

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2024.0024

基于 FDG-YOLO 轻量化模型的航空 发动机损伤检测方法

蔡舒妤*, 何冲

(中国民航大学 航空工程学院, 天津 300300)

摘要: 针对航空发动机损伤检测深度学习模型在嵌入式设备上部署应用的实时性差、检测精度低等问题, 提出一种轻量化航空发动机损伤检测模型 FDG-YOLO。引入 FasterNet 网络重构 YOLOv5 的主干网络, 解决主干网络参数量大的问题; 通过深度可分离卷积改进 YOLOv5 颈部网络的普通卷积, 减少颈部网络的冗余参数; 以 GSConv 为基础构建 GS C3 结构, 替换原模型的 C3 结构, 增强模型的表达能力和感受野; 在航空发动机损伤数据集进行实验验证。结果表明: 与 YOLOv5 原模型相比, 所提 FDG-YOLO 模型参数量降低了 52.5%, 浮点运算速度降低了 66%, 在嵌入式设备上的平均精度均值 (mAP) 达到 89.6%, 高于其他轻量化模型, 帧率达到 61 帧/s, 检测速度适配于发动机损伤图像采集速度, 能够更好地满足航空发动机损伤检测的智能化应用需求。

关键词: 损伤检测; FDG-YOLO 模型; 轻量化; FasterNet 网络; 深度可分离卷积; GSConv 技术

中图分类号: V263.6; TP391.41

文献标志码: A 文章编号: 1001-5965(2026)04-1055-09

航空发动机作为飞机的心脏, 对飞机的安全运行起着决定性作用。航空发动机核心部件长期工作在高温、高压、高转速的环境下, 容易出现裂纹、卷边、材料缺失等损伤^[1]。及早检测和准确评估这些损伤对于确保发动机的可靠性、延长其寿命及避免潜在的灾难性事故具有重要意义。目前, 检测航空发动机内部损伤主要依靠孔探检测技术^[2-4], 但孔探检测严重依赖人员的专业技术和经验且检测效率低。自动化的损伤检测方法能够提高检测效率, 避免人为因素的干扰。

近年来, 深度学习技术发展迅速, 被广泛应用于各种目标检测领域。基于深度学习的目标检测模型主要分为二阶段目标检测模型和一阶段目标检测模型 2 大类。在二阶段目标检测模型中, 文献[5]使

用改进的掩码区域卷积神经网络(mask region-based convolutional neural networks, Mask R-CNN)结合卷积注意力模块实现了航空发动机叶片损伤的分类和像素级分割。文献[6]提出改进的快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)模型对叶片表面损伤进行检测, 实现了叶片表面高精度的自动损伤检测。二阶段模型具有较高的检测精度, 但其检测过程需要先生成候选区域, 再对这些候选区域进行分类和位置回归, 这种顺序性的处理方式导致了较慢的检测速度, 无法满足实时检测的工作需求。

当前, 工业检测对实时性、准确性和智能化技术的需求不断增加, 使得轻量化智能检测模型成为研究的新热点。以 YOLO^[7] 为代表的一阶段目标检

收稿日期: 2024-01-15; 录用日期: 2024-05-09; 网络出版时间: 2024-05-24 10:37

网络出版地址: link.cnki.net/urlid/11.2625.V.20240523.1424.001

基金项目: 中央高校基本科研业务费专项资金(3122023PY11); 复杂零部件智能检测与识别湖北省工程研究中心开放课题资助(IDICP-KF-2024-07)

*通信作者. E-mail: csy0313@163.com

引用格式: 蔡舒妤, 何冲. 基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法 [J]. 北京航空航天大学学报, 2026, 52(4): 1055-1063.

CAI S Y, HE C. Damage detection method for aero-engine based on FDG-YOLO lightweight model [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(4): 1055-1063 (in Chinese).

测模型舍弃了候选区域生成过程, 直接对目标进行分类和位置回归, 因此, 推理速度更快。文献 [8] 以 YOLOv4 作为基础模型, 在路径聚合网络结构中融合浅层特征与深层特征, 同时去除自下而上的路径增强结构, 并优化聚焦损失中的平衡参数, 改进后模型检测精度提升了 2.17%, 检测速度帧率提升了 1.58 帧/s。文献 [9] 对 YOLOv5 模型进行改进, 在主干网络部分嵌入倒置残差模块与倒置残差注意力模块, 并在特征融合部分设计多尺度特征融合模块, 改进后模型参数量减少了 12.8%, 检测精度提升了 4%, 但检测速度帧率下降了 17 帧/s。文献 [10] 使用轻量化改进的 YOLOv4 模型对航空发动机损伤进行检测, 将主干网络替换为 MobileNetv3, 引入深度可分离卷积并加入卷积注意力模块, 在电脑端检测速度提升了 1.6 倍, 但检测精度下降了 3.55%。文献 [11] 对 YOLOv3 模型进行轻量化改进, 提出 NEW-ROI 操作, 并加入通道筛选模块和沙漏金字塔网络, 实验结果表明, 该模型在嵌入式设备上检测的平均精度均值 (mean average precision, mAP) 为 70.6%, 帧率为 21.1 帧/s。

然而, 在嵌入式设备上应用深度学习模型进行航空发动机损伤检测仍然面临着诸多挑战: ①孔探仪视频采集速度帧率能够达到 60 帧/s, 而现有检测精度较高 (90% 左右) 的模型, 在嵌入式设备上的检测速度滞后于孔探仪损伤数据采集速度, 影响损伤检测应用的智能化、自动化; ②现有轻量化模型检测速度能够与损伤数据采集速度相匹配, 但轻量化

改进牺牲了部分模型检测精度。轻量化模型在嵌入式设备上的检测精度较低, 不能满足损伤检测精度要求。

本文针对深度学习模型在航空发动机损伤检测中存在的问题, 提出 FDG-YOLO 轻量化航空发动机损伤检测模型, 该模型能够在嵌入式设备上实现航空发动机损伤快速、准确的自动化检测。

1 FDG-YOLO 轻量化航空发动机损伤检测模型

YOLOv5 是一种基于深度学习的目标检测模型, 其将整个图像作为输入, 并直接在图像中预测目标的边界框和类别概率。YOLOv5 以鲁棒性强、泛化能力强、检测速度快和准确率高而受到广泛关注。本文基于 YOLOv5 模型, 提出一个适用于嵌入式设备的 FDG-YOLO 轻量化航空发动机损伤检测模型, 模型结构如图 1 所示。

FDG-YOLO 主要由主干网络、颈部网络和检测头 3 部分组成。主干网络主要通过卷积操作和快速空间金字塔池化 (spatial pyramid pooling-fast, SPPF)^[12] 从图像中提取特征; 颈部网络通过特征金字塔结构, 将主干网络提取的不同尺度特征进行融合, 以获取更丰富的语义信息, 提高模型的检测性能; 检测头负责生成目标位置、种类和置信度信息, 检测头由 3 个不同尺度的输出层组成, 每个输出层负责检测不同尺寸大小的目标对象, 以提高模型对

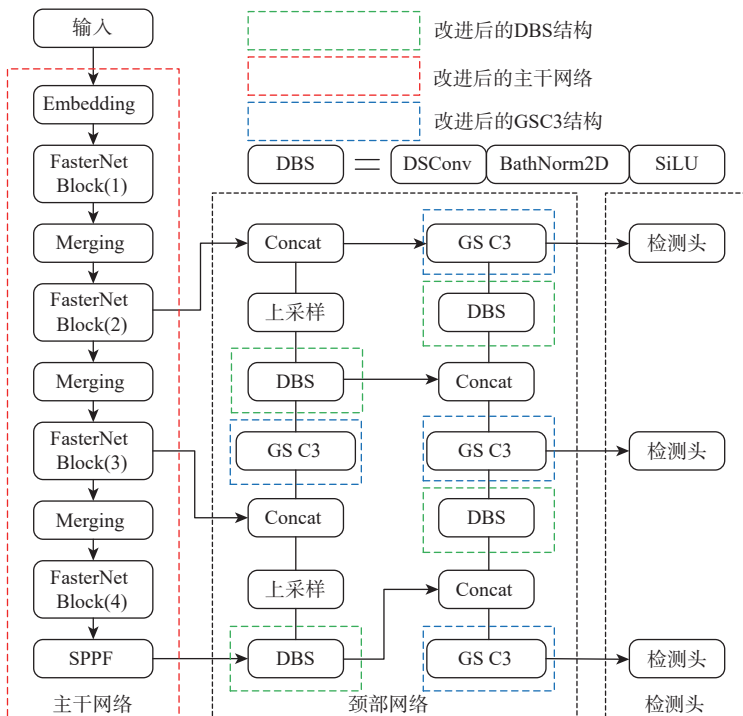


图 1 FDG-YOLO 轻量化航空发动机损伤检测模型

Fig. 1 FDG-YOLO lightweight aero-engine damage detection model

不同尺度目标的检测能力。

相较于 YOLOv5, FDG-YOLO 主要进行了 3 方面改进: ①使用轻量级 FasterNet 网络改进 YOLOv5 模型的主干网络。在保证检测精度的前提下, 减少主干网络的冗余参数, 降低模型复杂度。②将颈部网络中的 CBS(C 表示普通卷积, B 表示 BatchNorm2D, S 表示 SiLU 激活函数)结构替换为 DBS(D 表示 DSConv, B 表示 BatchNorm2D, S 表示 SiLU 激活函数(sigmoid linear unit, SiLU))结构, 实现颈部网络的轻量化。③采用 GSConv 重新设计颈部网络中的 C3(cross stage partial network with 3 convolutions)结构, 形成 GS C3 结构, 提升模型的非线性表达能力, 从而提升模型检测精度。本文 FDG-YOLO 模型的名称来源于上述三方面改进, 其中, F 表示 FasterNet 网络, D 表示 DBS 结构, G 表示 GS C3 结构。

1.1 基于 FasterNet 的主干网络改进

YOLOv5 的主干网络结构复杂, 将其部署在嵌入式设备上检测速度无法满足使用需求。为提升模型检测速度, 对 YOLOv5 的主干网络进行轻量化改进。快速卷积神经网络(faster convolutional neural networks, FasterNet)^[13] 网络结构简单, 对设备算力要求低, 更适合部署在嵌入式设备中。采用 FasterNet 网络改进 YOLOv5 的主干网络, 能够有效降低主干网络的复杂度, 提升模型检测速度。

YOLOv5 的主干网络主要由 5 个 CBS 结构和 4 个 C3 结构组成, 每个 CBS 结构包含 1 个普通卷积, 每个 C3 结构至少包含 5 个普通卷积。普通卷积操作需要在每个输入通道上执行, 且每个通道都需要一组卷积核, 这导致网络参数量大、内存占用高, 不利于在嵌入式设备上应用。FasterNet 网络主要由嵌入层、合并层和 FasterNet 块组成, 其结构简单, 计算

复杂度低, 通过引入 FasterNet 网络, 改进 YOLOv5 的主干网络, 能够有效降低主干网络的参数量。

部分卷积(partial convolution, PConv)只在部分输入通道上使用普通卷积进行空间特征提取, 并保持其余通道不变, 保证了输入和输出具有相同的通道数, 在保留空间信息的同时有效降低了模型的计算复杂度。逐点卷积(pointwise convolution, PWConv)使用 1×1 的卷积核对输入的每个像素点进行卷积, 能够充分利用所有通道的信息。

假设 h 为特征图的高, w 为特征图的宽, k 为卷积核尺寸, c 为通道数, c_p 为 PConv 中进行运算的通道数, r 为 PConv 中 c_p 与 c 的比值。在 $r = c_p/c = 1/4$ 时, PConv 的浮点运算速度为

$$G_{FL} = hwk^2c_p^2 \tag{1}$$

PConv 的内存访问量为

$$P_{con} = hw2c_p + k^2c_p^2 \approx hw2c_p \tag{2}$$

PConv 的浮点运算速度仅为普通卷积的 1/16, 内存访问量仅为普通卷积的 1/4。可以看出, 与普通卷积相比, PConv 有效降低了浮点运算速度和内存访问量, 可通过引入 PConv 实现模型计算复杂度的降低。

FasterNet 块由 1 个 PConv 和 2 个 PWConv 组成, 并仅在中间 PWConv 层后使用批归一化(batch normalization, BN)和激活函数, 在保证特征多样性的同时实现了更低的延迟和更快的推理。PConv 与 PWConv 的组合结构在输入特征图上的有效感受野呈 T 形, 与统一处理的普通卷积相比, 更加强调中心位置信息。融合 PConv 与 PWConv 不仅能够有效降低计算复杂度, 还能提高输出质量。

基于 FasterNet 网络的航空发动机损伤检测模型主干网络改进如图 2 所示, 首先, 引入 FasterNet 网络的嵌入层和合并层, 用于下采样和通道数扩

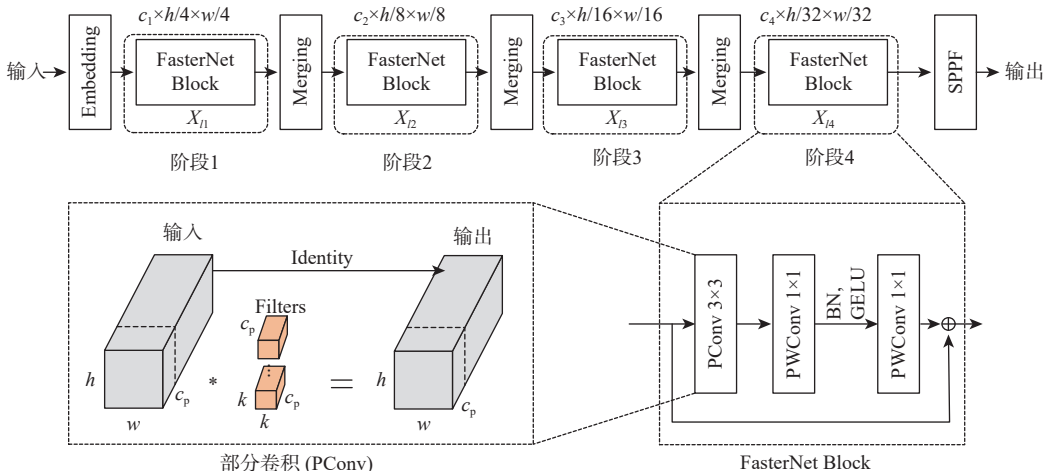


图 2 基于 FasterNet 的损伤检测模型主干网络改进

Fig. 2 Improvement of backbone network of damage detection model based on FasterNet

展;其次,引入 FasterNet 块用于特征提取;最后,保留 YOLOv5 的 SPPF 结构,增强模型对不同尺度目标的感知能力,其中, h 、 w 、 k 、 c 、 c_p 的含义与式(1)和式(2)中对应符号的含义相同。

与 YOLOv5 的主干网络相比,基于 FasterNet 的主干网络不仅降低了计算复杂度,同时充分利用了所有通道的信息,保持了较高的特征提取能力。

1.2 基于深度可分离卷积的颈部网络改进

YOLOv5 颈部网络的 CBS 结构中普通卷积参数量大、内存占用量多,导致模型检测速度慢。为减少颈部网络参数量,提升模型检测速度,对 CBS 结构中的普通卷积进行轻量化改进。深度可分离卷积(depthwise separable convolution, DSConv)^[14]

参数量小、内存占用量少。采用 DSConv 改进 CBS 结构中的普通卷积,能够有效减少颈部网络的参数量,提升模型检测速度。

YOLOv5 颈部网络中的 4 个 CBS 结构包含了 4 个普通卷积,在卷积过程中会产生较多的冗余参数。DSConv 计算效率高、更加适用于轻量化模型的构建。因此,采用 DSConv 改进 YOLOv5 颈部网络中的 CBS 结构。

DSConv 包含 2 个阶段,第 1 个阶段为逐通道卷积,这个阶段对输入的每个通道分别应用一个卷积核进行卷积,且不改变通道数;第 2 阶段为逐点卷积,该阶段对逐通道卷积的结果使用卷积进行通道数的调整。普通卷积和 DSConv 的过程如图 3 所示。




图 3 普通卷积与深度可分离卷积

Fig. 3 Ordinary convolution and depthwise separable convolution

假设 D_F 为输入特征尺寸, C_{in} 为输入通道数, D_H 为输出特征尺寸, C_{out} 为输出通道数, D_K 为卷积核尺寸。普通卷积的计算量 C_1 为

$$C_1 = C_{in} D_K^2 C_{out} D_F^2 \quad (3)$$

DSConv 的计算量 C_2 为

$$C_2 = C_{in} D_K^2 D_F^2 + C_{in} C_{out} D_F^2 \quad (4)$$

DSConv 与普通卷积计算量的比值为

$$\frac{C_2}{C_1} = \frac{C_{in} D_K^2 D_F^2 + C_{in} C_{out} D_F^2}{C_{in} D_K^2 C_{out} D_F^2} = \frac{1}{C_{out}} + \frac{1}{D_K^2} \quad (5)$$

由式(5)可知,DSConv 的计算量远小于普通卷积。

基于 DSConv 的航空发动机损伤检测模型 CBS 结构改进如图 4 所示,图中, CBS 结构由普通卷积、批归一化和 SiLU 激活函数串接组成, C 表示普通卷积 Conv2d, B 表示批归一化 BatchNorm2D, S 表示激活函数 SiLU。DBS 结构由 DSConv、批归一化和 SiLU 激活函数串接组成, D 表示 DSConv, B 表示批归一化 BatchNorm2D, S 表示激活函数 SiLU。将 DSConv 引入到 YOLOv5 的颈部网络中,将 CBS 结构中的普通卷积重构为逐通道卷积和逐点卷积,定义此结构为 DBS。这将有效降低 YOLOv5 颈部网络的参数量和内存占用量,从而提升模型检




图 4 基于 DSConv 的损伤检测模型 CBS 结构改进
Fig. 4 Improvement of CBS structure in damage detection model based on DSConv

测速度。

1.3 基于 GSConv 的颈部网络改进

轻量化改进必将导致模型的检测精度下降。为提升模型的检测精度,对 YOLOv5 颈部网络中的 C3 结构进行优化。新型轻量级卷积 GSConv^[15]的时间复杂度低且非线性表达能力强,因此,以 GSConv 为基础,重新设计 C3 结构,提升模型表达能力与感受野,进而提升模型检测精度。

YOLOv5 模型中的特征图在每次空间(宽度和高度)压缩和通道扩展特征映射时都会导致部分特征信息的丢失。普通卷积最大程度地保留了每个通道之间的隐藏连接,DSConv 则完全切断了这些连接。GSConv 通过引入 shuffle 混合策略,将普通卷积提取的信息通过在不同通道上均匀交换局部

特征信息而完全混合到 DSCnv 的输出中, 尽可能保留了通道间的隐藏连接, 在增强了非线性表达能力的时候, 保持较低的时间复杂度, 使 GSConv 在轻

量级模型中的优势更加明显。GSConv 的结构如图 5 所示。其中, C_{in} 表示输入通道数, C_{out} 表示输出通道数。




图 5 GSConv 结构

Fig. 5 GSConv structure

假设 W 和 H 为输出特征图的宽和高, $K_1 \times K_2$ 为卷积核大小, C_{in} 为输入特征图的通道数, C_{out} 为输出特征图的通道数。普通卷积、DSCnv 和 GSConv 的时间复杂度分别为

$$T_{SC} \sim O(W \times H \times K_1 \times K_2 \times C_{in} \times C_{out}) \quad (6)$$

$$T_{DSC} \sim O(W \times H \times K_1 \times K_2 \times C_{out}) \quad (7)$$

$$T_{GSC} \sim O \left[W \times H \times K_1 \times K_2 \times \frac{C_{out}}{2} \times (C_{in} + 1) \right] \quad (8)$$

可以看出, GSConv 的时间复杂度介于普通卷积和 DSCnv 之间。

以 GSConv 为基础, 重构 YOLOv5 颈部网络的 C3 结构, 称此结构为 GS C3, 如图 6 所示, 其中, CBS 结构的 C 表示普通卷积, B 表示批归一化, S 表示 SiLU 激活函数; GBS 结构的 G 表示 GSConv, B 表

示批归一化, S 表示 SiLU 激活函数。GS C3 结构将输入分为两路, 一路经过包含 N 个瓶颈模块 (BottleNeck module, BottleNeck) 的路径进行卷积, 另一路经过 CBS 结构, 然后, 将两路的输出进行连接操作 (concatenation, Concat) 结合。BottleNeck 模块也将输入分为两路, 一路经过包含 2 个 GBS 结构的路径, 另一路经过一个 CBS 结构, 然后, 将两路的输出结果相加。这种构建方式能够使不同阶段的特征图之间进行信息的交换和融合, 增加模型的表达能力和感受野。

以 GSConv 为基础构建的 GS C3 结构能够在保持较低时间复杂度的同时提升非线性表达能力。因此, 采用 GS C3 结构替换 YOLOv5 颈部网络中的 C3 结构。

2 基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法流程

基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法流程如下:

1) 航空发动机损伤数据集构建。从航空发动机孔探报告中收集损伤图像, 进行图像增广, 并对损伤位置和种类进行标注, 获得对应的标注文件, 最后, 将损伤图像及对应的标注文件划分为训练集、验证集和测试集。

2) 航空发动机损伤检测模型构建。通过引入 FasterNet 网络、DBS 结构和 GS C3 结构对 YOLOv5 模型进行改进, 构建 FDG-YOLO 轻量化航空发动机损伤检测模型。

3) 模型训练。将训练集和验证集导入 FDG-YOLO 轻量化航空发动机损伤检测模型, 并设置模型的训练参数进行训练。训练集用于 FDG-YOLO 轻量化模型的训练, 验证集用于评估每轮的训练结果, 最终得到 FDG-YOLO 轻量化模型的最优权重文件。

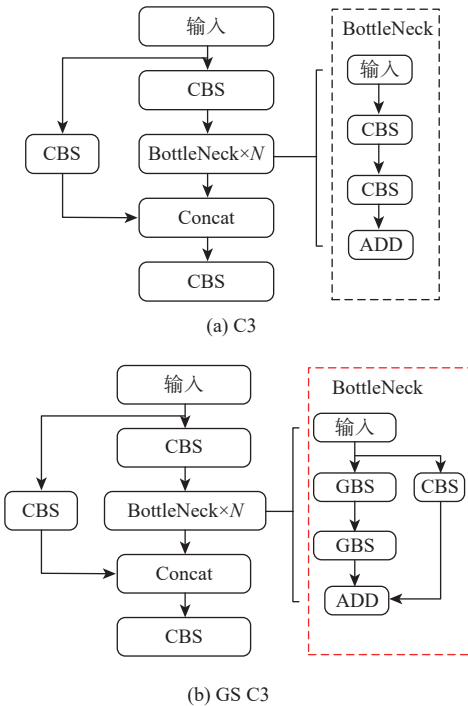


图 6 C3 结构和 GS C3 结构

Fig. 6 C3 structure and GS C3 structure

4) 性能测试。将测试集导入 FDG-YOLO 轻量化航空发动机损伤检测模型,并使用最优权重文件进行推理预测,获得 FDG-YOLO 轻量化模型的性能参数。

5) 部署应用。将 FDG-YOLO 轻量化航空发动

机损伤检测模型部署到嵌入式设备上,对航空发动机损伤图像或视频进行检测,实现对航空发动机损伤的自动化检测。

基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法具体流程如图 7 所示。

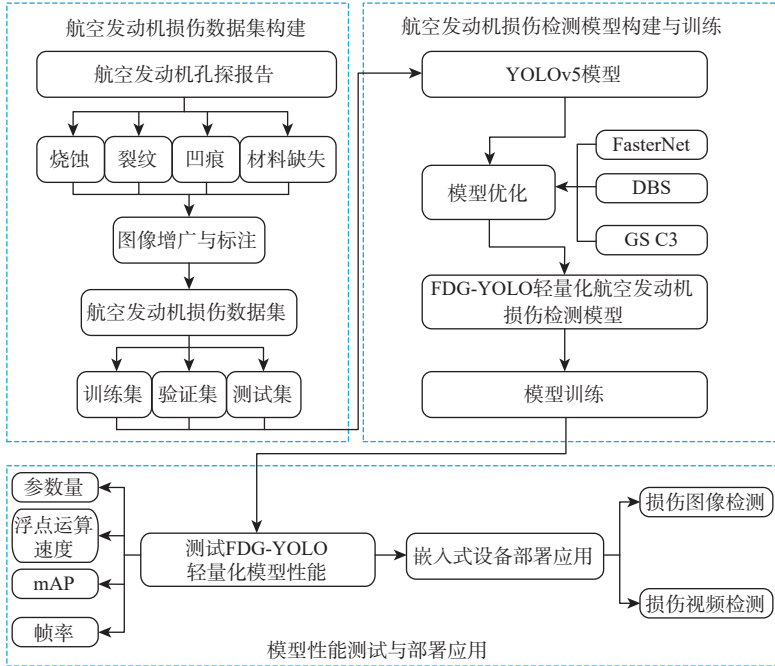


图 7 基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法流程

Fig. 7 Workflow of aero-engine damage detection method based on FDG-YOLO lightweight model

3 实验及结果分析

3.1 数据集与实验环境

通过某航空公司的发动机孔探报告制作数据集,共收集了 2455 幅损伤图像,包含烧蚀、凹痕、裂纹和材料缺失 4 种损伤,部分损伤图像如图 8 所示。随机选择其中 445 幅损伤图像作为测试集,对剩余的损伤图像使用旋转、缩放和添加噪声的方法进行图像增广。增广后的数据集共有 6000 幅损伤




图 8 航空发动机损伤图像

Fig. 8 Aero-engine damage images

图像,将数据集按 8:2 的比例划分为训练集和验证集,数据集样本分布如表 1 所示。

表 1 数据集样本分布

Table 1		Sample distribution of dataset		
损伤类型	训练集	验证集	测试集	幅
烧蚀	1360	343	125	
凹痕	857	140	85	
裂纹	827	136	85	
材料缺失	1756	581	150	

电脑端实验环境:处理器为 Intel Core i7-13700F 2.10 GHz,显卡为 NVIDIA GeForce RTX 4060Ti, 8 GB 内存。嵌入式设备为 Jetson Orin Nano, 8 GB 内存, TensorRT 加速。本文训练设置批量大小为 16,初始学习率设置为 0.01,选用随机梯度下降(stochastic gradient descent, SGD)优化器,动量参数设为 0.937,总迭代次数设为 200。

3.2 评价指标

为验证模型的性能,选择 mAP、参数量、浮点运算速度和帧率作为模型的评价指标。mAP 表示在交集与并集之比(intersection over union, IoU)阈值为 0.5 时,所有损伤类别平均精度的平均值,

AP表示以召回率 R 和准确率 P 为坐标轴形成的 P - R 曲线下的面积;召回率、准确率、平均精度和平均精度均值的计算式分别为

$$R = \frac{T_p}{T_p + F_N} \quad (9)$$

$$P = \frac{T_p}{T_p + F_p} \quad (10)$$

$$A_p = \int_0^1 P(R) dR \quad (11)$$

$$m_{AP} = \sum_{i=1}^c A_p / c' \quad (12)$$

式中: T_p 表示正样本预测正确的数量; F_N 表示正样本预测错误的数量; F_p 表示负样本预测错误的数量; c' 表示类别总数。

3.3 实验结果分析

3.3.1 消融实验结果分析

为验证本文方法的有效性,设计以下消融实验对本文方法进行评估,消融实验结果如表2所示。实验a为YOLOv5模型在航空发动机损伤数据集上进行训练和测试;实验b为YOLOv5使用FasterNet作为主干特征提取网络;实验c为YOLOv5使用FasterNet作为主干网络,同时在颈部网络中引入DBS结构;实验d为最终改进的FDG-YOLO模型,在实验c的基础上加入GS C3结构。

表2 消融实验结果

Table 2 Ablation experimental results

模型	参数量	mAP/%	浮点运算速度/ 10^9 s ⁻¹	帧率/(帧·s ⁻¹)
实验a	20 865 057	92.0	47.9	92
实验b	11 654 613	88.3	22.5	139
实验c	9 633 429	88.1	20.0	150
实验d	9 909 621	90.5	16.3	142

从实验a与实验b的对比可知,将主干网络替换为FasterNet后,mAP从92%下降到了88.3%,下降了3.7%,这是由于轻量化导致了模型的特征提取能力下降,但加入FasterNet后,模型的参数量和浮点运算速度都仅为YOLOv5的50%左右,帧率也提升了51%。

从实验b与实验c的对比可知,进一步加入深度可分离卷积后,在mAP几乎不变的同时,参数量和浮点运算速度进一步降低,帧率进一步提升。经过2种轻量化改进,在模型参数量和浮点运算速度都显著降低的同时也导致了检测精度的下降。

从实验c与实验d的对比可知,加入GS C3结构后,在参数量略微增加、帧率略微降低的同时,mAP从88.1%提升到90.5%,提升了2.4%,浮点运

算速度下降了18.5%。

综合来看,轻量化改进后的FDG-YOLO模型以极小mAP损失,使模型参数量减少了52.5%,浮点运算速度减少了66%,帧率提升了54.3%。与原模型相比,FDG-YOLO模型对设备算力要求更低,更适合于部署到嵌入式设备上。

3.3.2 不同模型检测性能分析

为验证本文模型的检测性能,将FDG-YOLO轻量化模型与轻量化模型YOLOv3-tiny^[16]和YOLOv7-tiny^[17]在相同电脑端实验环境下进行对比实验,不同模型检测性能如表3所示。

表3 不同模型检测性能对比

Table 3 Comparison of detection performance of different models

模型	参数量	mAP/%	浮点运算速度/ 10^9 s ⁻¹	帧率/(帧·s ⁻¹)
YOLOv3-tiny	8 673 622	86.7	12.9	159
YOLOv7-tiny	6 014 737	89.5	13.0	63
FDG-YOLO	9 909 621	90.5	16.3	142

由表3可知,FDG-YOLO、YOLOv3-tiny和YOLOv7-tiny的参数量与浮点运算速度相差不大,处于同一水平。在检测精度方面,FDG-YOLO的mAP达到90.5%,比YOLOv3-tiny高3.8%,比YOLOv7-tiny高1%;在检测速度方面,FDG-YOLO的帧率达到142,是YOLOv7-tiny的2.2倍,比YOLOv3-tiny低17。综合来看,本文FDG-YOLO模型兼顾了检测速度与检测精度,性能优于其他模型。

为更加直观地对比FDG-YOLO轻量化模型与轻量化模型YOLOv3-tiny和YOLOv7-tiny对航空发动机损伤的检测效果,从测试集中选择烧蚀、凹痕、裂纹和材料缺失4类典型损伤进行检测,不同模型的检测结果如图9所示。

由图9可知,对烧蚀损伤检测时,YOLOv3-tiny对1个损伤产生2个预测框,将连续区域的损伤分割为2部分,导致模型对烧蚀损伤计数不准;YOLOv7-tiny的预测框未能将损伤区域完全覆盖;FDG-YOLO模型的预测框精准覆盖了损伤区域。

对凹痕损伤检测时,YOLOv3-tiny出现漏检;YOLOv7-tiny出现误检,将图像左下角孔探仪的标志误检为凹痕损伤;FDG-YOLO模型没有出现漏检、误检,精准的检测出了图像中的凹痕损伤。

对裂纹损伤检测时,YOLOv3-tiny和YOLOv7-tiny都对1个损伤产生了2个预测框,将1条裂纹识别为2个,导致模型对裂纹损伤计数不准;FDG-YOLO模型精准检测出了图像中的裂纹损伤。

对材料缺失损伤检测时,YOLOv3-tiny和YOLOv7-tiny都出现了不同程度的漏检;FDG-




图9 不同模型检测结果对比

Fig. 9 Comparison of detection results of different models

YOLO模型没有出现漏检,精准检测出了图像中所有的材料缺失损伤。

综上,本文FDG-YOLO模型降低了漏检、误检发生的概率,检测准确度更高,检测效果优于其他检测模型。

3.3.3 嵌入式设备部署实验结果分析

在同一嵌入式设备Jetson Orin Nano上设计以下对比实验,验证不同模型在嵌入式设备上对航空发动机损伤的检测性能,嵌入式设备上不同模型检测性能如表4所示。

表4 嵌入式设备上不同模型检测性能对比

Table 4 Comparison of detection performance of different models on embedded devices

模型	mAP/%	帧率/(帧·s ⁻¹)
YOLOv3-tiny	85.4	76
YOLOv5	86.7	75
FDG-YOLO	89.6	61

由表4可知, YOLOv3-tiny模型和YOLOv5模型帧率达到70帧/s以上,检测速度满足应用需求,但mAP只有85%左右,相对较低。FDG-YOLO模型帧率达到61帧/s,能够与孔探仪视频数据采集速度相匹配,同时, mAP达到89.6%,比YOLOv3-tiny模型高4.2%,比YOLOv5模型高2.9%。综合来看,本文FDG-YOLO模型在嵌入式设备上保证检

测速度与孔探仪视频采集速度相匹配的同时保持了较高的检测精度,综合检测性能优于其他检测模型。

4 结论

本文为实现在嵌入式设备上对航空发动机损伤进行快速、准确检测,提出FDG-YOLO轻量化航空发动机损伤检测模型,可以得到以下结论:

1) 在模型复杂度与检测速度方面,通过加入FasterNet网络和DBS结构使模型参数量显著下降、复杂度显著降低、检测速度显著提升。FDG-YOLO模型在嵌入式设备上帧率达到61帧/s,使模型检测速度与损伤数据获取速度相匹配,满足在嵌入式设备上对航空发动机损伤检测对检测速度的需求。

2) 在检测准确度方面,通过加入GS C3结构,提升了颈部网络的非线性表达能力。FDG-YOLO模型在电脑端mAP为90.5%,在嵌入式设备上mAP为89.6%,高于其他轻量化目标检测模型。FDG-YOLO模型在兼顾检测速度的同时保持了较高的检测精度。

3) 本文FDG-YOLO轻量化航空发动机损伤检测模型,该模型能够在嵌入式设备上实现航空发动机损伤自动化检测,有利于提升航空发动机孔探检测的智能化水平。

参考文献 (References)

- [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.
GUAN S, QU P S, DONG W H, et al. Intelligent endoscope fault diagnose of aero engine[J]. Journal of Liaoning Technical University (Natural Science), 2009, 28(6): 981-984(in Chinese).
- [2] 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(15): 96-98.
XIAO B R. Application of borescope inspection technology in aero-engine maintenance[J]. China High Technology, 2019(15): 96-98 (in Chinese).
- [3] 刘文凯, 陈宸, 袁传金. 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.
LIU W K, CHEN C, YUAN C J. Application of borescope inspection in aero-engine maintenance[J]. Science and Technology Information, 2016, 14(7): 43-44 (in Chinese).
- [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, 48(6): 94-96.
YU H. Borescope and its application in the maintenance of aeroengine[J]. Aeronautical Manufacturing Technology, 2005, 48(6): 94-96 (in Chinese).
- [5] HE W F, LI C Z, NIE X F, et al. Recognition and detection of aero-engine blade damage based on improved cascade mask R-CNN[J]. Applied Optics, 2021, 60(17): 5124-5133.
- [6] LIU Y X, WU D B, LIANG J W, et al. Aeroengine blade surface

- defect detection system based on improved faster RCNN[J]. International Journal of Intelligent Systems, 2023, 2023(1): 1992415.
- [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. Piscataway: IEEE Press, 2016: 779-788.
- [8] 李彬, 汪诚, 丁相玉, 等. 改进 YOLOv4 的表面缺陷检测算法[J]. 北京航空航天大学学报, 2023, 49(3): 710-717.
- LI B, WANG C, DING X Y, et al. Surface defect detection algorithm based on improved YOLOv4[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 710-717(in Chinese).
- [9] 刘树东, 刘业辉, 孙叶美, 等. 基于倒置残差注意力的无人机航拍图像小目标检测[J]. 北京航空航天大学学报, 2023, 49(3): 514-524.
- LIU S D, LIU Y H, SUN Y M, et al. Small object detection in UAV aerial images based on inverted residual attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 514-524(in Chinese).
- [10] 蔡舒好, 闫子砚, 师利中. 基于改进 YOLOv4 的航空发动机损伤检测方法[J]. 现代制造工程, 2023(2): 99-108.
- CAI S Y, YAN Z Y, SHI L Z. Aeroengine damage detection method based on improved YOLOv4[J]. Modern Manufacturing Engineering, 2023(2): 99-108(in Chinese).
- [11] 张雯婷. 基于嵌入式图像目标检测系统的研究[D]. 沈阳: 沈阳航空航天大学, 2019: 45-59.
- ZHANG W T. Research on object detection system for embedded platforms[D]. Shenyang: Shenyang Aerospace University, 2019: 45-59 (in Chinese).
- [12] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//Proceedings of the Computer Vision-ECCV. Berlin: Springer, 2014: 346-361.
- [13] CHEN J R, KAO S H, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 12021-12031.
- [14] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 1800-1807.
- [15] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[EB/OL]. (2022-06-06)[2024-01-10]. <https://arxiv.org/abs/2206.02424>.
- [16] REDMON J, FARHADI A. YOLO9000: better, faster, stronger. [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 6517-6525.
- [17] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 7464-7475.

Damage detection method for aero-engine based on FDG-YOLO lightweight model

CAI Shuyu*, HE Chong

(College of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In response to the issues of poor real-time performance and low detection accuracy when deploying deep learning models for aero-engine damage detection on embedded devices, this paper introduces the FDG-YOLO lightweight model for aviation engine damage detection. Firstly, FasterNet was introduced to restructure the backbone network of YOLOv5, addressing the issue of large parameter count in the backbone network. Second, depth-wise separable convolutions were used to eliminate superfluous parameters in the neck network of YOLOv5 by improving ordinary convolutions. In order to improve the model's expressive power and receptive field, the original C3 structure was replaced with the GS C3 structure, which was built concurrently based on GSConv. Finally, experiments were conducted and validated on an aviation engine damage dataset. In the end, experiments were conducted and validated on an aero-engine damage dataset. The findings show that the FDG-YOLO model reduces the number of parameters by 52.5% and the giga floating-point operations per second by 66% when compared to the original model. On embedded devices, the mean average precision (mAP) reaches 89.6%, surpassing other lightweight models. The frames per second achieves 61, making the detection speed suitable for the engine damage image acquisition rate. It more effectively satisfies aero-engine damage detection's intelligent application criteria.

Keywords: damage detection; FDG-YOLO models; lightweight; FasterNet network; depthwise separable convolution; GSConv technique

Received: 2024-01-15; Accepted: 2024-05-09; Published Online: 2024-05-24 10:37

URL: link.cnki.net/urlid/11.2625.V.20240523.1424.001

Foundation items: The Fundamental Research Funds for the Central Universities (3122023PY11); Open Projects funded by Hubei Engineering Research Center for Intelligent Detection and Identification of Complex Parts (IDICP-KF-2024-07)

* Corresponding author. E-mail: csy0313@163.com