb为基础,模型结构如图2所示。

为实现模型对叶片损伤的实时高精度检测,

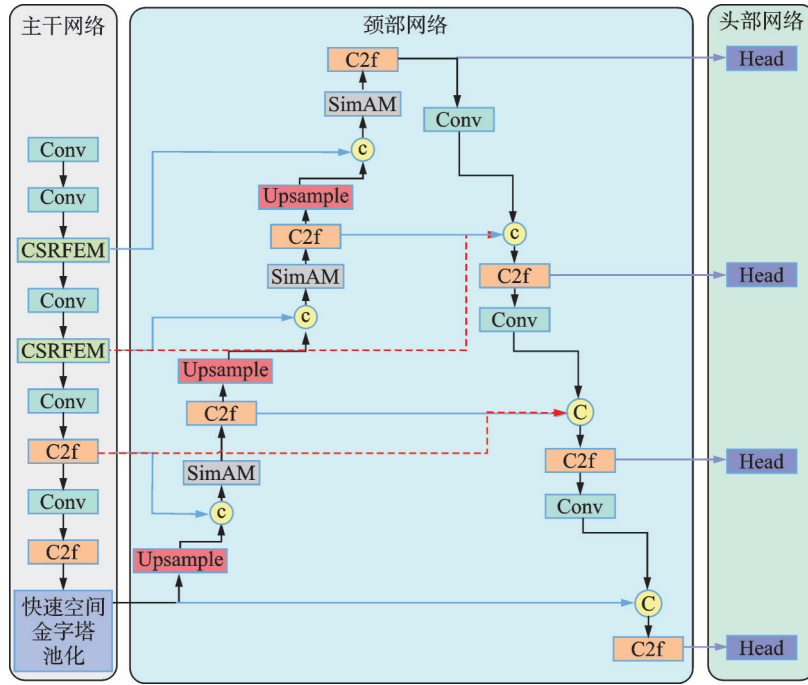


图2 BD-YOLO模型结构

Fig.2 Structure of BD-YOLO model

BD-YOLO做了如下改进:

(1)将主干网络中用于浅层特征提取的C2f模块替换为跨阶段局部感受野增强模块(Cross stage partial receptive field enhancement module, CSRFEF)。该模块通过扩大感受野的方式,增强对小尺寸损伤目标的特征提取能力,提升模型对小损伤和细长损伤的检测效果。

(2)引入双向特征金字塔网络(Bidirectional feature pyramid network, BiFPN)和注意力模块SimAM用于颈部网络的特征融合,使网络输出的孔探图像特征图拥有更丰富的信息。

(3)引入小目标检测头,利用大小为 160×160 的大尺度特征层进行预测,借助高分辨率的大尺度特征层,更好地检测小尺寸损伤。

1.1 小目标检测模块CSRFEF

对于孔探图像中叶片出现的微小损伤,如细小裂纹等,由于特征不够明显,导致模型对小尺寸损伤检测困难。在卷积神经网络中,浅层特征经过的卷积次数少,保留了大量的细节信息,但是表征能力较差。充分利用浅层特征图,可以使模型对小尺寸损伤和细长损伤的检测拥有更高的精度,因此本文结合密集连接扩张卷积模块(Receptive field enhancement module, RFEM)和部分跨阶段连接(Cross stage partial, CSP)结构^[12],设计了小目标检测模块CSRFEF,增加浅层网络的感受野,加强主干网络对浅层特征的提取,有效提高了模型对小尺寸损伤和细长损伤的检测精度。

(1) CSP结构

为了提升卷积神经网络提取特征的能力,最直接的方法之一是增加网络的深度。但只是简单的增加网络深度,会带来网络参数量大、计算量大,难以训练等问题。CSP结构诞生的初衷,就是增加网络的深度,同时保持网络的计算效率。CSP的主要思想是在输入一个用于特征提取的模块(block)之前,将输入分为两个分支,分支1不进行任何操作,分支2通过block进行计算,然后拼接两个分支作为最终的输出。

(2) 密集连接扩张卷积模块

RFEM通过空洞卷积扩大特征图的感受野,并使用多个不同空洞率的空洞卷积来提取多尺度的特征信息并进行融合输出。本文引入的RFEM是一种级联与并联合结合的模块^[13],用更小的空洞率获得了更大的感受野,同时结合了多尺度特征提供更丰富的信息。

将该RFEM引入CSP结构,本文提出如图3所示的CSRFEF小目标检测模块。

1.2 特征融合结构SimBiFPN

在孔探图像中,面对裂纹等细长的损伤,受到卷积核形状和大小的限制,现有模型难以提供准确的位置信息。在卷积神经网络中,深层特征具有高语义的高维信息,能够有效用于叶片损伤的分类和边界框回归。而浅层特征则具有更多细节信息(如边缘、纹理),有利于捕捉损伤的局部特征和空间信息。本文结合加权双向特征金字塔网络BiFPN和




图3 CSRFEM模块
Fig.3 CSRFEM module

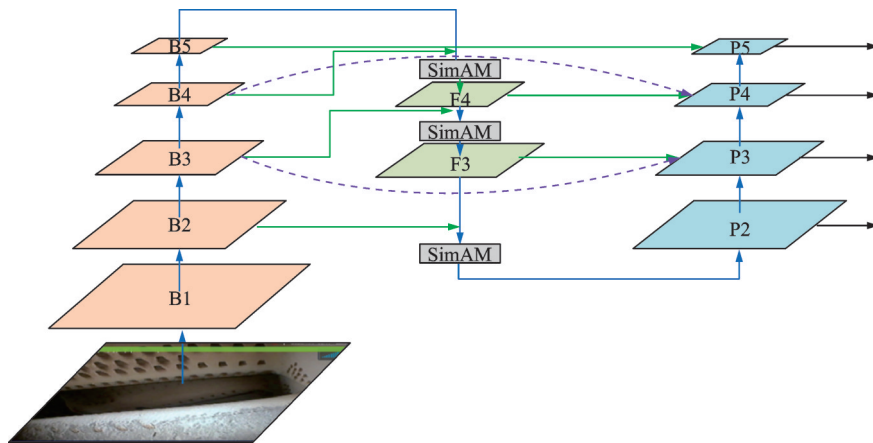


图4 SimBiFPN特征融合结构
Fig.4 Structure of feature fusion in SimBiFPN

SimAM 注意力机制,提出特征融合结构 SimBiFPN,如图 4 所示。在该结构中,自顶向下地在 B5 层~P2 层的特征传递路径中加入了 SimAM 注意力机制,以增强关键特征的代表能力。在自底向上、从特征层 P2~P5 的特征聚合路径中,采用特定的融合策略将不同尺度的特征进行融合,以提升模型对多尺度损伤特征的捕捉能力。

(1) SimAM 注意力机制

注意力机制通过对输入特征图的空间或通道分配权重,以模拟人在处理视觉信息时对不同区域的关注程度。利用注意力机制,可以增强网络对感兴趣区域的关注程度,并抑制背景区域等的无效信息。SimAM^[14]是一种简单且无参数的注意力机

制,其将特征图的像素视作神经元,构建了一个能量函数用于评估每个神经元的重要性,通过优化该函数来计算特征图每个神经元的注意力权重,提高特征图的代表能力。

(2) BiFPN 特征融合结构

BiFPN^[15]是一种特征融合网络,相比于特征金字塔网络 (Feature pyramid network, FPN) 和 PANet,可以更有效地整合多尺度特征信息,使颈部网络输出更优质的用于预测的特征图,其核心为:通过双向跨尺度连接和加权融合的方式,在不增加太多成本的情况下融合更多的特征。跨尺度连接可以有效地整合浅层特征和深层特征。加权融合通过为不同尺度特征图分配权重,量化并学习

各特征图对融合特征图的贡献度,进而优化特征融合的整体效果。

本文结合 BiFPN 的结构优势,引入 SimAM 对不同尺度特征图的贡献做进一步的增强。针对特征融合结构 SimBiFPN,在 YOLOv8 原本用于检测的特征层 P3~P5 的基础上,增加了大尺度特征层 P2,用于提供更多不同尺度的融合信息。具体来说,将主干网络中的浅层特征层 B2 作为骨干分支,同时将 SimBiFPN 自顶向下路径的特征层 F3 上采样与特征层 B2 维度对齐,作为 P2 的另一个分支。随后,两个分支进行拼接操作,拼接后的融合特征依次经过 SimAM 注意力机制和 C2f 模块处理,最终得到用于检测的大尺度特征层 P2。而在融合方式方面,与 BiFPN 的特征图相加不同,本文选择了与 YOLOv8 一致的相同尺度特征图通道拼接策略,以更好地保留各尺度特征的完整性。

1.3 小目标检测头

对孔探图像中的小尺寸损伤和细长损伤而言,YOLOv8 用于预测的 80 像素×80 像素、40 像素×40 像素、20 像素×20 像素这 3 种尺度的特征图的分辨率不足,难以对其进行准确预测。如图 4 所示,本文使用的 SimBiFPN 引入了大尺度特征层 P2 用于加强特征融合的能力,为了充分利用尺度为 160 像素×160 像素的 P2 层,于是增加一个用于检测 P2 层的小目标检测头,增强对小目标的检测能力。

2 实验分析

2.1 数据集准备

为训练叶片损伤检测模型 BD-YOLO,本研究构建了专用的孔探叶片损伤图像数据集。首先,通过最大帧间差分法从孔探视频中提取关键帧,经人工筛选后获得 708 张初始图像(部分示例如图 5 所示,涵盖烧蚀、刻口、撕裂及裂纹 4 类损伤)。进一



(a) Ablation (b) Nick (c) Tear (d) Crack

图 5 孔探图像叶片和损伤数据样本

Fig.5 Data samples of blades and damages in borescope images

步通过添加噪声、调整对比度和旋转图像等数据扩充方式将样本量扩充至 2 505 张,包含烧蚀样本 760 个、刻口样本 681 个、撕裂样本 696 个、裂纹样本 512 个以及完整叶片样本 2 122 个。最终按 7:3 的比例划分训练集(1 754 张)与测试集(751 张)。

2.2 评价指标

目标检测中,常用的模型评价指标有:精确率(Precision)、召回率(Recall)、平均精度均值(Mean average precision, mAP)、检测速度,从模型精度、模型检测速度等角度评价模型。

(1) 精确率和召回率

精确率计算的是模型预测为正例中实际为正例的比例,用于衡量模型判别类型的能力。召回率计算的是所有正例中被模型预测为正例的比例,用于衡量模型正确划分类别的能力。精确率和召回率用于评价模型的预测性能,两者的值越高,模型的检测精度越高。计算公式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

式中:TP 为模型正确检测出的损伤样本数,FP 为模型误报的样本数,FN 为模型漏报的样本数

(2) mAP

mAP 代表了各类别目标的平均精度(Average precision, AP)的平均值。AP 是以召回率 R 为横轴,精确率 P 为纵轴绘制的 $P-R$ 曲线下的面积,用于衡量模型在特定类别上的检测能力。mAP 的计算首先需要确定预测框与真实框的交并比(Intersection over union, IoU)阈值,通过这个阈值来划分一个预测结果是否为 TP,阈值越高表示要求越严格。然后根据划分的 TP 计算不同类别的 AP,对所有类别的 AP 平均,获得 mAP。计算公式为

$$\text{AP} = \int_0^1 P(R) dR \quad (3)$$

$$\text{mAP} = \frac{\sum_{i=1}^K \text{AP}_i}{K} \quad (4)$$

式中 K 为检测的总类别数。本文选择 3 种不同 IoU 下的 mAP 对模型进行评价。

(a) mAP50 指 IoU 阈值为 0.5 下的 mAP,较为宽松的标准,用于初步评估模型性能。

(b) mAP75 指 IoU 阈值为 0.75 下的 mAP,更为严格的标准,适用于对小目标检测精度和高精度定位能力的评估。

(c) mAP50~95 指 IoU 阈值为 0.5~0.95 范围内,以 0.05 为步长计算的平均值,考虑了不同 IoU 阈值下的模型性能,提供更全面的评估。

(3) 检测速度

检测速度用模型每秒能够处理的图像数量表示,用于评价目标检测模型的推理速度。检测速度越高表明算法的实时性越好,为满足孔探检测的实时性需求,模型的推理速度应至少达到 24 帧/s。

2.3 实验环境与训练

本文基于 PyTorch 深度学习框架训练 BD-YOLO 模型。实验硬件配置为:13th Gen Intel® Core™ i5-13400KF 中央处理器、NVIDIA GeForce RTX 3060 显卡(12 GB 显存)及 16 GB 内存。训练超参数设置如下:迭代轮次=300,批尺寸=32,优化器采用随机梯度下降法(Stochastic gradient descent, SGD),动量=0.937,权重衰减=0.000 5。学习率调度策略采用余弦退火法,初始值设为 1×10^{-2} ,最小值为 1×10^{-5} 。

图 6 展示了 BD-YOLO 模型在训练集和测试集上的损失(含定位损失(box_loss)、分类损失(cls_loss)和动态特征损失(dfl_loss))曲线。训练集损失随轮次增加而下降,定位损失和动态特征损失在 0~50 轮快速下降后趋缓,分类损失在 0~30 轮快速下降后趋缓,最终 3 类损失分别约为 0.6、0.6、1.6。验证集损失变化趋势与训练集类似,均随迭代次数的增加而减小,然后逐渐稳定在一个较小的区间,未出现反弹或显著发散。同时整体两者趋势一致,说明模型已经收敛且未出现过拟合现象。




图 6 BD-YOLO 模型在训练集和测试集的损失曲线

Fig.6 Loss curves of the BD-YOLO model on training and validation sets

2.4 消融实验

为了验证改进模块对网络性能提升的影响,本节将 YOLOv8-obb 与分别添加了小目标检测模块 CSRFEFEM、特征融合结构 SimBiFPN 和小目标检

测头后的模型进行对比。

(1) 小目标检测模块 CSRFEFEM

表 1 为添加小目标检测模块前后两者在测试集上的检测结果。可以看出,相比于 YOLOv8-obb,添加了 CSRFEFEM 模块后模型的 mAP50、mAP75、mAP50~95 分别提升了 0.1%、4.4%、1.54%。mAP50 的提升极小,这是因为在这个阈值下,基础模型的性能已经趋于饱和,很难对其产生有效的提升,而 mAP50~95 的变化也被低阈值的结果稀释。因此,使用 AP75 即 IoU 阈值为 0.75 时的 AP 值对各个损伤进行单独的对比。

表 1 添加 CSRFEFEM 前后结果对比

Table 1 Comparative results before and after adding CSRFEFEM %

模型	mAP50	mAP75	mAP50~95
YOLOv8-obb	98.5	74.9	62.0
YOLOv8+CSRFEFEM	98.6	79.3	63.5

通过表 2 可以看出,添加了 CSRFEFEM 模块后,叶片烧蚀、刻口、撕裂和裂纹损伤的 AP75 分别提高了 4.2%、4.7%、2.6%、5.7%,模型在检测数据集中存在小尺寸目标的烧蚀和刻口损伤以及形态细长的裂纹损伤方面表现出显著的能力提升。图 7(a)为 YOLO-obb 模型的检测结果,图 7(b)为添加 CSRFEFEM 模块后的检测结果,可以看出,增加了 CSRFEFEM 后有效地提升了模型的检测精度。


表 2 添加 CSRFEFEM 前后各损伤检测结果对比

Table 2 Comparative results before and after adding CSRFEFEM %

模型	损伤类型	AP75
YOLOv8-obb	烧蚀	62.8
	刻口	75.1
	撕裂	95.1
	裂纹	58.5
YOLOv8+CSRFEFEM	烧蚀	67.0
	刻口	79.8
	撕裂	97.7
	裂纹	64.2

(2) 特征融合结构 SimBiFPN 和小目标检测头

为了验证特征融合结构 SimBiFPN 和检测大尺度特征层 P2 的小目标检测头的有效性。将只引入 SimBiFPN 的模型 YOLO-SBI、添加了小目标检测头的 YOLO-P2、同时引入 SimBiFPN 和小目标检测头的 YOLO-P2SBI 与 YOLOv8-obb 进行了对比实验,表 3 为实验结果。可以看出,mAP50 依然变化不大;结合了 SimBiFPN 和小目标检测头的



(a) Detection results of YOLOv8-obb (b) Detection results of YOLOv8+CSRFEM

图 7 检测结果对比

Fig.7 Comparison of detection results

表 3 特征融合和小目标检测头改进前后结果对比
Table 3 Comparative results before and after improvement of feature fusion and small object detection head

模型	mAP50/ %	mAP75/ %	mAP50~ 95/%	检测速度/ (帧·s ⁻¹)
YOLOv8-obb	98.5	74.9	62.0	42
YOLO-SBI	98.5	80.2	62.3	39
YOLO-P2	98.5	81.4	62.1	38
YOLO-P2SBI	98.4	81.7	62.0	36

YOLO-P2SBI 在 mAP75 中获得最佳表现, 为 81.7%, 但检测速度最低; 各模型的 mAP50~95 则与初始模型相比差别不大。且随着模型复杂度的提升, 模型的检测速度有所下降。

为了直观地展现各模型在不同类别损伤检测上的性能差异, 图 8 展示了各模型在不同类别上的 AP75 指标。从图 8 可以看出相对于基础模型而言, 各改进模型的 AP75 在烧蚀、刻口和裂纹损伤中均有提升, 裂纹损伤的提升最大, 而在撕裂损伤中有所降低。其中, YOLO-SBI 在烧蚀、裂纹损伤和叶片的检测精度最高, YOLO-P2 在刻口损伤的检测精度最高, YOLOv8-obb 在撕裂损伤的检测精度最高。从图 8 中 YOLO-SBI 的曲线可以看出, 改进的特征融合结构 AP75 最为均衡, 说明有效地利用了各尺度的特征图, 很好地平衡了各类的精度。增加了小目标检测头的 YOLO-P2 在存在较小尺寸的刻口损伤表现最好, 说明增加了对小尺寸损伤的检测精度。YOLO-P2SBI 则结合了两者的优




图 8 模型改进前后各类别 AP75

Fig.8 AP75 for each category before and after model improvement

点, 获得了最高的 mAP75。

2.5 与其他模型检测结果对比

为了进一步验证本文提出的 BD-YOLO 模型在航空发动机叶片损伤检测任务上的优势, 本节将 BD-YOLO 与其他常用的旋转框目标检测模型 R3-Det、YOLOv5-obb、YOLOv7-tiny-obb 等模型进行对比实验。在相同的实验环境配置下, 使用相同的参数和数据集进行训练和测试。

表 4 为对比实验结果。在 mAP50 和 mAP75 这两项指标上, 与 YOLOv8-obb、R3-Det、YOLOv5-obb、YOLOv7-tiny-obb 相比, BD-YOLO 均取得了最佳表现, 尤其在 mAP75 上与其他模型的差距明显, 说明模型对小尺寸损伤有更好的检测效果。在 mAP50-95 这项指标上 BD-YOLO 不如 R3-Det, 说明在综合检测能力方面, BD-YOLO 尚有提升空间, 但与其他模型相比仍具有优势。同时, BD-YOLO 的检测速度逊色于 YOLOv8-obb, 但领先于其他检测模型, 且满足实时检测的需求。通过以上分析可知, BD-YOLO 兼具精度与速度, 在孔探损伤检测任务上具有优势。

表 4 BD-YOLO 与其他旋转框目标检测模型对比
Table 4 Comparison between BD-YOLO and other rotated bounding box object detection models

模型	mAP50 /%	mAP75/ %	mAP50 ~95/%	检测速度/ (帧·s ⁻¹)
YOLOv8-obb	98.5	74.9	62.0	42
R3-Det	97.2	82.2	69.3	10
YOLOv5-obb	94.4	78.1	61.9	30
YOLOv7-tiny-obb	94.0	76.4	61.8	32
BD-YOLO	98.6	84.3	63.3	34

3 结 论

本文提出一种基于旋转目标检测的 BD-YOLO 模型, 旨在解决孔探图像中叶片缺陷方向任意性及细长损伤定位精度不足的问题。该模型的核心创新包括: (1) 设计 CSRFEM, 提升浅层

特征对小尺寸损伤的捕获能力;(2)引入改进的双向特征金字塔网络SimBiFPN,优化多尺度特征融合效率;(3)增设小目标专用检测头,增强对细微损伤的识别敏感度。系统的消融实验验证了各模块的有效性,对比实验进一步证明:BD-YOLO在叶片损伤检测任务中实现了精度与速度的平衡(mAP50为98.6%,34帧/s)。本模型为航空发动机孔探图像中的复杂目标检测提供了解决方案,具备工程应用潜力。

参考文献:

- [1] 余佳琛. 民航发动机电子内窥镜孔探检查的管理[J]. 电子世界, 2017(24): 190-191.
- [2] 王晓兵. 基于孔探检测的民航发动机维修间隔优化研究[D]. 天津: 中国民航大学, 2018.
WANG Xiaobing. Research on civil aviation engine maintenance interval optimization based on borescope inspection[D]. Tianjin: Civil Aviation University of China, 2018.
- [3] 杨晓军,王瑛琦,刘智刚. 航空发动机涡轮叶片损伤分析[J]. 机械工程与自动化, 2017(3): 203-205.
YANG Xiaojun, WANG Yingqi, LIU Zhigang. Analysis of damaged blades of aero-engine turbine[J]. Mechanical Engineering & Automation, 2017(3): 203-205.
- [4] 卢宏涛,罗沐昆. 基于深度学习的计算机视觉研究新进展[J]. 数据采集与处理, 2022, 37(2): 247-278.
LU Hongtao, LUO Mukun. Survey on new progresses of deep learning based computer vision[J]. Journal of Data Acquisition and Processing, 2022, 37(2): 247-278.
- [5] 孙涵,刘译善,林昱涵. 基于深度学习的显著性目标检测综述[J]. 数据采集与处理, 2023, 38(1): 21-50.
SUN Han, LIU Yishan, LIN Yuhuan. Deep learning based salient object detection: A survey[J]. Journal of Data Acquisition and Processing, 2023, 38(1): 21-50.
- [6] 旷可嘉. 深度学习及其在航空发动机缺陷检测中的应用研究[D]. 广州: 华南理工大学, 2017.
KUANG Kejia. Research on deep learning and its application on the defects detection for aeroengine[D]. Guangzhou: South China University of Technology, 2017.
- [7] 曹斯言,刘君强,宋高腾,等. 基于自注意力语义分割的航空发动机孔探图像检测[J]. 北京航空航天大学学报, 2023, 49(6): 1504-1515.
CAO Siyan, LIU Junqiang, SONG Gaoteng, et al. Borehole image detection of aero-engine based on self-attention semantic segmentation model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(6): 1504-1515.
- [8] 何宇豪,曹学国,刘信良,等. 基于SW-YOLO模型的航空发动机叶片损伤实时检测[J]. 推进技术, 2024, 45(2): 197-203.
HE Yuhao, CAO Xueguo, LIU Xinliang, et al. Real-time detection of aircraft engine blade damage based on SW-YOLO model[J]. Journal of Propulsion Technology, 2024, 45(2): 197-203.
- [9] 黄睿,成旭毅,汪若飞,等. 自适应参数分析结果的航空发动机孔探图像损伤检测[J]. 中国图象图形学报, 2023, 28(10): 3136-3148.
HUANG Rui, CHENG Xuyi, WANG Ruofei, et al. Adaptive parameters based borescope image-related damage detection of aeroengine[J]. Journal of Image and Graphics, 2023, 28(10): 3136-3148.
- [10] SHANG H, WU J, SUN C, et al. Global prior transformer network in intelligent borescope inspection for surface damage detection of aeroengine blade[J]. IEEE Transactions on Industrial Informatics, 2023, 19(8): 8865-8877.
- [11] LLERENA J M, ZENI L F, KRISTEN L N, et al. Gaussian bounding boxes and probabilistic intersection-over-union for object detection[J]. IEEE Transactions on Image Processing, 2024, 33: 671-681.
- [12] WANG C Y, LIAO H Y M, YEH I H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[EB/OL]. (2019-11-27). <https://arxiv.org/abs/1911.11929>.
- [13] HAN Y, LIAO J, LU T, et al. KCPNet: Knowledge-driven context perception networks for ship detection in infrared imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-19.
- [14] YANG L, ZHANG R Y, LI L, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks[C]//Proceedings of the 38th International Conference on Machine Learning.[S.l.]: PMLR, 2021: 11863-11874.
- [15] 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.[S.l.]: IEEE, 2020: 10781-10790.