

改进 YOLOv7 的航空发动机叶片损伤检测方法

魏永超¹, 刘嘉欣², 朱泓超², 朱姿翰³, 刘伟杰²

(中国民用航空飞行学院 科研处¹, 民航安全工程学院², 航空电子电气学院³; 四川德阳 618307)

摘要: 针对目前航空发动机叶片损伤检测精度低的问题, 提出了一种基于改进 YOLOv7 的发动机叶片损伤检测模型 YOLOv7-CC。对发动机叶片缺损图像进行损伤标注, 构建航空发动机叶片损伤数据集, 并且采用二分 K-means 算法对标记框进行聚类, 获取与该数据集最匹配的锚框(anchor)。在模型中 Backbone 网络输出之后采用坐标注意力机制, 分别捕获长距离依赖关系和保留精确的位置信息, 提高对损伤目标的检测能力, 并在特征重组过程中采用轻量级上采样算子(CARAFE), 同时保留了语义信息以及位置信息, 通过更大的感受野来完成上采样, 提高了网络对特征的提取能力。结果表明: 所提出的基于 YOLOv7-CC 算法的损伤检测的平均精度达到了 83.53%, 相较于基准网络提升了 7.4%, 能够对航空发动机叶片 3 种常见的损伤类型实现高效检测。

关键词: 损伤检测; 深度学习; YOLOv7 模型; 注意力机制; 航空发动机

中图分类号: V232.4

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2025.01.019

Improved YOLOv7 Damage Detection Method for Aeroengine Blade

WEI Yong-chao¹, LIU Jia-xin², ZHU Hong-chao², ZHU Zi-han³, LIU Wei-jie²

(Department of Scientific Research Office¹, School of Civil Aviation Safet Engineering², School of Avionics and Electrical³,
Civil Aviation Flight Academy of China: Deyang Sichuan 618307, China)

Abstract: Aiming at the current problem of low accuracy of aeroengine blade damage detection, an engine blade damage detection model YOLOv7-CC based on improved YOLOv7 was proposed. The engine blade defect images were labeled with damage to construct an aeroengine blade damage dataset, and the labeled frames were clustered using the bifurcated K-means algorithm to obtain the anchors that best match this dataset. After the output of Backbone network in the model, the coordinate attention mechanism was used to capture the long-distance dependency and retain the accurate position information respectively, to improve the detection ability of the damage target, and the CARAFE lightweight up-sampling algorithm was used during the feature reorganization process, retaining the semantic information as well as the positional information at the same time; the up-sampling was completed through the larger sensory field, improving the feature extraction ability of the network. The results show that the proposed YOLOv7-CC algorithm for damage detection achieves an average accuracy of 83.53%, which is a 7.4% improvement compared to the baseline network, and is able to realize highly efficient detection of the three common damage types of aeroengine blades.

Key words: damage detection; deep learning; YOLOv7 model; attention mechanism; aeroengine

0 引言

航空发动机被誉为飞机的“心脏”, 其安全性对整架飞机而言具有至关重要的意义^[1]。航空发动机的结构复杂, 工作环境恶劣^[2], 许多零部件长时间处于高温高压条件下, 而且还需应对腐蚀和氧化的环境侵蚀。在发动机运行过程中, 叶片容易出现裂纹(Crack)、烧

蚀(Burn)和涂层脱落(Missing Coating)等损伤^[3]。因此, 发动机叶片的状况极大程度上影响着其正常运行, 并潜在地威胁着飞机的运行安全^[4]。现有的发动机叶片缺陷检测手段, 通常采用孔探设备获取叶片信息, 再由人工判断叶片状况, 存在效率低和操作人员易疲劳等问题。深度学习技术的发展, 为航空发动机缺陷检测提供了新的解决方案。

收稿日期: 2023-08-28 基金项目: 中央高校基本科研业务费(J2021-056)、四川省科技厅重点研发项目(2022YFG0356)、西藏科技厅重点研发计划(XZ202101ZY0017G)、中科院西部青年学者项目、中国民用航空飞行学院科研基金(J2020-040, CJ2020-01)资助
作者简介: 魏永超(1981), 男, 博士, 教授。

引用格式: 魏永超, 刘嘉欣, 朱泓超, 等. 改进 YOLOv7 的航空发动机叶片损伤检测方法[J]. 航空发动机, 2025, 51(1): 133-139. WEI Yongchao, LIU Jiixin, ZHU Hongchao, et al. Improved YOLOv7 damage detection method for aeroengine blade[J]. Aeroengine, 2025, 51(1): 133-139.

通过目标检测算法的改进,深度学习在航空发动机损伤检测任务中提高了精度和效率,使其成为该领域的研究热点。许多专家学者在航空发动机缺陷检测任务中尝试了深度学习的方法,取得了不错的效果。Sun 等^[5]将空闲信道评估(Clear Channel Assessment, CCA)思想应用于特征融合和图像识别,但该方法只在小样本量情况下表现突出;李龙浦^[6]使用改进的 Faster R-CNN 和改进的 YOLOv3 模型, mAP 值分别为 81.3% 和 90.5%, 但改进之后的网络速度较慢;李浩^[7]提出了改进的 R-FCN 算法,并对 YOLOv3 的特征金字塔网络(Feature Pyramid Networks, FPN)进行了优化,获取了更丰富的特征,具有较高的准确率;李涛^[3]针对 Mask R-CNN 模型在缺陷检测中实时性较差的问题,提出了一种改进的 TMask R-CNN 模型, mAP 值达到 90.65%;李鑫等^[8]使用改进的 YOLOv5 缺陷检测模型,在不降低检测速度的情况下,将 mAP 值提高了 1.2%,实现了对航空发动机 4 种常见类型缺陷的高效智能检测;刘宜轩等^[9]使用改进的 YOLOv5 叶片表面缺陷检测方法,提高了对叶片表面缺陷特征的提取能力,相对于 YOLOv5 算法,该方法在平均精度均值上提升了 1.4%;赵崇林等^[10]将协调注意力模块融入基准网络 YOLOv5,其检测缺陷的平均精确度达到了 89.7%,比基准网络提升了 6.3%。上述学者们采用深度学习算法在航空发动机缺陷检测任务中取得了显著进展。然而,缺陷目标具有尺寸较小、边界模糊以及背景纹理复杂等特点,这些均可能导致在检测时出现漏检和误检情况^[11]。复杂的特征增加了算法的难度,因此需要更高准确度的检测算法来应对挑战。

为了增强模型对复杂目标特征的提取能力,提高航空发动机叶片损伤检测的准确度,本文在基于改进的 YOLOv7(You Only Look Once v7)网络上提出了一种叶片损伤检测方法 YOLOv7-CC。

1 YOLOv7-CC 损伤检测算法

1.1 YOLOv7-CC 网络介绍

本文在 YOLOv7^[12]基础上进行了优化,提出了 YOLOv7-CC 模型。YOLOv7-CC 模型主要由骨干网络(Backbone)、颈部网络(Neck)和检测头部(Head)3 部分组成,其结构如图 1 所示。

首先,输入的图片通过 Backbone 进行特征提取,

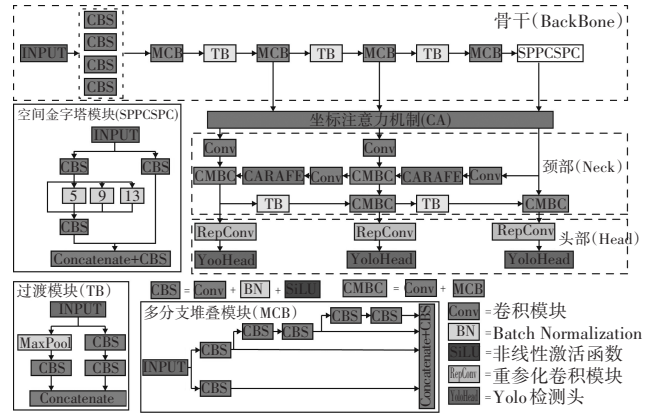


图 1 YOLOv7-CC 模型结构

生成 3 个不同尺寸的特征集合,分别输入坐标注意力机制(Coordinate Attention, CA)注意力模块,以增强网络对感兴趣目标特征的代表能力;其次,特征集合进入 Neck 部分,Neck 利用特征金字塔结构^[13]增加感受野的范围,对不同尺寸的特征层进行特征融合,以便提取更加丰富的特征;最后,经过特征重组,3 个不同尺寸的特征集合分别输入到 Head 中,利用 RepConv 进行重参数化,输入到 YoloHead 中进行目标检测,输出目标的类别信息和置信度分数。

1.2 坐标注意力机制

为了提高检测的效果,采用一种新型的 CA^[14]。

CA 将位置信息嵌入到通道注意力机制中,其结构如图 2 所示。CA 将通道注意力分解为 2 个 1 维特征编码过程来实现,这 2 个过程沿着不同方向聚合特征以捕获长距离依赖关系且保留精确的位置信息。然后,得到的特征图被编码成 1 对方向感知和位置敏感的注意力图,这些图可以互补地应用于输入特征图,以增强感兴趣目标的表示^[14]。

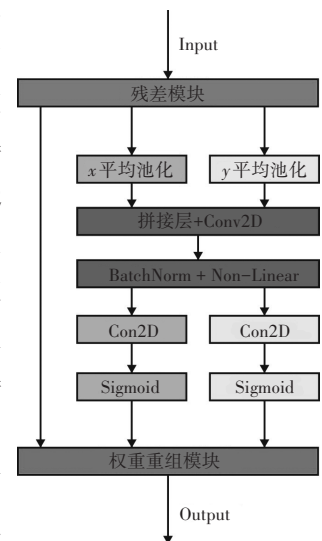


图 2 CA 模块结构

为了避免空间信息全部压缩到通道中,CA 没有使用全局平均池化,而是对输入尺寸为 $C \cdot H \cdot W$ 的特征图分别从 x 方向和 y 方向进行池化,得到 1 对方向感知的特征图 $Z_c^h(h)$ 和 $Z_c^w(w)$

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

$$Z_c^w(w) = \frac{1}{H} \sum_{j=0}^H x_c(j,w) \quad (2)$$

这种处理会捕捉到沿着一个空间方向的长距离依赖关系,并保存沿着另一个空间方向的精确位置信息。

对得到的 2 个特征图进行拼接操作 (Concatenate), 然后通过一个 1×1 的卷积核进行降维, 再通过 Sigmoid 函数激活后得到

$$f = \delta(F_1([Z^h, Z^w])) \quad (3)$$

对得到的 f 沿着空间维度进行 Split 操作分别得到 f^h 和 f^w , 通过一个 1×1 的卷积核进行升维, 结合 Sigmoid 激活函数, 得到注意力权重 g^h 和 g^w

$$g^h = \sigma(F_h(f^h)) \quad (4)$$

$$g^w = \sigma(F_w(f^w)) \quad (5)$$

最后将输入特征图 x 、注意力权重 g^h 和 g^w 相乘, 得到了输出 y

$$y_c(i,j) = x_c(i,j) \cdot g_c^h(i) \cdot g_c^w(j) \quad (6)$$

1.3 CARAFE 上采样

在多层特征重组的过程中, 将小尺寸的特征图经过上采样之后与大尺寸的特征图进行拼接, 以此完成不同层特征的重组。为了提高特征的信息重组效果, 采用轻量级上采样算子 (Content-Aware ReAssembly of Features, CARAFE)^[15]。

CARAFE 是一种用于图像上采样的神经网络模型, 其具体结构如图 3 所示, 旨在通过扩展低分辨率图像的特征来提高图像的细节和质量。传统的上采样方法, 如双线性插值或卷积神经网络的反卷积层, 都是通过位置信息来完成上采样, 并且感受野较小, 通常会导致图像细节的模糊或失真。CARAFE 则通过引入一个自适应的重组过程来解决这个问题, 它能够更好地保留细节。CARAFE 的基本思想是在低分辨率特征图的每个像素位置周围生成一个权重矩阵, 该矩阵用于在高分辨率上采样图像中重新组装特征。

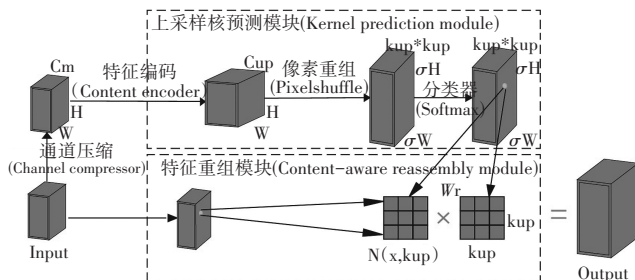


图3 CARAFE 结构

这种组装过程利用低分辨率特征图中的信息来决定高分辨率图像中每个像素的值。

CARAFE 分为 2 个主要模块, 分别是上采样核预测模块 (Kernel Prediction Module, KPM) 和特征重组模块 (Content-Aware Reassembly Module, CARM)^[15]。假设上采样倍率为 σ , 给定一个形状为 $H \cdot W \cdot C$ 的输入特征图, 为了降低后续计算的计算量, 用一个 1×1 卷积对它进行通道压缩 (Channel Compressor), 得到 $H \cdot W \cdot C_m$ 的特征图; 然后通过特征编码操作 (Content Encoder), 通过大小为 $k_{\text{encoder}} \cdot k_{\text{encoder}}$ 的卷积层, 生成大小为 $C_{\text{up}} \cdot H \cdot W$ 的特征图, C_{up} 的大小为

$$C_{\text{up}} = \sigma^2 \cdot k_{\text{up}}^2 \quad (7)$$

再经过像素重组 (Pixelshuffle), 将特征图重组为 $\sigma H \cdot \sigma W \cdot k_{\text{up}}^2$ 的预测上采样核; 最后用 Softmax 函数对上采样核进行归一化。

利用上采样核预测模块生产的预测上采样核, 取出以输入特征图每个位置为中心的 $k_{\text{up}} \cdot k_{\text{up}}$ 区域 N 与预测上采样核模块中大小为 $k_{\text{up}} \cdot k_{\text{up}}$ 的重组内核 W_r 作点积, 以加强特征图的语义信息, 最后得到形状为 $\sigma H \cdot \sigma W \cdot C$ 的输出特征图。其中, k_{encoder} 表示感受野的大小, k_{up} 表示重组内核的大小, 值越大使用的特征图语义信息就越多, 但计算复杂度也会增大。

相比于双线性插值算法, CARAFE 算法在利用空间位置信息的基础上, 还充分利用了语义信息, 增加了特征在经过上采样后的信息丰富程度, 提高了网络对特征的提取能力。

2 试验和结果分析

2.1 数据介绍与数据预处理

本文所使用的损伤图像来自航空公司机务维修处和发动机修理厂等地, 在不同光照条件和背景下通过孔探针和工业相机等设备拍摄获取的发动机叶片图像共 1182 张, 像素大小为 384×288 到 1024×768 。对原始图像进行筛选和分类, 选择裂纹 (Crack)、烧蚀 (Burn) 和涂层脱落 (Missing Coating) 3 种常见的发动机叶片表面损伤制作数据集, 如图 4 所示。




图4 3种损伤类型

采用 Labelme 软件对原始图像进行数据的标注,得到的数据集中3种损伤的数量分布见表1。

表1 损伤类别的数量统计

损伤类别	总计
Crack	285
Burn	662
Missing Coating	884

在 YOLOv7 中,预设的 Anchor 是通过在 COCO 数据集上使用 K-means 算法生成的。然而,对于本文所使用的数据集,这些 Anchor 并不适配。因此,本文使用了二分 K-means 算法^[16]对数据集进行聚类,以获取更符合数据集标记的 Anchor。

K-means 算法将相似的对象归为同一个簇,簇内对象的相似度越高,聚类效果越好。然而,K-means 算法只能收敛到局部最小值,而非全局最小值^[16]。为了提高聚类性能,即降低误差平方和(the Sum of Squares Due To Error, SSE),采用了二分 K-means 算法。该算法将所有锚框作为一个簇,然后将其一分为二,再根据 SSE 的值对簇进行划分,以最大程度地降低 SSE 的值。通过迭代执行此过程,直到达到所需的簇数量为止。 S_{SE} 的表达式为

$$S_{SE} = \sum_{i=1}^n W_i (y_i - \hat{y}_i)^2 \quad (8)$$

式中: S_{SE} 为误差平方和; W_i 为权重值; \hat{y}_i 为该簇所有点的平均值。

二分 K-means 算法在降低 S_{SE} 方面的效果比经典的 K-means 算法更好。二分 K-means 算法生成的锚框更加适配于数据集,从而在网络初始化阶段选择能够更好地符合数据集中真实标记框的尺寸锚框。使用二分 K-means 算法,生成如下锚框(Anchor):(30, 33)、(45, 46)、(49, 105)、(76, 70)、(81, 158)、(133, 110)、(141, 211)、(285, 155)、(273, 396),包含3个不同尺度的 Anchor。

2.2 试验环境介绍

本文所采用的试验环境:操作系统为 Windows 10, CPU 为 i9-12900K 3.20 GH, GPU 为 RTX 3090,

python 版本为 3.7,深度学习框架为 Pytorch, CUDA 版本为 11.6。

在验证算法性能时,所采用的参数设置保持一致。设置 Batch Size 为 16,设置训练迭代次数为最大,即 300;使用 MOSAIC 数据增强,概率设置为 0.5;使用 SGD 优化器,设置 momentum 为 0.937,设置权值衰减为 0.0005;设置初始学习率为 0.01,学习率下降方式设置为 cos;输入图像调整为 640×640。

2.3 模型评价指标

本文采用类别平均精度均值(Mean Average Precision, mAP)作为模型评价指标,mAP 即对3个类别的平均精度(Average Precision, AP)均值求和平均。 P_r 为精确度, R_e 为召回率, F_1 为平衡 F 分数, A_p 值是以 R_e 为横坐标、 P_r 为纵坐标所围成的面积,其计算式为

$$P_r = \frac{T_p}{T_p + F_p} \quad (9)$$

$$R_e = \frac{T_p}{T_p + F_N} \quad (10)$$

$$F_1 = 2 \frac{R_e \cdot P_r}{R_e + P_r} \quad (11)$$

$$A_p = P_r(R_e) d_{Re} \quad (12)$$

式中: T_p 为样本真实类别是正样本,且模型识别的结果为正样本; F_p 为样本真实类别是负样本,但模型识别的结果为正样本; F_N 为样本真实类别是正样本,但模型识别的结果为负样本。

2.4 不同算法试验对比

为了验证本文所改进的 YOLOv7-CC 算法对于航空发动机损伤检测的泛化性和可行性,在相同的训练集、验证集、测试集以及超参数下,与几种主流的算法进行试验对比,包括端到端检测网络(End-to-End Object Detection with Transformers, DETR)^[17],2 阶段算法 Faster R-CNN^[18],1 阶段算法 YOLOv3^[19]、YOLOv5^[20]、YOLOv7、YOLOv8,试验对比结果见表 2。

表2 不同算法模型的试验结果对比

模型	mAP	AP _{Crack}	AP _{Burn}	AP _{Missing Coating}	P_r	R_e	F_1
DETR	68.95	49.73	72.77	84.34	53.61	73.75	62
Faster R-CNN	66.27	36.86	80.49	81.47	48.14	72.69	58
YOLOv3	52.00	6.52	82.03	67.44	62.59	33.83	44
YOLOv5	74.94	55.07	87.57	82.18	88.56	56.31	66
YOLOv7	76.13	59.02	87.79	81.59	81.57	65.47	72
YOLOv8	77.67%	64.40%	86.47%	82.15%	79.62%	70.32%	74%
YOLOv7-CC	83.53%	71.87%	90.65%	88.06%	85.78%	74.81%	79%

从表中可见,相比几种主流的目标检测算法,本文所改进的 YOLOv7-CC 模型在检测精度方面具有明显优势, mAP 值取得最高值, 达到 83.53%, 相较于 DETR、Faster R-CNN、YOLOv3、YOLOv5、YOLOv7、YOLOv8 分别高出 14.58%、17.26%、31.53%、8.59%、7.4%、5.86%。YOLOv7-CC 模型在裂纹、烧蚀和涂层脱落 3 种类别中的 mAP 值均高于其他模型, 分别达到 71.87%、90.65% 和 88.06%, 并且模型精确度达到 85.78%, 召回率达到 74.81%, F_1 分数达到 79%。不同算法检测效果对比如图 5 所示。从图中可见,

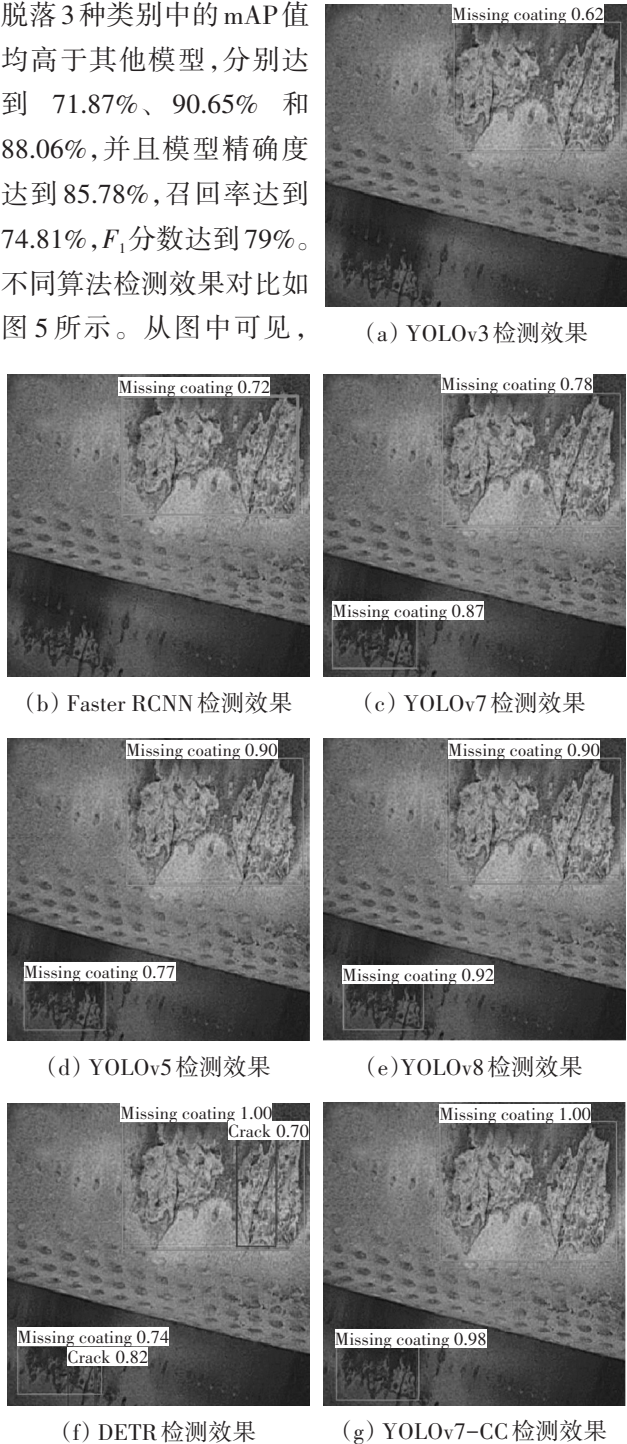


图 5 不同算法检测效果对比
(以缺陷类型加置信度分数的方式呈现)

对于涂层脱落损伤, YOLOv7-CC 模型的检测效果最佳, YOLOv3 和 Faster R-CNN 都存在漏检的情况, DETR 产生了误检的情况, YOLOv7、YOLOv5 以及 YOLOv8 检测结果所得的置信度评分均低于 YOLOv7-CC 模型的。

综上所述, 与其他 6 种模型相比, 本文模型性能优于 DETR、Faster R-CNN 以及其他 YOLO 模型的, 在损伤检测任务中具有显著优势。

2.5 消融试验

为了检验改进的有效性, 本文设计了消融试验来进行验证, 不同算法在统一的硬件设施下进行试验对比, 具体结果见表 3。

表 3 加入不同模块试验结果对比 %

序号	Baseline	二分 K-means	CARAFE CA	mAP	AP _{Crack}	AP _{Burn}	AP _{Missing Coating}
1	√			76.13	59.02	87.79	81.59
2	√	√		79.77	63.10	90.63	85.59
3	√	√	√	82.37	71.47	89.15	86.48
4	√	√		√ 81.40	69.09	87.59	87.52
5	√	√	√	√ 83.53	71.87	90.65	88.06

注: √表示加入了该模块; Baseline 为基准网络。

分析试验结果可知: 使用二分 K-means 算法之后对发动机叶片损伤检测的平均精度提升了 3.64%, 在裂纹、烧蚀和涂层脱落 3 种类别的检测中均有提升, 在裂纹和涂层脱落的平均检测精度提升均超过 4%。这说明二分 K-means 算法可以根据不同目标尺寸生成更好的 Anchor Box, 提高检测精度。

在加入 CARAFE 上采样模块之后的平均精度提升了 2.6%, 在裂纹和涂层脱落的检测上均有提升, 对裂纹的检测提升超过 8%, 但是在烧蚀类别中有所下降。这说明二分 K-means 算法在结合了更大的感受野的情况下, 对小目标进行上采样后, 能够提高模型对小目标的感知能力。

在引入坐标注意力机制之后的平均精度提升了 1.63%, 裂纹和涂层脱落上均有提升, 但是在烧蚀类别中有所下降。这说明坐标注意力机制可以在更大的范围里关注到小目标, 提高模型对小目标的检测精度。

同时采用二分 K-means 算法、CARAFE 上采样模块以及 CA 坐标注意力机制之后, Crack、Burn 和 Missing Coating 3 种类别的检测精度提升均特别明显, 分别为 12.85%、2.86% 和 6.47%。

本文提出的 YOLOv7-CC 模型, 相比原 YOLOv7

模型,在航空发动机叶片损伤检测的平均精度上有较大提升,3种类型的损伤检测平均精度提升了7.4%。

3 结论

(1)使用二分K-means算法可以适应目标尺寸和形状生成更好的Anchor Box,从而使模型的检测头能够更准确地标识出损伤的位置。

(2)采用CARAFE算法获得了更大的感受野,可以更好地提取和传递特征的语义信息,从而提高了模型的检测精度。

(3)使用坐标注意力机制,通过2条路径分别捕获长距离依赖关系和保留精确的位置信息,提高了模型对损伤目标的检测能力。

(4)经过试验对比可知,本文提出的YOLOv7-CC相较于原始的YOLOv7网络,平均检测精度提高了7.4%。表明改进后的模型在航空发动机叶片损伤检测中表现更优。

YOLOv7-CC模型在航空发动机叶片损伤检测方面表现出良好的应用前景。高精度的检测结果可以帮助工程师及时发现和处理叶片损伤问题,确保发动机的正常运行和飞行安全。

参考文献:

- [1] 陈柳金,何法江,吕鸿雁.民用航空发动机叶片损伤研究[J].物流科技,2022,45(1):59-61.
CHEN Liu jin, HE Fajiang, LYU Hongyan. Study on blade damage of civil aviation engine[J]. Logistics Sci-Tech, 2022, 45(1): 59-61. (in Chinese)
- [2] 王佳宇,孟德君,冯冬民,等.鸟撞损伤风扇气动特性仿真[J].航空发动机,2024,50(4):52-57.
WANG Jiayu, MENG Dejun, FENG Dongmin, et al. Numerical study on aerodynamic characteristics of damaged fan subjected to bird strike[J]. Aeroengine, 2024, 50(4): 52-57. (in Chinese)
- [3] 李涛.基于深度学习的孔探缺陷自动检测方法研究[D].四川广汉:中国民用航空飞行学院,2022.
LI Tao. Research on automatic detection method of hole probe defects based on deep learning[D]. Guanghan Sichuan: Civil Aviation Flight University of China, 2022. (in Chinese)
- [4] 史磊,林文俊,黄晨雷,等.前缘缺口型损伤风扇转子叶栅流动特性分析[J].航空发动机,2022,48(5):73-79.
SHI Lei, LIN Wenjun, HUANG Chenlei, et al. Analysis of flow characteristics of fan rotor cascade with leading edge notch damage[J]. Aeroengine, 2022, 48(5): 73-79. (in Chinese)
- [5] Sun Q S, Zeng S G, Liu Y, et al. A new method of feature fusion and its application in image recognition[J]. Pattern Recognition, 2005, 38(12): 2437-2448.
- [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. (in Chinese)
- [7] 李浩.基于图像识别的航空发动机叶片裂纹检测研究[D].成都:电子科技大学,2019.
LI Hao. Research on the blade crack detection of aero-engine based on image recognition[D]. Chengdu: University of Electronic Science and Technology of China, 2019. (in Chinese)
- [8] 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):1615007-1-10.
LI Xin, LI Xiangrong, WANG Cheng, et al. Aero-engine surface defect detection model based on improved YOLOv5[J]. Laser & Optoelectronics Progress, 2023, 60(16): 1615007-1-10. (in Chinese)
- [9] 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):1-7.
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): 1-7. (in Chinese)
- [10] 赵崇林,朱江,胡永进,等.融合注意力和多尺度特征的航空发动机缺陷检测[J].北京航空航天大学学报,2023:1-14.
ZHAO Chonglin, ZHU Jiang, HU Yongjin, et al. Aero-engine defect detection based on fusing attention and multi-scale features[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023: 1-14. (in Chinese)
- [11] 蔡舒好,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 Shuyao, YAN Ziyao. Research on small target damage detection of aero-engine based on improved YOLOv4[J]. Journal of Aerospace Power, 2023, 38(2): 445-452. (in Chinese)
- [12] 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[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver: IEEE, 2023: 7464-7475.
- [13] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//Proceedings of the 13th European Conference on Computer Vision (ECCV). Zurich: IEEE, 2014: 346-361.
- [14] 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. Nashville: IEEE, 2021: 13713-13722.
- [15] Wang J Q, Chen K, Xu R, et al. CARAFE: Content-Aware ReAssembly of FEatures [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 3007-3016.
- [16] 陈平华,陈传瑜.基于满二叉树的二分K-means聚类并行推荐算

- 法[J].计算机工程与科学,2015,37(8):1450-1457.
- CHEN Pinghua, CHEN Chuanyu. A bisecting K means clustering parallel recommendation algorithm based on full binary tree[J]. Computer Engineering & Science, 2015, 37(8): 1450-1457. (in Chinese)
- [17] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[M]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 213-229.
- [18] 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.
- [19] Redmon J, Farhadi A. YOLOv3: An incremental improvement[EB/OL]. [2025-02-12]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [20] Zhu X K, Lyu S C, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Montreal: IEEE Press, 2021: 2778-2788.

(编辑: 刘 静)