

基于SW-YOLO模型的航空发动机叶片损伤实时检测*

何宇豪¹, 曹学国², 刘信良¹, 蒋浩坤¹, 王静秋¹

(1. 南京航空航天大学 直升机传动技术重点实验室, 江苏南京 210016;

2. 广州飞机维修工程有限公司 工程部发动机处, 广东广州 510470)

摘要: 孔探检测技术是航空发动机叶片损伤检测的主要手段,但目前依赖人工操作,耗时耗力。本文提出了一个孔探视频检测的SW-YOLO模型,该模型包括输入端、主干网络、颈部网络、头部网络4个模块。首先,在主干网络加入了空间通道注意力模块(Spatial Channel-Convolutional Block Attention Module, SC-CBAM),有效避免位置信息丢失,提高目标边界回归能力,相较于YOLOv5,其平均精度均值 $\bar{P}_A@0.5$ 提高了5.4%。其次,在颈部网络对特征金字塔网络(Feature Pyramid Network, FPN)进行了改进,通过融合低层特征,扩大了模型感受野,有利于较小损伤区域的检测,如烧蚀损伤,平均精度提高了8.1%。最后,通过与YOLOv5, Faster R-CNN, SSD模型的对比实验,结果表明SW-YOLO模型的平均精度均值分别提高了7%, 6.2%, 6.3%,检测速度满足实时检测需求,有利于提高航空发动机孔探检测的自动化和智能化水平。

关键词: 航空发动机; 叶片损伤; 深度学习; 孔探检测; 目标检测; 实时检测

中图分类号: V263.6; TP391.4 **文献标识码:** A **文章编号:** 1001-4055 (2024) 02-2302058-07

DOI: 10.13675/j.cnki.tjjs.2302058

1 引言

航空发动机作为航空器的动力心脏,其正常运行是飞行安全的关键。发动机由压气机、高压涡轮机等组成,由于长时间工作在高温、高压、高转速的严苛环境中,随着工作时间的不断积累,其核心构件,如发动机叶片,易产生烧蚀、卷边、裂纹、刻口、撕裂等损伤^[1],对发动机的正常运行构成威胁。目前,孔探检测是航空发动机叶片损伤检测的主要技术^[2-5],但其主要依赖人工操作,耗时耗力、效率较低。

随着计算机图像处理技术的发展,人们将其引入到孔探检测技术之中。其主要流程为:孔探图像预处理→边缘检测→特征提取→损伤检测。丁鹏等^[6]针对发动机叶片损伤,利用SUSAN边缘检测算法和小波变换检测叶片损伤程度。张勇等^[7]提出了一种基于样条插值的缺陷尺寸自动测量方法。刘笃

喜等^[8]基于边缘检测和小波变换技术提出了一种对发动机叶片裂纹的自适应检测算法。相较于传统的人工检测,上述研究提高了孔探检测技术的自动化水平。但由于图像处理技术操作过程是单向线性流程,特征提取难,步骤多且复杂,并且在特征提取过程中存在参数冗余和参数不足的情况,不可避免地会造成误差累积。

随着深度学习^[9]技术的不断发展,卷积神经网络(Convolutional Neural Network, CNN)被应用于计算机视觉和目标检测领域。Bian等^[10]提出多尺度特征金字塔网络(Feature Pyramid Network, FCN)用于检测发动机叶片热障涂层丢失。旷可嘉^[11]针对发动机叶片凹痕、缺口、烧蚀三种损伤类型,构建了缺陷图像识别系统。

上述研究成果表明CNN模型在发动机叶片损伤检测的可行性。为提升实际孔探过程的自动化和智

* 收稿日期: 2023-02-27; 修订日期: 2023-06-15。

基金项目: 直升机传动技术重点实验室基金(HTL-A-21G03)。

作者简介: 何宇豪, 硕士生, 研究领域为状态监测与故障诊断。

通讯作者: 王静秋, 博士, 教授, 研究领域为状态监测与故障诊断。E-mail: meejqwang@nuaa.edu.cn

引用格式: 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): 2302058. (HE Y H, CAO X G, LIU X L, et al. Real time detection of aircraft engine blade damage based on SW-YOLO model[J]. Journal of Propulsion Technology, 2024, 45(2): 2302058.)

能化水平,本文针对孔探视频,构建了一个 SW-YOLO 模型,可以实现航空发动机叶片损伤实时准确检测。

2 SW-YOLO 叶片损伤检测模型

YOLOv5 是在 2020 年被提出的一个具有代表性的 One-stage 目标检测模型(直接对整张图像进行检测并给出目标的类别概率和位置坐标值),由于其泛化能力强、准确率高以及最高可达 140 FPS 的检测速度,受到广泛关注。本文通过结合 YOLOv5 的优点,即在满足实时检测需求的同时,兼顾叶片损伤检测的准确性,提出了一个用于航空发动机叶片损伤视频检测的 CNN 模型—SW-YOLO,模型结构如图 1 所示。

SW-YOLO 模型包括输入端、主干网络、颈部网络、头部网络 4 个模块。输入端运用 Mosaic 数据增强提高网络模型训练效率;主干网络中主要通过卷积和池化金字塔结构(Spatial Pyramid Pooling - Fast, SPPF)^[12]提取图像特征;颈部网络采用特征金字塔结构,对不同尺寸目标特征信息进行传递;头部网络主要采用三种损失函数分别计算目标的类别、定位和置信度损失。相较于 YOLOv5 模型,SW-YOLO 模型主要进行了两个改进:①在主干网络中的每个 C3 模块后嵌入空间通道注意力模块(Spatial Channel - Convolutional Block Attention Module, SC-CBAM),形成 SCC3 模块,利用注意力机制提取更多关键信息,提高模型检测精确度以及目标边界的回归能力。②在特征金字塔结构中运用多尺度特征融合进行模型结

构改进,形成 W-PAN(Weighted Path Aggregation Network)结构,扩大感受野,提高模型对于尺寸较小的损伤的检测效果,降低漏检率。该模型的名称即来源于上述两个改进,其中 S 代表 SC-CBAM 注意力机制;W 代表 W-PAN 特征融合结构。

2.1 空间通道注意力模块

注意力机制的本质是从众多信息中选择出对当前任务目标更关键的信息,抑制无用信息,有利于提高检测精度。Woo 等^[13]提出一种注意力模块 CBAM (Convolutional Block Attention Module),同时关注了空间信息和通道信息,该模块由 CAM(Channel Attention Module)和 SAM(Spatial Attention Module)两个子模块组成。

在航空发动机叶片损伤图像中,需要着重关注损伤区域。空间注意力就是寻找目标区域进行处理,因此本文对 CBAM 结构进行改进,提高对空间注意力的关注程度,对输入特征同时进行通道和空间特征提取,然后进行特征融合,进一步抑制无用信息以提高模型的检测精度,构成 SC-CBAM 模块,其结构如图 2 所示。

SC-CBAM 输出公式如下

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

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

$$F_{out} = F_c \oplus F_s \quad (3)$$

式中 $F \in R^{W \times H \times C}$ 为输入特征图, $M_c(F)$ 和 $M_s(F)$ 分别为 F 经过通道注意力模块和空间注意力模块所得特

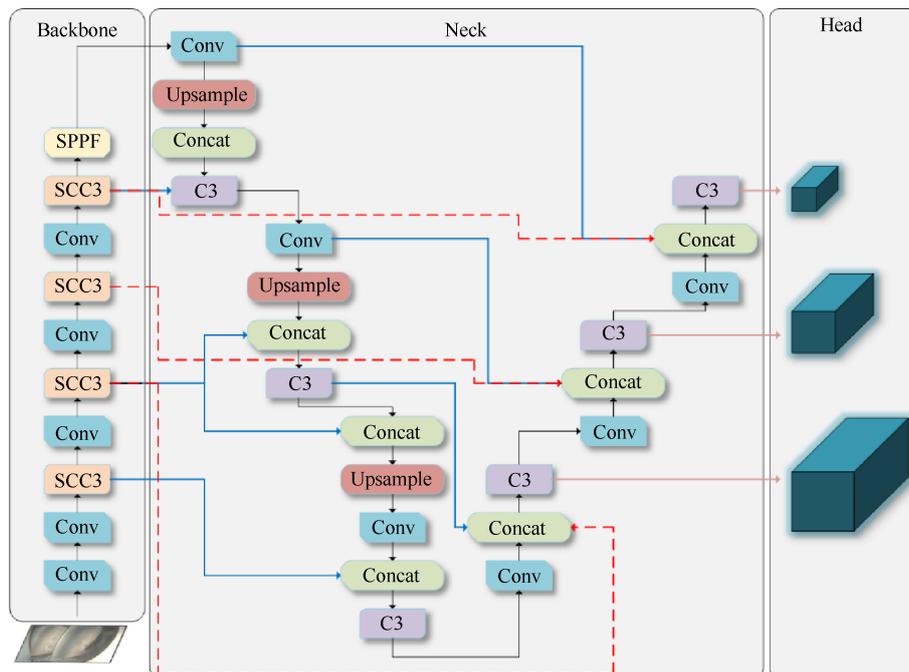


Fig. 1 Network structure diagram of SW-YOLO

征, F_{out} 为最终输出特征图, \otimes 表示元素乘法, \oplus 表示元素相加。

在主干网络中的 C3 模块后添加一个 SC-CBAM 模块得到 SCC3 模块。加入 SC-CBAM 模块后的结构如图 3 所示, 图 3(a) 是主干网络中的 C3 模块, 图 3(b) 是添加 SC-CBAM 之后的主干网络中的 SCC3 模块。

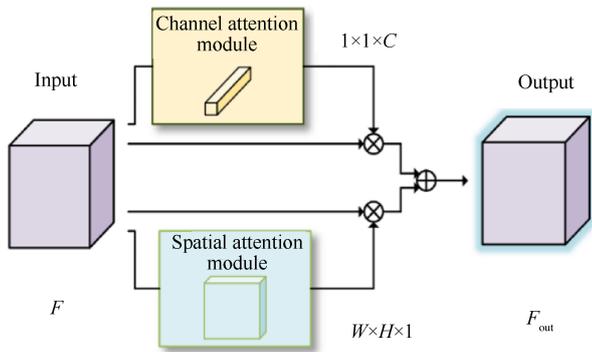


Fig. 2 SC-CBAM structure

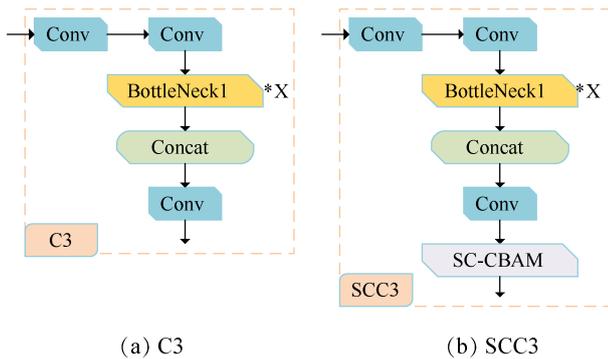


Fig. 3 Improvement of C3 structure

2.2 特征融合

目标检测模型通常利用多次卷积和下采样后的深层特征进行目标分类和回归。但对于尺寸较小的目标, 随着网络的加深, 经过多次卷积和下采样, 可用特征信息有限甚至消失, 造成检测效果不佳。特征融合通过融合浅层网络和深层网络中的图像特征信息, 缓解了尺寸较小目标特征信息丢失问题。

特征金字塔结构 FPN, 通过提取不同尺度的图像特征, 产生多尺度特征, 提高模型的泛化能力, 解决在检测过程中处理多尺度变化的不足。图 4 为 FPN 结构示意图。

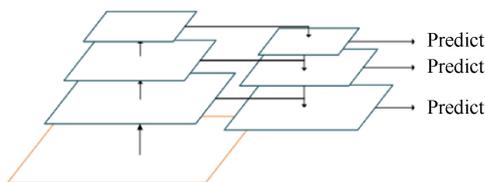


Fig. 4 FPN structure

YOLOv5 使用的特征融合借鉴了 PANet^[14] 的思想, 对 FPN^[15] 结构进行补充, 增加了自底向上的特征融合层。从原理来看, FPN 自顶向下传达更多语义信息, 而自底向上的特征融合层传达更多定位信息。因此对于不同尺度信息融合成为提升网络架构的一种方法^[16-20]。

双向特征金字塔网络 (Bi-direction Feature Pyramid Network, BiFPN) 是在 EfficientDet^[21] 目标检测算法中首次提出。BiFPN 主要的思想是通过高效的双向跨尺度连接和加权特征融合的方式, 丰富了特征的语义信息。

航空发动机损伤检测过程中, 较小尺寸损伤可提取特征少, 导致检测精度低。考虑到 BiFPN 的优势, 本文将 BiFPN 结构的思想应用于特征融合部分, 并充分利用高分辨率的低层特征, 扩大模型的感受野。改进后的结构称为 W-PAN, 具体结构如图 5 所示, 图 5(a) 为 YOLOv5 中的特征融合结构, 图 5(b) 为改进后的 W-PAN 结构。

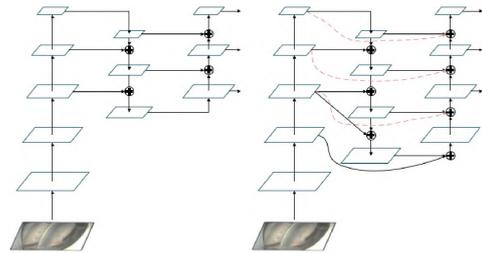


Fig. 5 Improvement of FPN structure

图 5 中红色虚线为跨层加权连接, 跨层加权连接能有效地将浅层信息融入到深层网络中, 使网络模型对目标边界回归更加准确。利用高分辨率的低层特征, 扩大模型感受野, 使网络模型获得更多语义信息和位置信息, 提高模型的学习能力, 进一步提升网络模型对航空发动机叶片中尺寸较小损伤的检测精度。

3 实验与分析

3.1 数据集制作

卷积神经网络需要运用图像数据进行训练, 通过学习数据样本的分布规律完成各图像处理任务。本文利用某航空公司提供的孔探视频制作数据集。孔探视频是图像序列, 若进行逐帧处理, 存在数据冗余且需要花费大量时间。因此, 本文采用基于固定帧数和基于帧间差分法两种关键帧提取技术获取图像数据样本。

基于固定帧数是在规定的时间或帧数间隔内提取关键帧,方法实现简单,能够快速提取图像。本文以20帧为固定帧,对多段孔探视频进行关键帧提取。

基于帧间差分法主要原理是利用每帧平均像素强度,通过对两帧图像进行差分衡量图像变化大小。若某一帧与前一帧发生较大变化,可作为关键帧进行提取。本文设置时间序列为50帧,选用差分强度局部最大值进行关键帧提取,能够有效移除噪声,一定程度上弥补了基于固定帧数提取关键帧的不足。图6为孔探视频平均差分强度图。

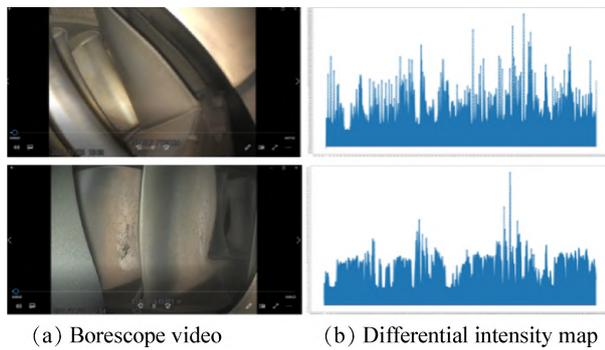


Fig. 6 Differential intensity of borescope video

通过对提取的孔探图像数据样本进行筛选后发现,出现频次最多的损伤类型为叶片边缘缺陷和烧蚀。对筛选后的数据样本进行增广以及类别均衡处理。最终,制作完成的数据集包括3000幅孔探图像,分辨率为 640×480 ,并按照7:2:1的比例随机划分为训练集、验证集、测试集,部分图例如图7所示。

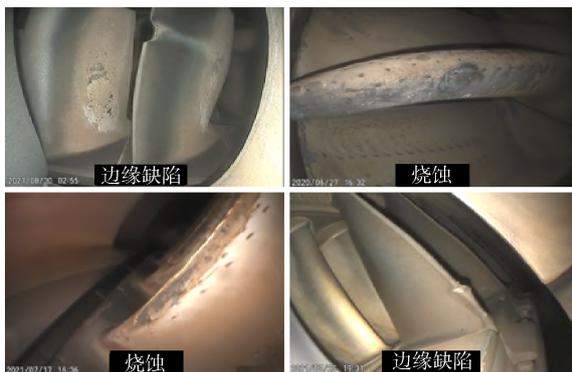


Fig. 7 Two typical damage types in borescope dataset

3.2 实验环境

本文利用Pytorch深度学习框架实现SW-YOLO模型的开发和训练。实验所用计算机处理器为AMD Ryzen 5 5600X 6-Core Processor 3.70 GHz,显卡为NVIDIA GeForce 3060 Ti,16 GB内存。模型训练参数,如,批量训练大小设为8,初始学习率设为0.01,

选用动量参数为0.937的随机梯度下降(SGD)优化器,总迭代次数设为300。

3.3 模型性能的评价指标

为了验证模型的性能,本文使用平均精度均值($\bar{P}_A@0.5$)、召回率(R_{recall})、检测速度(FPS)作为目标检测模型的评价指标。其中, $\bar{P}_A@0.5$ 表示在交并比(IoU,用来度量目标检测中预测框与真实框的重叠程度)阈值为0.5时,对所有类别的平均精度(P_A)的平均值。FPS表示每秒检测图像的数量,值越大检测速度越快。

\bar{P}_A 的计算公式为

$$\bar{P}_A = \frac{\sum_{i=1}^K P_{A,i}}{K} \quad (4)$$

式中 K 是检测的类别数; \bar{P}_A 是 P_A 的平均值,该值越高表明检测效果越好。 P_A 是以召回率(R_{recall})为横轴,准确率($R_{\text{precision}}$)为纵轴形成的PR曲线下的面积。准确率和召回率的计算公式为

$$R_{\text{precision}} = \frac{n_{\text{TP}}}{(n_{\text{TP}} + n_{\text{FP}})} \quad (5)$$

$$R_{\text{recall}} = \frac{n_{\text{TP}}}{(n_{\text{TP}} + n_{\text{FN}})} \quad (6)$$

式中 n_{TP} 代表IoU \geq 设定阈值的检测框数目, n_{FP} 代表IoU<设定阈值的检测框数目, n_{FN} 代表漏检的目标数目。

3.4 对比实验

SC-CBAM注意力机制模块和特征融合模块W-PAN是本文提出的SW-YOLO模型的2个重要结构改进,为了验证其有效性,本文开展了以下三个对比实验。

(1) SC-CBAM注意力机制对比实验

分别将CBAM和SC-CBAM两种注意力机制加入YOLOv5模型,在测试集上进行对比实验,结果如表1所示。

Table 1 Comparison of experiments before and after CBAM attention improvement

Item	Mean average precision ($\bar{P}_A@0.5$)	Detection speed (FPS)
YOLOv5	0.788	60
YOLOv5-CBAM	0.837	58
YOLOv5-SCCBAM	0.842	57

从表1中可以看出,加入SC-CBAM模块后的模型, $\bar{P}_A@0.5$ 提升了5.4%。

图8为加入CBAM和SC-CBAM两种注意力机制模块后的热力图对比。可以看出,加入SC-CBAM注

意力机制模块后,热力图更明显,说明赋予通道和空间注意力模块相同的优先级,提高了特征图在通道和空间上的信息交流,抑制了无用信息,使得网络模型对目标检测区域的覆盖度和关注度都有所提升,更有利于提取目标的有效特征。

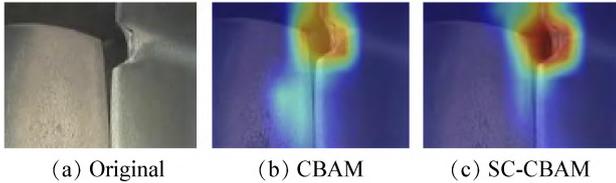


Fig. 8 Comparison of attention thermogram

图9为在测试集上的叶片损伤检测结果,图框表示损伤位置,并给出损伤类型(如刻口)和置信度(如0.91)。从图中可以看出,加入SC-CBAM注意力机制后的模型具有更高的检测精度。

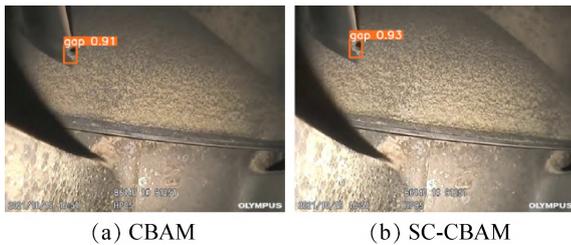


Fig. 9 Comparison of test results

(2)W-PAN 特征融合模块对比实验

将 W-PAN 特征融合模块加入 YOLOv5 模型,并在测试集上进行了对比实验,结果如表2所示。相比于 YOLOv5 模型,加入 W-PAN 特征融合模块后, $\bar{P}_A@0.5$ 提升了 5.6%。

Table 2 Comparison of results before and after feature fusion improvement

Item	Mean average precision ($\bar{P}_A@0.5$)	Detection speed (FPS)
YOLOv5	0.788	60
YOLOv5-WPAN	0.844	38

表3为在测试集上两种叶片损伤检测结果的对比。对于叶片烧蚀损伤的平均检测精度 P_A 值提升了 8.1%,对于刻口检测的平均精度 P_A 值提升了 3.1%。图10(a)为 YOLOv5 检测结果,图10(b)为 YOLOv5-WPAN 检测结果。从图中可以看出,YOLOv5 对于叶片烧蚀存在一定的漏检现象,如图中红色框。改进后的 W-PAN 结构使得网络模型不仅对于精度有一定的提升,而且降低了一定漏检现象。

Table 3 Comparison of two types of blade damage detection results

Item	Damage types	Average precision
YOLOv5	Ablation	0.759
	Gap	0.818
YOLOv5-WPAN	Ablation	0.840
	Gap	0.849



Fig. 10 Comparison of test results

(3)SW-YOLO 与其它模型对比实验

本文将 SW-YOLO 模型与 Faster-RCNN^[22-23], SSD^[24] 目标检测模型在相同实验环境、相同参数和测试集上进行了对比实验,结果如表4所示。

与 YOLOv5 相比,SW-YOLO 虽然检测速度略有不足,但检测精度有所提升,且检测速度也满足实时检测需求。与同为单阶段的 SSD 模型相比,检测精度提升了 6.3%,检测速度提升也较为明显。与两阶段的 Faster R-CNN 模型相比,检测精度提升了 6.2%,速度上也有明显优势。

Table 4 Comparison between SW-YOLO and other object detection algorithms

Item	Mean average precision ($\bar{P}_A@0.5$)	Detection speed (FPS)
YOLOv5	0.788	60
Faster R-CNN	0.796	14
SSD	0.795	25
SW-YOLO	0.858	35

4 结论

本文针对航空发动机叶片损伤检测进行了研究,提出了一个用于孔探视频实时检测的 SW-YOLO 模型,可以得到以下结论:

(1)SW-YOLO 模型通过 SC-CBAM 模块提高了

目标边界回归能力,有利于获取更多关键信息,相较于 YOLOv5,其平均精度均值 $\bar{P}_A@0.5$ 提高了 5.4%。

(2)采用 W-PAN 结构充分利用低层特征,扩大了模型的感受野,提高了对小尺寸损伤的检测效果,如烧蚀损伤,平均精度提高了 8.1%。

(3)通过与 YOLOv5, Faster R-CNN, SSD 模型的对比实验,结果表明 SW-YOLO 模型的平均精度均值分别提高了 7%, 6.2%, 6.3%, 该模型在提高检测精度的同时也保证了实时检测的需求,利于提高航空发动机孔探检测技术的自动化和智能化水平。

致谢:感谢直升机传动技术重点实验室基金的资助。特别感谢南京航空航天大学高性能计算平台的支持和南京航空航天大学机电学院王晓雷、黄巍、戴庆文等参与本研究的讨论及提供的帮助。

参考文献

- [1] 官 颂, 曲培树, 董文会, 等. 航空发动机智能内窥故障诊断[J]. 辽宁工程技术大学学报(自然科学版), 2009, 28(6): 981-984.
- [2] 袁传金, 刘文凯, 陈 宸. 航空发动机维护中孔探检测的运用[J]. 科技资讯, 2016, 14(7): 43-44.
- [3] 肖柏荣. 航空发动机维护中孔探检测技术的应用[J]. 中国高新技术, 2019, 51(15): 96-98.
- [4] 于 辉. 孔探技术及其在航空发动机维修中的应用[J]. 航空制造技术, 2005(6): 94-99.
- [5] 李小丽, 陈新波, 吴松华, 等. 基于图像预处理的发动机叶片掉块损伤自动测量技术[J]. 推进技术, 2023, 44(4): 210916. (LI X L, CHEN X B, WU S H, et al. Automatic measurement technology of engine blade damage based on image processing[J]. Journal of Propulsion Technology, 2023, 44(4): 210916.)
- [6] 丁 鹏, 李长有, 马齐爽, 等. 基于小波的航空发动机叶片孔探损伤检测[J]. 北京航空航天大学学报, 2006, 36(12): 1435-1438.
- [7] 张 勇, 刘冠军, 邱 静. 基于图像自动测量的航空发动机故障检测技术研究[J]. 机械科学与技术, 2008, 27(2): 176-179.
- [8] 刘笃喜, 温立民, 朱名铨. 飞机发动机叶片裂纹自适应检测算法的研究[J]. 测控技术, 2007, 26(6): 31-33.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [10] BIAN X, LIM S N, ZHOU N. Multiscale fully convolutional network with application to industrial inspection [C]. Lake Placid: 2016 IEEE Winter Conference on Applications of Computer Vision(WACV), 2016.
- [11] 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.
- [12] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence(T-PAMI), 2015, 37(9): 1904-1916.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]. Munich: European Conference on Computer Vision(ECCV), 2018.
- [14] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. Salt Lake City: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2018.
- [15] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Honolulu: 2017 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2017.
- [16] GHIASI G, LIN T Y, LE Q V. NAS-FPN: learning scalable feature pyramid architecture for object detection [C]. Long Beach: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- [17] HUANG Z, WANG J, FU X, et al. DC-SPP-YOLO: dense connection and spatial pyramid pooling based YOLO for object detection [J]. Information Sciences, 2020, 522: 241-258.
- [18] 奉志强, 谢志军, 包正伟, 等. 基于改进 YOLOv5 的无人机实时密集小目标检测算法[J]. 航空学报, 2023, 44(7): 327106.
- [19] 邱天衡, 王 玲, 王 鹏, 等. 基于改进 YOLOv5 的目标检测算法研究[J]. 计算机工程与应用, 2022, 58(13): 63-73.
- [20] 刘彦清. 基于 YOLO 系列的目标检测改进算法[D]. 长春: 吉林大学, 2021.
- [21] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection [C]. Seattle: 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020.
- [22] 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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [23] GIRSHICK R. Fast R-CNN [C]. Santiago: 2015 IEEE International Conference on Computer Vision (ICCV), 2015.
- [24] LIU W, AANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Amsterdam: The 14th European Conference on Computer Vision, 2016.

(编辑:梅 瑛)

Real time detection of aircraft engine blade damage based on SW-YOLO model

HE Yuhao¹, CAO Xueguo², LIU Xinliang¹, JIANG Haokun¹, WANG Jingqiu¹

(1. National Key Laboratory of Science and Technology on Helicopter Transmission, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Engine Division of Engineering Department, Guangzhou Aircraft Maintenance Engineering Co. Ltd., Guangzhou 510470, China)

Abstract: Borescope detection technology is one of the main means for detecting damage of aero-engine blades, but currently it mainly relies on manual operation and is time-consuming and labor-intensive. This paper proposes a SW-YOLO model for aero-engine blade damage borescope video detection. The model includes 4 modules: input terminal, backbone network, neck network and head network. Firstly, by adding a space channel attention module Spatial Channel-Convolutional Block Attention Module (SC-CBAM) to the backbone network to alleviate the loss of location information and improve the ability of target boundary regression, and its average accuracy $\bar{P}_A@0.5$ increases by 5.4% compared with YOLOv5. Secondly, the structure of Feature Pyramid Network (FPN) is improved in the neck network, and the low-level features are fused to expand the receptive field of the model, which has a better detection effect for the smaller damage area, such as ablation, and the average accuracy is improved by 8.1%. At last, compared with YOLOv5, Faster R-CNN and SSD models, the experimental results show that the average precision mean of the SW-YOLO model has been improved about 7%, 6.2%, 6.3%, respectively, and the detection speed meets the real-time detection requirements, which is conducive to improving the automation and intelligence level of aero-engine blade damage borescope detection.

Key words: Aircraft engine; Blade damage; Deep learning; Borescope detection; Object detection; Real-time detection

Received: 2023-02-27; **Revised:** 2023-06-15.

Foundation item: National Key Laboratory of Science and Technology on Helicopter Transmission (HTL-A-21G03).

DOI: 10.13675/j.cnki.tjjs.2302058

Corresponding author: WANG Jingqiu, E-mail: meejqwang@nuaa.edu.cn