

文章编号: 1000-8055(2023)08-1857-08

doi: 10.13224/j.cnki.jasp.20210381

基于深度学习的航空发动机内部损伤 实时检测方法

何超¹, 陈果², 王雨薇¹

(1. 南京航空航天大学 民航学院, 南京 211106;
2. 南京航空航天大学 通用航空与飞行学院, 南京 213300)

摘 要: 针对航空发动机内部损伤实时检测问题, 提出了基于 YOLOv4 框架下的目标识别网络模型, 该网络模型具有检测精确度高, 推理速度快的优点, 实现了发动机内部损伤的实时检测。在具体实施过程中, 该方法首先对不同损伤类型进行分类并对损伤位置进行标注, 将图片与之对应的标注导入到改进网络中进行训练并得到对应的检测模型, 最后, 基于训练好的模型, 对图片和视频流上的损伤进行实时检测。利用 Pascal VOC (visual object classes) 标准数据集与真实的航空发动机孔探图像数据集进行方法验证, 结果表明所提出的目标识别网络在保证准确率的前提下每秒检测的帧率相比原目标识别网络提升了 23.7% 以上。为解决孔探损伤检测中人为因素导致的检测结果不准确与检测效率低下等问题提供了有效途径, 具有很强的工程实用价值。

关键词: 航空发动机损伤; 孔探检测; 深度学习; 损伤检测; YOLOv4 网络模型
中图分类号: V263.6 文献标志码: A

Real-time detection method of aero-engine internal damage based on deep learning

HE Chao¹, CHEN Guo², WANG Yuwei¹

(1. College of Civil Aviation,
Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;
2. College of General Aviation and Flight,
Nanjing University of Aeronautics and Astronautics, Nanjing 213300, China)

Abstract: In view of the problem in real-time detection of aero-engine internal damage, an object detection network model based on the YOLOv4 framework was proposed. With advantages of high detection accuracy and fast reasoning speed, this network model realized real-time detection of engine internal damage. In specific implementation process, the method first classified different damage types and annotated the damage location, and then imported the image and its corresponding annotations into the improved network for training to obtain the corresponding detection model. Finally, based on the trained model, real-time detection of damage on pictures and video streams was performed. The Pascal VOC (visual object classes) standard data set and the real aero-engine borescope image data set were used to verify the method. The results showed that the proposed object detection network can improve the frame rate of detection per second more than 23.7% on the premise of ensuring accuracy compared with the original object detection network. The method could provide an effective way to solve the problems of

收稿日期: 2021-07-20

基金项目: 国家科技重大专项(2017-IV-0008-0045, J2019-IV-004-0071)

作者简介: 何超(1998—), 男, 硕士生, 主要研究方向为深度学习。E-mail: agatsumazenitsu@nuaa.edu.cn

引用格式: 何超, 陈果, 王雨薇. 基于深度学习的航空发动机内部损伤实时检测方法[J]. 航空动力学报, 2023, 38(8): 1857-1864. HE Chao, CHEN Guo, WANG Yuwei. Real-time detection method of aero-engine internal damage based on deep learning[J]. Journal of Aerospace Power, 2023, 38(8): 1857-1864.

inaccurate detection results and low detection efficiency caused by human factors in borescope damage detection, showing strong engineering practical value.

Keywords: aero-engine damage; borescope detection; deep learning; damage detection; YOLOv4 network model

高效、高质量的飞机维护对于保障飞行安全至关重要^[1-2]。在飞机运行过程中,作为其心脏的航空发动机工作在高速、高温、高压的恶劣环境,其叶片受外物打伤、转静碰摩、燃烧、腐蚀等,极易产生各种故障或损伤,如叶片磨损、卷曲、裂纹等^[3-4]。目前,孔探技术作为窥视和检测航空发动机内部损伤状况的重要检测手段,在航空维修工作中具有举足轻重的地位,孔探技术就是将内部状况以光学图像的形式传递,工作人员观察、判断光学图像,以此来评估航空发动机内部的状况,即便对于部分难以拆卸或者可达性差的部件也可以通过以上方法完成检测^[5-7]。

孔探检测技术和人工检测的配合可以较为快速地判断航空发动机内部的故障缺陷。但是人工检测依赖于工作人员的检测经验以及操作方式,不同工作人员主观因素的差别可能导致检测结果相距甚远^[8-9]。随着计算机视觉的发展与图像处理水平的提高,人工检测环节逐渐被图像处理技术替代。李华等^[10]提出了一种航空发动机裂纹的检测方法,可以测量孔探图像中裂纹的尺寸,但该方法推理速度较慢,无法完成实时检测,该方法检测对象单一,仅能对航空发动机内部裂纹进行检测。旷可嘉^[11]使用了 Faster R-CNN(region-based convolutional neural networks)和 SSD(single shot multi-box detector)等卷积神经网络模型对航空发动机三类缺陷进行训练,所得到模型测试的平均检验精确度为 89.36%,平均检测帧率为 29.8(一般检测帧率达到 30 以上可以认为达到了实时检测),实现了缺陷的实时识别与检测,但此方法中的 SSD300 模型训练时间长,并且该模型的检测效率较低,消耗大量 GPU(graphics processing unit)且同一时间内只检测一种缺陷的情况下才能达到实时检测。赵焯^[12]使用优化的残差网络,采取迁移学习的方式,所训练出的优化模型对叶片损伤的总识别率达到了 94.17%,此方法的识别率较高,并且能对多种损伤进行检测分类,但检测效率较低,无法满足实时检测。李龙浦^[13]以 Faster R-CNN 与 YOLOv3 两个目标识别网络为基础进行改进优化,实现了对与航空发动机四类损伤的识别检测,其中 YOLOv3 网络改进

后的 YOLOv3-Dense,相比原本的目标识别网络精确度从 87.2% 提升到了 90.5%,但是速度相较原本模型有所下降,检测帧率从 34 下降到了 29,其中的 YOLOv3 模型在推理速度与平均准确度两方面已被其改进版本 YOLOv4 模型超过。

本文针对上述研究所存在的问题,对于航空发动机孔探图像中的损伤图像,基于改进的 YOLOv4 目标识别网络模型,提出了一种能够实时且高精度检测航空发动机内部损伤图像的方法,并利用实际孔探图像进行了方法验证。

1 航空发动机损伤图像获取

使用孔探仪作为获取设备,对航空发动机内部进行图片拍摄或视频拍摄,获得某航空发动机内部损伤的图片。孔探仪拍摄的图片可以直接选择其中包含损伤的图片作为损伤图像数据;拍摄的视频可以分解为多张图片,选择其中包含损伤的图片作为损伤图像数据。

航空发动机的叶片工作环境恶劣,通常在高温、高压的状态下工作,叶片主要损伤包括掉块、裂纹、腐蚀等。图 1(a)为某型航空发动机的掉块图片,图 1(b)为裂纹图片,图 1(c)为腐蚀图片。



图 1 航空发动机典型损伤图片

Fig. 1 Typical damage picture of aero-engine

2 基于深度学习的航空发动机损伤识别方法流程

使用孔探设备获取航空发动机损伤图像数据后,首先需要对损伤图像进行图像数据增强,常见的图像增强方法有拉伸、旋转、缩放、平移、噪声等,再将所有图片的损伤部位和损伤类别进行人工标注,获得所有图片对应的标注文件,将所有图片以及对应的标注文件分为训练集、测试集,将其中的训练集导入目标检测网络训练。

将孔探损伤图像的训练集导入不同的目标检测网络训练后, 得到不同的目标检测模型。使用测试集分别测试模型的准确率(mean average pre-

cision, mAP) 与推理速度(frames per second, FPS), 比较准确率与推理速度, 选择最优的模型即可, 流程图如图 2 所示。

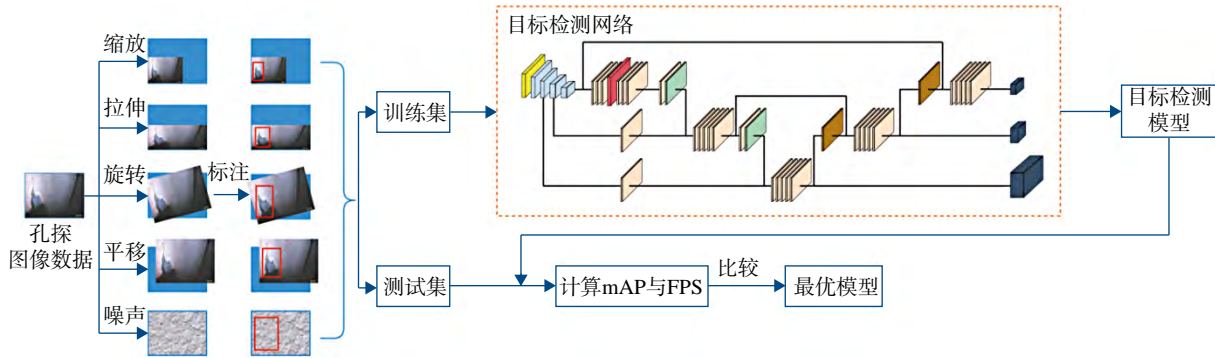


图 2 航空发动机损伤检测模型训练流程

Fig. 2 Aero-engine damage detection model training flowchart

3 目标检测算法

3.1 VoVNetv2 网络

VoVNet 网络基于 DenseNet 网络结构优化而来, DenseNet 最主要的一个问题就是密集连接过重, 每层都会聚合前面层的特征^[14], 这种将会造成特征冗余。这种信息冗余就是 VoVNet 优化的方向, 据此提出了 OSA(one-shot aggregation) 模块, 如图 3 所示, 这个改动解决了 DenseNet 前面所述的问题。




图 3 OSA 模块

Fig. 3 OSA module

图 3 所示为输入依次经过 5 个相同的 3×3 卷积块, 每进行一个卷积块后将其输出保留, 经过第 1 个卷积块后为输出 1, 第 2 个则为输出 2, 以此类推, 最终将输入与保留的 5 个输出堆叠, 再经过一个 1×1 的卷积块后输出最终结果。

Lee 等^[15] 在文中的实验结果表明, 将 VoVNet 作为 DSOD(deeply supervised object detectors) 检测模型的骨干网络, 相比 DenseNet 作为主干网络的推理速度提升了一倍, 并且准确率更高; 在

Mask R-CNN 中主干网络使用 VoVNet 相比 Res-Net^[16] 准确率更高, 在此基础上推理时间稍低, 说明 VoVNet 继承了 DenseNet 的准确度优势并且计算更高效。VoVNet-39 的详细结构如表 1 所示, 表中 s 为步长。

Lee 等^[17] 在 CenterMask 实例分割模型一文中提出了基于 VoVNet 的改进骨干网络即 VoVNetv2 结构, 如图 4 所示。

改进后的 OSA 模块前半部分与图 3 中 OSA 模块相同, 将图 3 的最终输出作为输出 6, 输出 6 经过全局平均池化、全连接层与 Sigmoid 激活函数后与自身相乘得到输出 7, 将输出 7 与输入直接相加获得改进后 OSA 模块的最终输出。

改进的 OSA 模块直接将输入加到输出上, 形成短路连接, 进而能够训练更深的 VoVNet 网络; 改进的另一个点是在于在最后的特征层加上 eSE(effective squeeze and excitation) 模块进一步增强特征, 原 SE(squeeze and excitation) 模块包含两个全连接层, 中间的全连接层的主要目的是减少通道数, 这种方式会丢失部分信息, 而 eSE 模块仅使用一个全连接层, 维护了通道信息, 进而提高性能。VoVNetv2-39 的结构即在原 VoVNet-39 网络结构上进行上述改进。

3.2 YOLOv4-VoVNetv2-39 网络结构

网络 YOLOv4-VoVNetv2-39 的整体结构图如图 5 所示。将原骨干网络(backbone)的 Csp-DarkNet-53 网络结构替换成为 VoVNetv2-39 结构, 加强特征提取网络为 PANet(path aggregation network)网络^[18]。该网络将孔探图片划分为多个网

表 1 VoVNet-39 网络结构
Table 1 VoVNet-39 network structure

阶段	VoVNet-39	输出
初始阶段 1	3 × 3 卷积块, 64 通道数, s=2 3 × 3 卷积块, 64 通道数, s=1 3 × 3 卷积块, 128 通道数, s=1	208 × 208 × 128
OSA 模块阶段 2	[3 × 3 卷积块, 128 通道数, × 5 堆叠 1 × 1 卷积块, 256 通道数] × 1	104 × 104 × 256
OSA 模块阶段 3	[3 × 3 卷积块, 160 通道数, × 5 堆叠 1 × 1 卷积块, 512 通道数] × 1	52 × 52 × 512
OSA 模块阶段 4	[3 × 3 卷积块, 192 通道数, × 5 堆叠 1 × 1 卷积块, 768 通道数] × 2	26 × 26 × 768
OSA 模块阶段 5	[3 × 3 卷积块, 224 通道数, × 5 堆叠 1 × 1 卷积块, 1024 通道数] × 2	13 × 13 × 1024

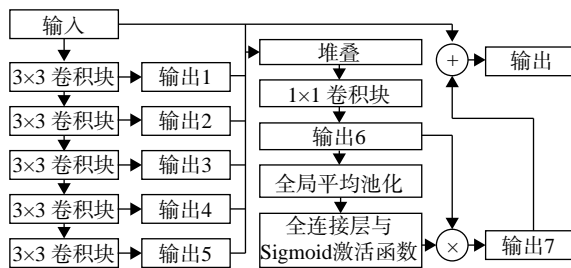


图 4 改进后的 OSA 模块
Fig. 4 Improved OSA module

格, 在每个网格上生成先验框, 通过先验框预测孔探图像中损伤的类别、置信度与坐标, 通过坐标的数值计算孔探图像损伤的位置^[19]。

首先输入的孔探图像统一转化为 416 × 416 的大小, 随后传入到骨干网络 VoVNetv2-39 中, 骨干网络主要包含 1 × 1 与 3 × 3 的卷积层, 进行卷积、合并、相加等操作。第 1 个特征层在经过 OSA 模块阶段 3 与 1 次卷积块后传入 PANet, 第

2 个特征层在经过 OSA 模块阶段 4 与一次卷积块后传入 PANet, 第 3 个特征层在经过骨干网络与 3 次卷积块后, 传入空间池化金字塔 (spatial pyramid pooling, SPP)^[20], SPP 主要分别利用 4 个尺度池化核为 13 × 13、9 × 9、5 × 5、1 × 1 进行最大池化处理后进行合并, 再经过 3 次卷积块后传入到 PANet。SPP 的优势在于能够分离出最显著的上下文特征, 增大感受野。

对 3 个特征层使用 PANet 网络对发动机孔探图像进行特征提取。PANet 是一种实例分割算法, 在完成从下到上的特征提取后, 还要完成自底向上的特征提取。这种自底向上的路径增强, 是为了缩短信息传播路径, 同时利用低层特征的精准定位信息。在完成特征融合后, 输出 3 个尺度分别为 52 × 52、26 × 26、13 × 13 的特征图, 再通过 YOLO head 解码, 获得种类、置信度 (confidence)、预测框的调整参数等结果。

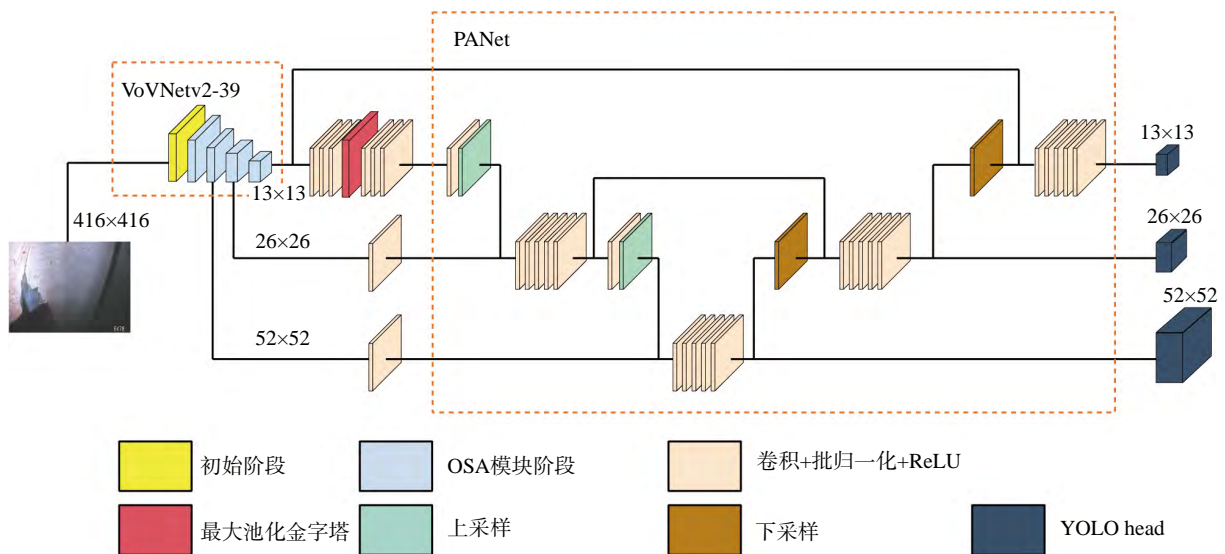


图 5 YOLOv4-VoVNetv2-39 网络结构图

Fig. 5 YOLOv4-VoVNetv2-39 network structure diagram

3.3 损失函数

损失函数 l 由 3 个部分组成, 分别为坐标损失 l_{box} , 置信度损失 l_{conf} 与类别损失 l_{class} 。其中的坐标损失采用 CIoU^[21](complete intersection over union), 计算公式如式(1)~式(4)所示:

$$l = l_{\text{box}} + l_{\text{conf}} + l_{\text{class}} \quad (1)$$

$$l_{\text{box}} = \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} \left[1 - I_{\text{ou}} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \frac{16}{\pi^4} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^4 \right] \quad (2)$$

$$1 - I_{\text{ou}} + \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2$$

$$l_{\text{conf}} = \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{obj}} [-\hat{C}_i^j \lg(C_i^j) - (1 - \hat{C}_i^j) \lg(1 - C_i^j)] + \lambda_{\text{noobj}} \sum_{i=0}^{s^2} \sum_{j=0}^B I_{i,j}^{\text{noobj}} [-\hat{C}_i^j \lg(C_i^j) - (1 - \hat{C}_i^j) \lg(1 - C_i^j)] \quad (3)$$

$$l_{\text{class}} = \sum_{i=0}^{s^2} I_{i,j}^{\text{obj}} \sum_{a \in C_1} [-\hat{P}_i^j \lg(P_i^j) - (1 - \hat{P}_i^j) \lg(1 - P_i^j)] \quad (4)$$

式(2)中 s^2 为网格数量, B 为事先设定的先验框数量, 若第 i 个网格第 j 个先验框有目标则 $I_{i,j}^{\text{obj}}$ 为 1, 反之则为 0, I_{ou} 为预测框和真实框的交并比, b 和 b^{gt} 分别为预测框和真实框的中心位置, $\rho(b, b^{\text{gt}})$ 为两个中心位置的欧几里得距离, c 代表能够同时包含预测框和真实框的最小矩形的对角线长度, c 与 $\rho(b, b^{\text{gt}})$ 的几何关系如图 6 所示。 w^{gt} 和 h^{gt} 、 w 和 h 分别为真实框和预测框的宽与高。

式(3)中 \hat{C}_i^j 与 C_i^j 分别代表真实框与预测框的置信度, λ_{noobj} 为人为设定的调整参数, 通常选择不超过 1.0 的正数, $I_{i,j}^{\text{noobj}}$ 的计算如式(5)所示:

$$I_{i,j}^{\text{noobj}} = 1 - I_{i,j}^{\text{obj}} \quad (5)$$

式(4)中的 $\sum_{a \in C_1} [\dots]$ 代表多种类的交叉熵损失, \hat{P}_i^j 与 P_i^j 分别代表真实框与预测框的类别概率。

孔探图像损伤的识别可归为多分类问题, 每一类的准确率指标为平均精确度(average precision, AP), 评判模型性能的标准一般为所有类别的平均精确度(mAP)与推理速度(FPS), mAP 的计算如式(6)~式(9)所示:




图 6 c 与 $\rho(b, b^{\text{gt}})$ 的示意图

Fig. 6 Schematic diagram of c and $\rho(b, b^{\text{gt}})$

$$P = \frac{T_p}{T_p + F_p} \quad (6)$$

$$R = \frac{T_p}{T_p + F_n} \quad (7)$$

$$A_p = \int_0^1 P(R) dR \quad (8)$$

$$m_{\text{AP}} = \frac{A_p}{c} \quad (9)$$

其中 P 为准确率, R 为召回率, 对于每一类, 可以规定一个置信度阈值(通常为 0.5)来判断是否是正例, T_p 为此类中准确识别正例的数量, F_p 为非此类但识别为此类正例的数量, F_n 为未能识别出此类正例的数量, A_p 为平均精确度 AP, m_{AP} 为所有类别的平均精确度 mAP, c 为类别数。mAP 越大则模型的准确率越高。

FPS 的计算如式(10)所示:

$$f_{\text{FPS}} = \frac{1}{t_{\text{ave}}} \quad (10)$$

其中 f_{FPS} 为 FPS, t_{ave} 为平均检测一张图片所需的时间, f_{FPS} 越大, 则目标检测模型的推理速度越快。

4 目标识别模型训练及测试

4.1 Pascal VOC 数据集的训练及测试

Pascal VOC 数据集是 Pascal VOC 挑战赛当中使用的数据, 主要用于目标分类, 目标检测等, 包含人、猫、椅子、汽车等 20 种类别。将 Pascal VOC 2007 的训练集与 Pascal VOC 2012 的训练集作为目标识别模型的训练集, 共计 22 136 个样本, Pascal VOC 2007 的测试集作为目标识别模型的测试集, 共计 4 952 个样本。

通过 Python 3.6 语言编程, 使用 Pytorch-1.2.0 作为深度学习框架, 在硬件 NVIDIA 2080TI 上实现目标识别模型的训练与测试。模型训练轮次(Epoch)设置为 100, 前 50 轮学习率设为 0.001,

Batch Size 设置为 8; 后 50 轮, 学习率为 0.000 1, Batch Size 设置为 4。预设值的先验框一共 9 个, 分别为 [12, 16], [19, 36], [40, 28], [36, 75], [76, 55], [72, 146], [142, 110], [192, 243], [459, 401]。

将上述训练集分别导入到 YOLOv4 网络与 YOLOv4-VoVNetv2-39 网络中训练。两个网络的参数数量与训练的模型大小如表 2 所示。

表 2 网络参数与模型大小比较

Table 2 Comparison of network parameters and model size

模型	参数量	模型大小/MB
YOLOv4 网络	63, 312, 477	248.6
YOLOv4-VoVNetv2-39	59, 747, 965	230.9

训练完成后, 分别对两种模型使用 Pascal VOC 2007 的测试集进行测试, 最终得到的不同种类的平均精确度如图 7 所示。

两种模型在不同种类的平均精确度差距甚微, YOLOv4 的 mAP 值为 77.41%, 在相同的训练条件下, YOLOv4-VoVNetv2-39 的 mAP 值为 77.97%, 比原网络稍高。

两种模型的推理速度对比如表 3 所示。部分识别结果如图 8 所示, 方框框出的部分即为所检

测出的目标对象, 方框上同时标有种类与对应的置信度。

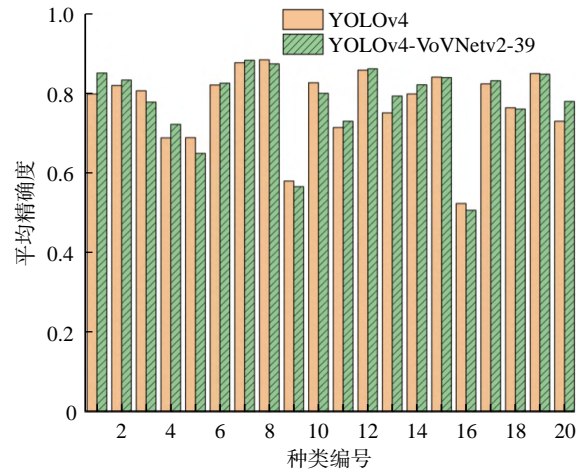


图 7 不同种类的平均精确度对比

Fig. 7 Comparison of AP of different classes

表 3 两种模型的推理速度对比

Table 3 Comparison of FPS of the two models

模型	平均每张图片推理时间/s	FPS/帧
YOLOv4	0.025 28	39.6
YOLOv4-VoVNetv2-39	0.020 35	49.2

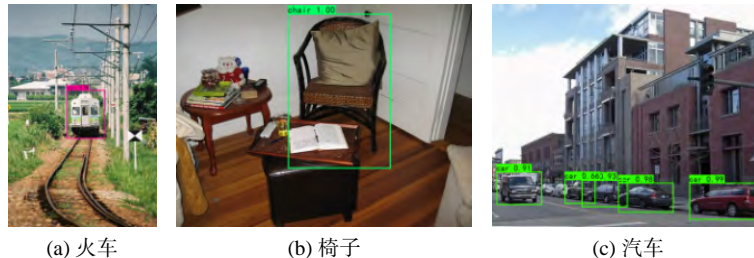


图 8 部分 Pascal VOC 测试集检测结果

Fig. 8 Part of Pascal VOC test data set detection results

YOLOv4-VoVNetv2-39 平均每张图片的推理时间相比原目标识别网络减少了 19.5%, 每秒检测的图片相比原目标识别网络增加 26.2%, 在推理速度上得到了提升。VoVNetv2-39 相比 Csp-DarkNet-53 拥有更少的参数量, 自上而下特征传递的路径更短, 特征传递更快。

4.2 孔探损伤图像数据集的训练及测试

孔探损伤图像的数据由某航空公司提供, 经过图 2 所示流程的处理后, 获得共计 4 713 个样本, 其中训练集样本为 4 242 个, 测试集样本 471 个, 孔探图像的 3 种损伤分别为掉块、裂纹、腐蚀。

模型训练轮次设置为 40, 前 10 轮学习率设

为 0.001, Batch Size 设置为 8; 后 30 轮学习率为 0.000 1, Batch Size 设置为 4。将上述训练集分别导入到 YOLOv4 与 YOLOv4-VoVNetv2-39 网络中训练。

模型训练完成后, 使用发动机孔探损伤图像测试集对两个模型进行测试, 测试结果如表 4 所示, 部分航空发动机孔探损伤图像检测结果如图 9 所示。

YOLOv4-VoVNetv2-39 与 YOLOv4 相比, 在 mAP 方面稍高, 在平均每张图片推理时间上减少了 19.1%, 在 FPS 上提高了 23.7%。同样在保证精确度的情况下, 提高了推理速度。

表 4 两种模型的检测平均精确度、速度对比
Table 4 Comparison of detection average precision and FPS of the two models

模型	$A_p/\%$			$m_{AP}/\%$	平均每张图片推理时间/s	FPS/帧
	掉块	裂纹	腐蚀			
YOLOv4	98.32	97.86	83.58	93.25	0.025 34	39.5
YOLOv4-VoVNetv2-39	97.95	99.09	85.36	94.13	0.020 49	48.8




图 9 部分发动机孔探损伤检测结果

Fig. 9 Part of aero-engine borescope damage detection results

5 结 论

本文提出了基于 YOLOv4 网络改进的网络模型 YOLOv4-VoVNetv2-39, 分别在标准数据集 Pascal VOC 数据集与某航空公司提供的航空发动机孔探损伤图像数据集进行了训练测试。对比实验结果表明, 在对不同目标检测的准确度方面, YOLOv4-VoVNetv2-39 网络与 YOLOv4 网络几乎保持一致, 均能准确完成孔探图像的检测任务; 在推理速度方面, YOLOv4-VoVNetv2-39 网络的 FPS 相比 YOLOv4 网络在 Pascal VOC 数据集上提升了 26.2%, 在航空发动机孔探损伤数据集上提升了 23.7%, 实时性得到了大幅提升。该模型可以实时并高精度识别航空发动机内部各类损伤, 可于工程应用中使用。

参考文献:

- [1] 易中辉, 李世林, 李子铭. 图像识别在航空发动机维修中的应用[J]. 中国科技信息, 2020, 32(23): 27-28.
YI Zhonghui, LI Shilin, LI Zimin. The application of image recognition in aero-engine maintenance[J]. China Science and Technology Information, 2020, 32(23): 27-28. (in Chinese)
- [2] 肖柏荣. 航空发动机维护中孔探检测技术的应用[J]. 中国高新科技, 2019, 3(15): 96-98.
XIAO Bairong. Application of borescope detection technology in aero-engine maintenance[J]. China High-Tech, 2019, 3(15): 96-98. (in Chinese)
- [3] 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 detection[D]. Tianjin: Civil Aviation University of China, 2018. (in Chinese)
- [4] 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, 39(24): 190-191.
YU Jiachen. The management of the borescope detection of civil aviation engine electronic endoscope[J]. Electronics World, 2017, 39(24): 190-191. (in Chinese)
- [5] 胡静, 徐拓. 基于孔探技术的航空发动机常见损伤及案例分析[J]. 装备制造技术, 2017, 45(11): 183-185.
HU Jing, XU Tuo. The common damage and case analysis of aero-engine based on borescope technology[J]. Equipment Manufacturing Technology, 2017, 45(11): 183-185. (in Chinese)
- [6] 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, 46(3): 203-205.
YANG Xiaojun, WANG Yingqi, LIU Zhigang. Analysis of damaged blades of aero-engine turbine[J]. Mechanical Engineering & Automation, 2017, 46(3): 203-205. (in Chinese)
- [7] 刘斌江, 孙科. 孔探技术在航空发动机维修中的应用[J]. 国防制造技术, 2016, 8(3): 67-69.
LIU Binjiang, SUN Ke. Application of hole exploring technology in aero-engine maintenance[J]. Defense Manufacturing Technology, 2016, 8(3): 67-69. (in Chinese)
- [8] 樊玮, 段博坤, 黄睿, 等. 基于风格迁移的交互式航空发动机孔探图像扩展方法[J]. 计算机应用, 2020, 40(12): 3631-3636.
FAN Wei, DUAN Bokun, HUANG Rui, et al. Interactive augmentation method for aircraft engine borescope inspection images based on style transfer[J]. Journal of Computer Applications, 2020, 40(12): 3631-3636. (in Chinese)
- [9] 张栋善, 赵成. 航空发动机维修中孔探技术的应用分析[J]. 电子制作, 2019, 26(12): 98-99.
ZHANG Dongshan, ZHAO Cheng. Application analysis of hole exploring technology in aero-engine maintenance[J]. Practical Electronics, 2019, 26(12): 98-99. (in Chinese)
- [10] 李华, 陈果, 陈新波, 等. 航空发动机内部裂纹自动测量方法研究[J]. 计算机工程与应用, 2016, 52(11): 233-237.
LI Hua, CHEN Guo, CHEN Xinbo, et al. Study on automatic measurement method for aero-engine inner damage crack[J]. Computer Engineering and Applications, 2016, 52(11): 233-237. (in Chinese)
- [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.
- KUANG Kejia. Research on deep learning and its application on the defects detection for aero-engine[D]. Guangzhou: South China University of Technology, 2017. (in Chinese)
- [12] 赵焯. 基于卷积神经网络的叶片损伤识别方法研究[D]. 天津: 中国民航大学, 2019.
- ZHAO Ye. Research on blade damage identification method based on convolution neural network[D]. Tianjin: Civil Aviation University of China, 2019. (in Chinese)
- [13] 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 aero-engine blades based on borescope data[D]. Tianjin: Civil Aviation University of China, 2020. (in Chinese)
- [14] HUANG G, LIU Z, PLEISS G, et al. Convolutional networks with dense connectivity[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 44(12): 8704-8716.
- [15] LEE Y, HWANG J, LEE S, et al. An energy and gpu-computation efficient backbone network for real-time object detection[C]//CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2019: 752-760.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [17] LEE Y, PARK J. Centermask: real-time anchor-free instance segmentation[C]//CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 13906-13915.
- [18] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 8759-8768.
- [19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: optimal speed and accuracy of object detection[EB/OL]. [2022-12-21]. <https://arxiv.org/abs/2004.10934>.
- [20] 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, 2015, 37(9): 1904-1916.
- [21] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574-8586.

(编辑: 张 雪)