

DOI: 10.19344/j.cnki.issn1671-5276.2025.02.043

基于改进 YOLOv4 的航空发动机叶片损伤检测

王倩岚^{a,b}, 刘文波^{a,b}, 滕子煜^{a,b}, 单永奇^{a,b}

(南京航空航天大学 a. 自动化学院; b. 高速载运设施无损检测监控技术工信部重点实验室, 江苏 南京 211106)

摘要:针对孔探设备检测航空发动机叶片损伤时会出现的漏检和人力物力耗费过大的问题,在 YOLOv4 网络的基础上提出一种基于扩张卷积和注意力机制的目标检测算法。使用 CSPDarknet53 作为特征提取网络;引入混合注意力机制并融合扩张卷积来增强网络的特征提取能力;采用 Focal Loss 函数优化原有的损失函数。实验结果表明:改进后算法网络的检测精度提高了 5.71 个百分点,更能满足发动机叶片损伤检测不漏检的需求。

关键词:发动机;叶片损伤;目标检测;YOLOv4;注意力机制;扩张卷积

中图分类号:TP391.4 **文献标志码:**A **文章编号:**1671-5276(2025)02-0223-04

Aeroengine Blade Damage Detection Based on Improved YOLOv4

WANG Qianlan^{a,b}, LIU Wenbo^{a,b}, TENG Ziyu^{a,b}, SHAN Yongqi^{a,b}

(a. College of Automation Engineering; b. Non-destructive Testing and Monitoring Technology for High-speed Transport Facilities Key Laboratory of Ministry of Industry and Information Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: In order to solve the problems of missed detection and excessive cost of human and material resources when detecting aeroengine blade damage with hole detection equipment, a target detection algorithm based on dilated convolution and attention mechanism was proposed based on YOLOv4 network. CSPDarknet53 was used as the feature extraction network, and the Mixed attention mechanism and the fusion expansion convolution were introduced to enhance the feature extraction capability of the network. The Focal Loss function was applied to optimize the original loss function. The experimental results show that the detection accuracy of the improved algorithm network is increased by 5.71 per cent, better meeting the requirements of the engine blade damage detection without missed detection.

Keywords: engine; blade damage; target detection; YOLOv4; attention mechanism; dilated convolution

0 引言

航空发动机是重要的航空武器装备。然而叶片的工作环境常常伴随着高温、高压、高转速以及外物击伤等诸多不利因素^[1]。叶片在长时间的高负荷工作状态下,极易出现如撕裂、划痕、掉块、缺口、凹坑、鼓包、烧蚀等损伤。因此加强对叶片的损伤维修检测^[2]是至关重要的。

目前航空发动机的维修检查主要是依靠孔探设备^[3]来完成的。但孔探设备是通过人眼对孔探仪器获得的图像进行损伤判断,但依赖于员工经验存在诸多问题。因而研究一套能够自动识别飞机发动机叶片损伤的系统具有很大的现实意义。

近几年,以深度学习和图像处理技术为基础的目标检测方法越来越被广泛应用,深度卷积神经网络优秀的特征提取能力很适用于背景环境复

杂的场景中,在航空发动机叶片检测研究上也有优异的表现。REDDY 等^[4]使用 CNN 对收集到的风力涡轮机叶片图像开展损伤检测的工作,在涡轮机维护和检查的过程中,极大降低了时间成本。中国民航大学的赵焯^[5]以 ResNet 作为基础神经网络结构,选择批量梯度下降算法作为损失函数反向传导时计算梯度的方式,得到了较高的精度。朱倩等^[6]设计并实现了一种基于 Faster R-CNN 模型的发动机叶片损伤识别算法,结合了区域建议网络 RPN 和 Fast R-CNN 的特点,既能够实现对外边缘磕口、裂纹、表皮脱落等损伤的高精度识别,还有效提高了检测速度。HE 等^[7]提出改进后的 Mask R-CNN 算法,此算法对发动机叶片的损伤检测有很大程度的提升,既能完成损伤分类工作,还能实现损伤像素级的分割内容。

航空发动机叶片损伤检测相较于检测速度,

基金项目:国家自然科学基金项目(61871218);国家重点研发计划项目(2018YFB2003304);中央高校基本科研业务费项目(NJ2019007,NJ2020014)

第一作者简介:王倩岚(1999—),女,江苏常州人,硕士研究生,研究方向为深度学习和图像处理,408463044@qq.com。

更侧重于检测的准确性。因此本文选取了检测精度较高的 YOLOv4 网络为基础,其中引入了混合注意力机制以及扩张卷积部分,优化了网络提取不同尺度的特征信息的能力,提高了网络的检测精度。

1 YOLOv4 算法

YOLO 系列作为单阶段目标检测算法,是现在主流的深度学习检测方法之一。YOLOv4 是一种端对端的网络,原始图像输入网络后,在产生候选框的同时,可以完成位置调整和分类任务。YOLOv4 的网络结构主要有 4 个部分:主干网络 CSPDarknet53、空间金字塔池化网络、路径聚合网络和 YOLOHead 头部网络,其结构如图 1 所示。主干网络 CSPDarknet53 是在 Darknet53 的基础上加入跨界段部分连接,更好地提升网络性能,避免重复学习,提高了内存利用率。

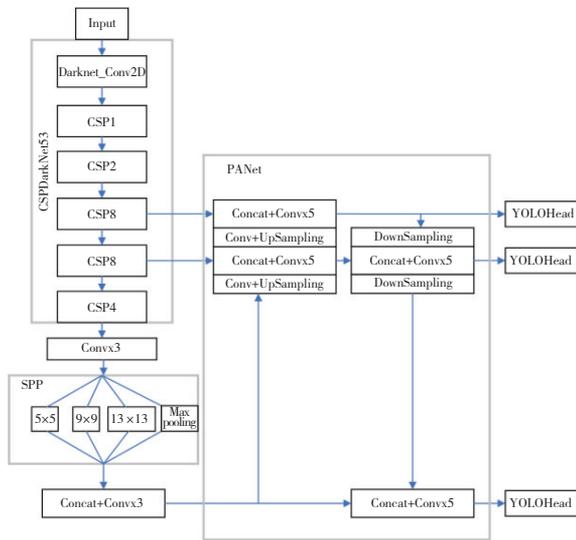


图 1 YOLOv4 结构

2 模型改进及其优化

2.1 加入 CBAM 模块

飞机发动机叶片损伤图片存在着复杂的背景信息,在一定程度上会影响提取目标检测的特征。出于抑制噪声对检测影响的考虑,本文在 PANet 加入混合注意力模块(convolutional block attention module, CBAM)^[8],模块结构如图 2 所示。

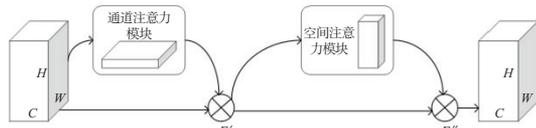


图 2 CBAM 模块

注意力机制是一种通过模拟人类视觉以此来进行信号处理的机制。它利用网络学习来获取权重系数,然后以动态加权的方式来完成输入特征的调整工作,得以专注于网络感兴趣的区域,与此同时还能抑制其他区域。

如图 2 所示,输入特征 F ,其大小为 $H \times W \times C$ 的。 C 是特征 F 的通道数, $H \times W$ 是特征 F 的尺寸。

CBAM 模块的具体计算过程如式(1)、式(2)所示。

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

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

式中: F 为输入特征; M_c 为通道注意力模块的运算过程; F' 为通道注意力模块输出的特征; M_s 为空间注意力模块的运算过程; F'' 为空间注意力模块输出的特征,即重构特征。

2.2 融合扩张卷积的注意力机制

在卷积神经网络中,感受野的大小对提高目标检测性能是很重要的。因此,可以在 CBAM 模块中引入扩张卷积(dilated convolution),在不减小特征图尺寸的同时,能够增大卷积核的感受野。

扩张卷积是通过插入空洞的方式使卷积核增大,增大感受野,从而增强对多尺度信息的捕捉,获得更多浅层信息。不同扩张率的 3×3 卷积核的结构如图 3 所示。

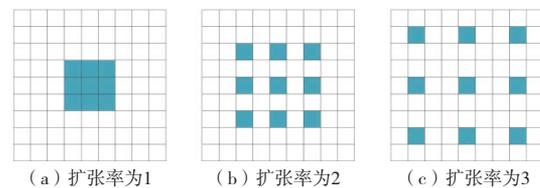


图 3 不同扩张率的 3×3 卷积核

如图 3 所示,当扩张率为 a 、卷积核为 b 时,该卷积的感受野等同于卷积核大小为 A ,如式(3)所示。

$$A = b + (b-1)(a-1) = ab - a + 1 \quad (3)$$

由于扩张卷积的卷积核是有间隔的,在多层具有相同扩张率的扩张卷积叠加时会存在洞,因此会出现输入感受野不能被完全覆盖的问题。为了整合不同尺度的感受野,减少信息丢失,本文设计一个并行的扩张卷积结构,如图 4 所示。本文选取了 4 个扩张率依次递减的 3×3 卷积核,避免了空洞不连续现象,同时能生成不同尺度的感受野,减少了浅层信息的丢失。

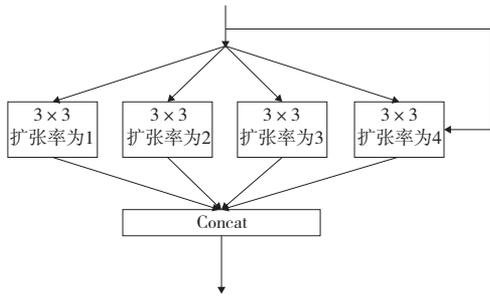


图4 并行扩张卷积

2.3 优化损失函数

YOLOv4 算法作为 one-stage 算法,为了提高检测速度,缺少了对先验框的筛选过程,就需要直接处理大量的先验框。而当一副图像中的真实目标即正样本很少时,大量的先验框就会处在背景区域即负样本中,这就会导致正负样本的不平衡。

为了解决这个问题,本研究使用了 Focal Loss 损失函数代替原来的交叉熵损失函数。Focal Loss 损失函数可以减少样本背景区域的占比,检测时集中于目标物体,提高检测的准确率。Focal Loss 损失函数的定义如式(4)、式(5)所示。

$$FL(p_i) = -\alpha_i(1-p_i)^\gamma \lg p_i \quad (4)$$

$$p_i = \begin{cases} p, & y=1 \\ 1-p, & y=-1 \end{cases} \quad (5)$$

式中: α_i ($\alpha_i \in [0, 1]$) 是平衡因子; p ($p_i \in [0, 1]$) 是预测框为目标标签的估计概率; y ($y \in \{0, 1\}$) 为实际的标签值; γ 为调整难易样本的参数。本实验设置 α_i 为 0.5, γ 经实验调整为 2 时最优。

3 实验与分析

3.1 实验环境

本文的实验环境如下:中央处理器为 AMD Ryzen 7 5800H, 内存为 16 GB; 采用 NVIDIA GeForce RTX 3050 显卡;操作系统为 Windows11;深度学习框架为 PyTorch1. 10. 0 + cu113, CUDA10.2。

3.2 实验数据集

本文的实验数据集主要来自某型航空发动机的孔探报告,收集了 174 张原始损伤样本,其中包含了缺口(nick)、裂纹(crack)、划痕(scratches)、掉块(missmaterial)4种典型的损失类型。在训练时发现,叶片上与周围存在的铁屑会影响检测效果,于是将其标注为污渍(stains)。由于样本数量较少,使用旋转、缩放和调整对比度等方法对样本进行扩充,得到 1 011 张样本图片。将数据集以

9 : 1 的比例划分为训练集和测试集进行训练。

3.3 评价指标

本研究主要用单类损伤的平均精度(average precision, AP)和所有类别损伤的平均精度(mean average precision, mAP)来衡量算法的准确性,用每秒帧数(frame per second, FPS)来衡量算法的检测速度。AP 值是以不同的准确率和召回率为横纵坐标,在其坐标上围成的面积,其相关公式如下:

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

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

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

$$m_{AP} = \frac{1}{n} \sum_{i=1}^n A_p(i) \quad (9)$$

式中: T_p 表示正样本预测正确的概率; F_p 表示负样本预测错误的概率; F_N 表示正样本预测错误的概率。

3.4 实验结果分析

本文分别通过加入 CBAM 注意力模块,将扩张卷积引入注意力机制,优化损失函数的方法在 YOLOv4 网络的基础上进行改进。接着进行消融实验对不同改进效果进行评估,以此来分析各个改进方法对检测效果的提升是否有效。实验 1 是代表未改进的 YOLOv4 算法;实验 2 是在 PANet 网络中加入 CBAM 注意力模块;实验 3 是将扩张卷积引入注意力机制;实验 4 是在实验 3 的基础上优化损失函数。不同的改进方法对损失的检测效果对比如表 1 所示。

表 1 不同改进方法的检测效果对比 单位:%

模型	m_{AP}	A_p				
		缺口	裂纹	划痕	掉块	污渍
实验 1	88.31	86.78	96.70	100.00	93.58	64.48
实验 2	89.88	94.15	100.00	100.00	89.92	65.35
实验 3	92.23	94.31	100.00	100.00	94.29	72.55
实验 4	94.02	95.90	100.00	100.00	97.14	77.06

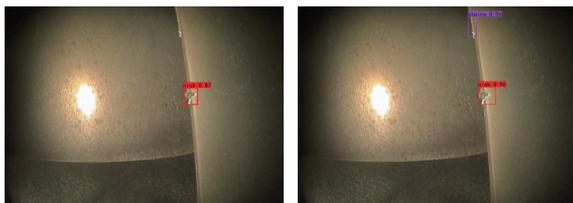
由表 1 可知,引入集成注意力模块能有效提高检测的精度,算法的检测精度提高了 1.57 个百分点。这说明了加入 CBAM 模块有效增强了主干网络的特征提取能力。在此基础上,在注意力机制中融合扩张卷积,提出扩张注意力机制,增加了卷积模块的感受野,将目标检测精度提升了 2.35 个百分点,其中污渍这类损失的检测准确率提高

了 7.2 个百分点,说明运用并行扩张卷积结果能够有助于注意力机制定位网络更感兴趣的区域,使输出能够包含不同尺度的特征信息,更准确识别不同大小的铁屑。实验 4 在扩张注意力机制的基础上使用 Focal Loss 函数, mAP 值进一步提高了 1.79 个百分点,说明改进后的损失函数能有效专注于损伤小目标样本,同时减小简单背景样本的训练权重,以此来提升算法的检测精度。

为了进一步验证本文算法的有效性,将本文算法与其他主流的目标检测算法进行对比实验,结果如表 2 所示。对比各个算法可知,本文算法在精度上体现了一定的优越性,较原始 YOLOv4 算法提高了 5.71 个百分点。虽然牺牲了一定的检测速度,但同时也提高了模型的特征提取能力,提高了目标检测精度。实验效果如图 5 所示,图 5(a)为原始 YOLOv4 算法在发动机叶片各类损伤上的检测效果,图 5(b)为改进后 YOLOv4 算法的检测效果。由图 5 可以看出 YOLOv4 在检测时有时会出现漏检的情况,而改进后的算法则有效降低了漏检,同时提高了检测置信度,证明了该算法能够有效检测到不同大小的损伤,在检测时其结果更为准确。

表 2 不同算法检测性能对比

模型	$m_{AP}/\%$	检测速度/(帧/s)
Faster RCNN	86.60	10.2
SSD	84.21	16.8
YOLOv3	85.24	24.5
YOLOv4-Tiny	73.62	58.9
YOLOv4	88.31	28.7
本文算法	94.02	26.7



(a) 原始YOLOv4算法

(b) 改进后YOLOv4算法

图 5 对比算法改进前后的检测结果

4 结语

针对现有飞机发动机叶片损伤检测存在的问题,本文提出了一种基于改进 YOLOv4 的目标检测算法。本文通过在 PANet 网络添加混合注意力机制,在通道和空间两个维度上获取更多特征信息。由于叶片损伤大小不一,为了更好地检测小目标的损伤,将扩张卷积加入注意力机制以增大卷积感受野,从而提高检测精度。最后,使用 Focal Loss 函数优化损失函数。实验结果表明:与原始的 YOLOv4 算法相比,其检测精度提升了 5.71 个百分点,但检测速度稍有降低,特别在污渍这类损伤类型上,检测准确率有较大提升,改善了叶片漏检的情况,更符合工业需求。

参考文献:

- [1] 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(11):183-185.
- [2] 何嘉辉,张栋善,赵成,等. 航空发动机叶片裂纹检测技术及应用分析[J]. 内燃机与配件,2020(15):151-152.
- [3] 肖柏荣. 航空发动机维护中孔探检测技术的应用[J]. 中国高新科技,2019(15):96-98.
- [4] REDDY A, INDRAGANDHI V, RAVI L, et al. Detection of Cracks and damage in wind turbine blades using artificial intelligence - based image analytics [J]. Measurement, 2019, 147: 106823.
- [5] 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.
- [6] 朱倩,朱建伟,宋艳艳,晏海龙. 基于 Faster R-CNN 的发动机叶片损伤识别方法研究[J]. 计算机科学与应用, 2022, 12(1): 46-53.
- [7] 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.
- [8] 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.

收稿日期:2023-07-25