

基于深度学习的航空发动机涡轮叶片 自动射线检测技术研究*

王栋欢, 肖洪, 吴丁毅

(西北工业大学 动力与能源学院, 陕西 西安 710129)

摘要: 一直以来, 航空发动机涡轮叶片的射线检测依靠检验员人工评片。为避免经验差异、眼睛疲劳、标准理解等人为因素影响, 有效改善传统射线检测费时费力、效率低下等问题, 针对航空发动机涡轮叶片射线图像, 基于YOLOv4模型提出了一种双主干特征融合的缺陷自动检测算法(DBFF-YOLOv4); 通过设计包含所有特征映射的新型连接结构搭建缺陷检测颈部网络, 建立了适用于涡轮叶片射线图像的缺陷自动检测模型; 针对每个缺陷, 采用9次裁剪、旋转和亮度增减的图像数据增强方法扩充样本数据, 在此基础上进行了模型训练与测试。结果表明, 针对完整涡轮叶片, 建立的缺陷检测模型在0.5的置信度阈值下可获得96.7%的平均查准率和91.87%的平均查全率, 优于通用目标检测算法YOLOv4模型。9次缺陷裁剪、旋转和亮度增减的图像数据增强方法能够显著提高模型的缺陷检测精度(平均精度分别得到了59.19%和2.53%的提升)。该研究为涡轮叶片自动射线检测提供了一种新方法。

关键词: 航空发动机; 涡轮叶片; 深度学习; 缺陷检测; 射线检测; 射线图像

中图分类号: V232.4

文献标识码: A

文章编号: 1001-4055 (2024) 05-2210024-09

DOI: 10.13675/j.cnki.tjjs.2210024

1 引言

涡轮叶片是航空发动机核心部件, 随着飞机性能的不不断提升, 对其核心部件涡轮叶片的可靠性、安全性和质量提出了更高的要求^[1-2]。在当前的技术水平下, 由于涡轮叶片结构复杂、内部流道多样, 精铸成型的涡轮叶片内部难免存在裂纹、冷隔、气孔、夹渣和疏松等缺陷^[3], 对其进行无损检测和质量管是叶片生产制造的必要环节, 而检测效率和精度与总体生产效益密切相关。

传统涡轮叶片无损检测方法包括涡流检测、磁粉检测、射线检测、超声波检测、同位素照相、渗透检测、红外热像检测和噪声检测^[4]。通常根据实际情况, 采用多种技术手段对缺陷进行检测、分析和综合评估。射线检测是检测叶片内部缺陷的主要方法, 其通过X射线照相技术得到叶片胶片图像, 再由检验员借助观片灯进行评片。由于经验差异、眼睛疲劳、标准理解等

人为因素影响, 存在误检/漏检率高、检测效率低和成本高等诸多问题。因而发展智能化的射线检测技术已然成为航空发动机涡轮叶片质量管理的迫切需求。

近年来, 国内外众多学者致力于X射线检测自动化、智能化的研究, 深度学习逐渐被用于工业铸件X射线图像的缺陷检测^[5-6]。Domingo Mery等^[7-8]建立了名为GDXray的公用数据集, 并以汽车零部件的X射线图像为研究对象, 评估和比较了包括深度学习、稀疏表示、局部描述符和纹理特征等24种计算机视觉技术。Ferguson M等^[9-10]在GDXray数据集的基础上利用迁移学习技术实现了Faster R-CNN ResNet-101, R-FCN ResNet-101, SSD VGG-16等多个先进目标检测模型对工业铸件X射线图像缺陷的定位与识别。时佳悦^[11]依据灰度变化率对图像进行分割, 通过选择14个特征值, 利用径向基函数(Radial Basis Function, RBF)神经网络对缺陷进行了分类识别。常海涛等^[12]建立了少量工业CT图像缺陷数据集, 基于

* 收稿日期: 2022-10-10; 修订日期: 2023-03-20。

基金项目: 中国航空发动机集团产学研合作项目(HFZL2019CXY008-1; HFZL2021CXY017)。

作者简介: 王栋欢, 博士生, 研究领域为智能缺陷识别、无损检测、航空发动机数字化智能化技术。

通讯作者: 肖洪, 博士, 教授, 研究领域为人工智能算法、航空发动机数字化智能化技术。E-mail: xhong@nwpu.edu.cn

引用格式: 王栋欢, 肖洪, 吴丁毅. 基于深度学习的航空发动机涡轮叶片自动射线检测技术研究[J]. 推进技术, 2024, 45(5): 2210024. (WANG D H, XIAO H, WU D Y. Automatic radiographic testing for aeroengine turbine blades based on deep learning[J]. Journal of Propulsion Technology, 2024, 45(5): 2210024.)

Faster-RCNN提出了适用于工业CT图像缺陷检测的深度学习检测方法,避免了传统缺陷检测需要手动选取目标特征的问题,检测效果良好。Fuchs等^[13-14]利用模拟程序设计了含有缺陷的铝模铸件模型,并自动生成包含缺陷、伪影、噪声的铝模铸件CT扫描模拟图像数据集和标签集,利用模拟数据对比分析了深度学习方法和基于过滤器方法在检测铝模铸件CT扫描图像上的表现结果,证明了深度学习在射线检测上的适用性。Du等^[15-16]采用特征金字塔网络(Feature pyramid networks, FPN)^[17]对汽车铝铸零部件X射线图像进行特征提取,并利用RoIAlign算法进一步提高了缺陷检测识别模型的检测性能。

不仅如此,在复杂的航空发动机叶片缺陷、损伤及故障检测领域也已出现深度学习的身影^[18-21]。基于深度学习的计算机视觉技术结合传统无损检测方法逐渐在叶片缺陷、损伤检测中得到应用,上述方法均是利用深度卷积神经网络在图像识别上的强大能力,建立多个适用于叶片损伤图像识别的深度学习模型,实现对叶片损伤的自动检测和识别。Chen等^[22-23]基于Fast R-CNN目标检测算法建立了航空发动机射线检测系统网络(Aeronautics engine radiographic testing inspection system net, AE-RTISNet),用于航空发动机射线图像的特征提取和缺陷识别,对8种类型缺陷的检测准确率高达90%以上,之后又基于YOLOv4算法实现了航空发动机X射线图像的缺陷检测,检测速度比之前提高了2倍。Zhang等^[24]基于YOLOv3算法建立了航空发动机叶片损伤检测模型,利用包含裂纹、卷曲、凹坑、缺口和撕裂5种损伤类型的227张航空发动机叶片孔探图像进行模型训练,实现了发动机风扇叶片损伤的自动识别。Kim等^[25]针对航空发动机孔探视频图像开发了一种基于卷积神经网络和传统图像处理技术的损伤识别算法,该算法已实现软件开发,并通过多次现场试验进行了验证,实现了对发动机风扇叶片和高压压气机叶片损伤自动检测。Shen, Chen团队^[26-27]基于深度学习目标检测算法建立了适用于航空发动机孔探图像损伤检测的深度学习模型,测试验证了深度学习目标检测算法应用于航空发动机孔探图像损伤检测的有效性。He等^[28]提出了一种基于改进Cascade Mask R-CNN模型用于航空发动机叶片孔探图像的损伤检测,并且建立多个语义分割模型(YOLOv4, Cascade R-CNN, Res2Net和Cascade Mask R-CNN)进行了对比研究。Shang等^[29]设计了一种纹理聚焦多尺度特征融合网络(Texture-focus multi-scale feature

fusion network, TFNet),用于提取航空发动机叶片孔探图像浅层纹理信息,利用改进Mask R-CNN实例分割算法实现了航空发动机叶片损伤的自动分类、定位和区域分割。

上述研究主要集中在涡轮叶片损伤图像的深度学习计算机视觉方法,目前鲜有针对航空发动机涡轮叶片射线图像的自动缺陷检测研究的相关文献报告。对此,本研究开展基于深度学习的航空发动机涡轮叶片自动射线检测技术研究。利用缺陷涡轮叶片X射线图像构建深度学习缺陷检测模型,实现射线检测的自动化和智能化。本研究的主要创新点如下:(1)针对航空发动机涡轮叶片X射线图像,提出了一种基于YOLOv4的双主干特征融合缺陷检测框架DBFF-YOLOv4,采用双深度卷积神经网络(Deep convolutional neural network, DCNN)提取分层缺陷特征;(2)设计了一种连接所有特征映射的新型路径聚合网络(Path aggregation network, PAN),融合了不同尺度的特征映射,增强了有效的特征传播,保证了缺陷检测性能;(3)采用9次缺陷均匀裁剪和多种图像数据增强方法,大大扩充了训练数据集,显著提高了缺陷检测模型的查准率。

2 方法

深度学习目标检测算法在计算机视觉领域被广泛应用,其检测识别对象是图像或视频数据,不同于常规深度学习的目标检测,航空发动机叶片射线检测的对象是X射线胶片。对于航空发动机涡轮叶片的射线检测而言,对射线检测产生的胶片图像进行数字化处理,进而针对胶片数字化图像结合深度学习目标检测算法进行缺陷检测和识别,该方法是将深度学习直接应用于涡轮叶片缺陷检测的有效途径。通用的目标检测算法适用于常见彩色图像的目标检测,目标物轮廓清晰,与背景色彩分明。然而涡轮叶片的X射线图像是单通道灰度图,缺陷尺寸微小且轮廓模糊,一般人眼也难于分辨。如何设计适用于涡轮叶片X射线图像的缺陷检测深度学习模型,最大化提高缺陷检测模型精度,降低漏检率和误检率是本研究的关键。本研究在现有目标检测算法的基础上,从数据集和标签集的获取、训练数据预处理、样本数据增强、缺陷检测网络架构设计、目标函数及优化算法各方面,详细介绍提出的基于深度学习的涡轮叶片的缺陷检测方法及其检测模型的实现过程。

2.1 缺陷样本获取及射线图像预处理

本研究涉及的射线胶片数据来自于某航空发动

机制造厂,利用胶片数字化扫描仪对600张含有缺陷的涡轮叶片胶片(胶片高0.5 m,宽0.41 m)进行了数字化处理,得到的X射线胶片数字图像分辨率(像素)为7960×9700。胶片数字化过程如图1所示。利用同涡轮叶片像素尺寸等大的固定框从胶片扫描数字图像上对缺陷叶片进行裁剪,以此得到2137张包含缺陷的涡轮叶片X射线图像(像素尺寸为770×1700)作为本研究的缺陷样本数据集。含有缺陷的涡轮叶片X射线图像如图2所示。

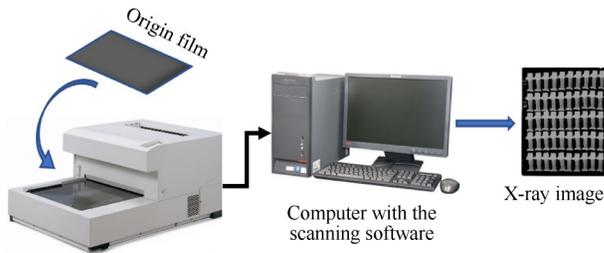


Fig. 1 X-ray image acquisition process

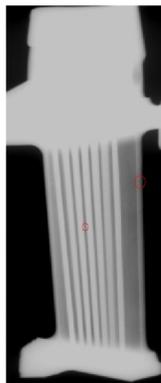


Fig. 2 X-ray blade image with defects

标签集是深度学习过程中的“答案集”,在基于深度学习的涡轮叶片缺陷检测模型的训练过程中,每张训练样本图片上的缺陷类别和位置信息需提前经由人工标定的方式给出,并作为标签参与模型训练。本文基于6种典型涡轮叶片缺陷的射线图像特征(如图3所示),利用Labeling标签制作软件建立了2137张缺陷样本的标签数据,以此作为本研究缺陷样本标签集。对6种缺陷及各自样本数量的统计如表1所示。

对于训练集,根据经验按照256×256的像素尺寸从每个缺陷涡轮叶片图像中对缺陷区域进行9次裁剪,使得缺陷均匀地落在裁剪图像的不同位置,裁剪示例如图4所示(为便于理解仅绘制3个裁剪框)。同时修改并扩充相应的标签数据,使得缺陷样本数量扩充至9倍,以此作为本研究的训练数据集。每个

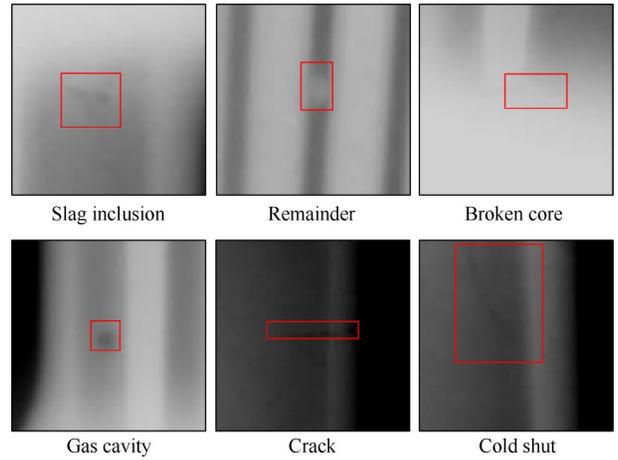


Fig. 3 Examples of different kinds of defect

Table 1 Statistical results of defect samples

Defect category	Remain-der	Broken core	Slag inclusion	Gas cavity	Cold shut	Crack	Sum
Sample quantity	515	373	1081	66	53	49	2137
Proportion/%	24.10	17.45	50.58	3.09	2.48	2.29	100

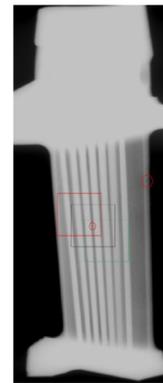


Fig. 4 Example of defect cropping process

缺陷经裁剪扩充9倍后的缺陷图像如图5所示。

对所有训练样本使用翻转、旋转、亮度增减的操作实现对图像数据的增强,测试样本保持不变。图6给出了本研究采用的图像数据增强示例。

2.2 缺陷检测网络模型构建

本研究基于YOLOv4^[30]目标检测算法,发展了一种双主干特征融合网络模型(Dual backbone feature fusion network, DBFFNet),该模型由四个模块组成(如图7所示)。第一个模块是ResNet-50^[31]和CSP-Darknet-53^[30]的双主干特征提取网络,它们负责提取特征并生成不同尺度的特征图。第二个模块称为颈部(Neck),由特征金字塔网络(Feature pyramid network, FPN)^[17]和路径聚合网络组成,采用了一种新的连接形式对所有特征映射进行了多尺度融合。第三

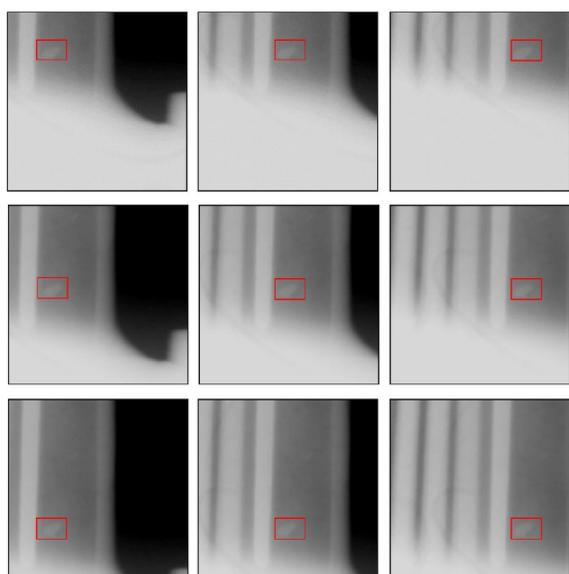


Fig. 5 Example of cropped pictures obtained by 9 cropping cycles in defective turbine blade images

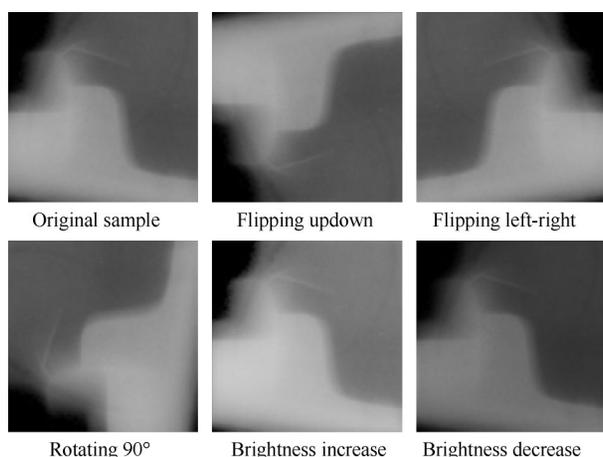


Fig. 6 Examples of image data augmentation

个模块是与 YOLOv4 的目标分类与坐标回归预测端相同的预测端 (YOLO Head), 负责将提取的特征映射为缺陷类别和缺陷坐标。最后一个模块则是对坐标的修正和对预测框的非极大值抑制 (Non-maximum suppression, NMS) 四个模块依次连接, 形成结构连贯统一的网络模型。

模型的“颈部”模块, 对于双主干网络输出的 6 个特征映射, 提出了一种包含所有特征映射的双路径聚合网络 (Dual-path aggregation network, D-PANet)。D-PANet 作为缺陷检测模型的核心, 用于融合不同比例的特征映射以提高检测性能。图 8 显示了该 D-PANet 结构, 其中 Concat 表示沿通道方向的横向连接, DBL 则由卷积 Conv、批归一化 BN 和 Mish 激活函数依次连接组成。输入是 6 个三种层次的特征映射。F1 和 P1 分别是 ResNet-50 和 CSPDarknet-53 浅层输

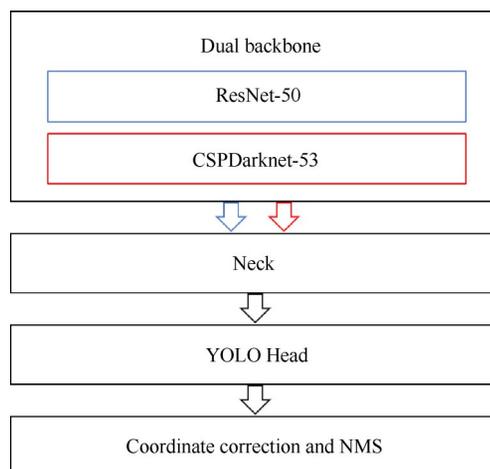


Fig. 7 Defect detection model framework

出的最大特征映射。F2 和 P2 是 ResNet-50 和 CSPDarknet-53 中间层输出的特征映射, F3 和 P3 分别是来自上述两个主干网络最后一层输出的最小特征映射。对包含较大感受野语义信息的 F3 和 P3 分别进行上采样后与 P2 和 F2 连接。之后, 对中间层输出的特征映射和最大特征映射执行相同的上采样和连接。值得注意的是, 自下而上的过程是双路径的, 因为有两组主干特征映射。在自上而下的过程中, 通过连接前两条自下而上路径的最后输出来获得顶层映射。此时, 执行一条自上而下的路径, 以融合来自不同尺度映射及层级结构的特征。经过上下特征传递后, D-PANet 输出三个尺度的融合特征图。在这里, 每个融合特征映射用于预测不同尺寸的缺陷。

2.3 目标函数及权值更新

本研究构建的缺陷检测模型的目标函数 (也称损失函数) 与 YOLOv4 的目标函数相同, 目标函数由

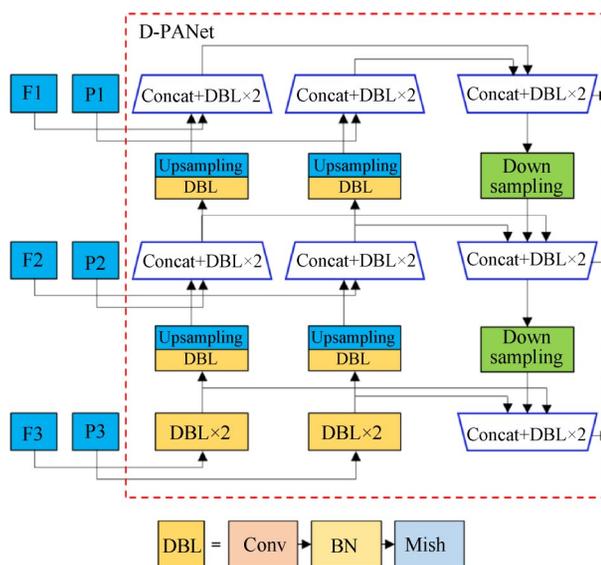


Fig. 8 Structure of our D-PANet

坐标预测误差、置信度误差和分类误差三部分组成。在坐标误差方面,值得注意的是,位置回归的目标是相对于先验框的期望修正值,而不是实际坐标。总损失的定义如下,即

$$Loss = L_{\text{coor}} + L_{\text{IoU}} + L_{\text{cls}} \quad (1)$$

等式右边第一项 L_{coor} 表示坐标损失(坐标的 L_2 损失),第二项 L_{IoU} 为置信度损失(置信度的交叉熵损失);第三项 L_{cls} 表示类别损失(类别概率的交叉熵损失)。具体表达式参考文献[23]。

2.4 模型训练与测试

选择 Keras 框架进行建模。80% 的样本用于训练,其余样本用于测试。训练阶段,10% 的训练集用于模型验证。模型训练和测试环境为 Windows 系统 NVIDIA GeForce GTX 2080Ti GPU。训练分为两个阶段。首先,以 ResNet-50 和 CSPDarknet-53 为主干的 YOLOv4 分别在训练数据集上进行预训练。训练时长设置为 100 个 Epoch,当连续 6 个 Epoch 的验证损失没有下降时,定义训练提前终止。在每次迭代中,Batchsize 设置为 32。采用自适应动量估计(Adam)算法^[32]及默认指数衰减率优化网络权值。之后,利用预训练权值初始化模型,进行整体网络训练。该过程首先对两个主干网络权值实时“冻结”,即固定权值不参与权重更新,对整个模型的 Neck 和 YOLO Head 部分使用与预训练阶段相同的训练参数进行训练。之后,将所有层“解冻”(整体模型的所有权值参与模型精细化训练)。全参数精细化训练阶段对计算资源的要求较大,因此将 Batchsize 设置为 8,Epoch 设置为 50,初始学习率设置为 10^{-4} 。模型训练及测试阶段的主要环境配置如表 2 所示。

3 结果与讨论

本研究采用目标检测领域常用指标:多目标类平均查准率(Mean average precision, mAP)和平均查全率(Mean average recall, mAR)、单目标平均查全率(Average recall, AR)和平均查准率(Average Precision,

Table 2 Main environment configuration

Parameters	Type
CPU	Inter Xeon(R) Silver 4114 @2.20 GHz
GPU	NVIDIA GeForce GTX 2080Ti
System	Windows 10
Python	3.6.9
Keras	2.3.1
Tensorflow-gpu	1.14.0
CUDA	10.0
CuDNN	7.6.4

AP)以及每秒传输帧数(Frames per second, FPS)对提出的缺陷检测模型进行评估。除了使用裁剪扩充后的缺陷样本(像素尺寸 256×256)训练和测试本研究的缺陷检测模型之外,还分别利用未裁剪的缺陷叶片图像(像素尺寸为 770×1700)、裁剪扩充后的缺陷样本(像素尺寸 256×256)训练并测试了通用目标检测模型 YOLOv4,以此进行对比研究。总的测试样本量为 427,包含具体的缺陷样本数量如表 3 所示。表 4 给出了 DBFF-YOLOv4 缺陷检测模型与 YOLOv4 模型的测试结果,其中 DBFF-YOLOv4 模型基于裁剪的缺陷样本构建,模型输入像素尺寸为 256×256, YOLOv4 模型基于原始未裁剪叶片图像样本构建,模型输入像素尺寸为 770×1700。可以看出,本研究提出的 DBFF-YOLOv4 缺陷检测模型(基于裁剪图像样本构建)在航空发动机叶片缺陷检测方面具有明显优势,其 mAP 可达到 99.58%,在 0.5 阈值($T=0.5$)下 mAR 达到了 91.87%。与不做图片裁剪而直接基于原始叶片图像构建的 YOLOv4 模型相比,基于裁剪图像构建的 DBFF-YOLOv4 在 mAP, mAR 方面的性能显著提高。

为了评估本研究提出的 DBFF-YOLOv4 模型框架在缺陷特征提取上的性能,利用相同的图像预处理方法(图像裁剪扩充和数据增强)并基于裁剪图像样本(像素尺寸 256×256)训练了以 ResNet-50 和 CSPDarknet-53 为主干特征提取网络的 YOLOv4 模型,并使用相同测试数据集进行了模型测试,表 5 给出了三个模型在所有缺陷类型下的 mAP, mAR 和 FPS。结果

Table 3 Details of the test datasets

Defect	Remainder	Broken core	Slag inclusion	Gas cavity	Cold shut	Crack	Sum
Quantities	103	74	216	13	11	10	427

Table 4 Comparison results of DBFF-YOLOv4 proposed and YOLOv4 with the raw input size (%)

Model	Input size	mAP	mAP($T=0.5$)	mAR($T=0.5$)
DBFF-YOLOv4(Proposed model)	256×256	99.58	99.90	91.87
YOLOv4	770×1700	31.27	50.24	8.02

显示 DBFF-YOLOv4 模型在缺陷检测上表现出最优性能,与以 CSPDarknet-53 为主干的 YOLOv4 模型相比,mAP 提高了 1.54%,mAR 提高了 0.02%。三个模型中以 ResNet-50 为主干的 YOLOv4 模型性能最差,mAR 只有 68.53%,该结果表明 ResNet-50 网络并不适合对涡轮叶片缺陷的特征提取。由于 DBFF-YOLOv4 缺陷检测模型采用双主干特征提取网络进行缺陷特征提取,同时进行多特征映射之间的双路级联。模型的复杂度提高,因此 FPS 最小。在相同的条件下,分别对以 CSPDarknet-53 为主干的 YOLOv4 模型和 DBFF-YOLOv4 模型就每种缺陷的识别情况进行对比分析,表 6 分别给出了两种缺陷检测模型针对每种缺陷的单目标平均检测精度(查准率)测试对比结果。与以 CSPDarknet-53 为主干网络的 YOLOv4 相比,DBFF-YOLOv4 模型的缺陷检测性能较优,多余物 AP 提升 0.174%,断芯 AP 提升 0.03%,冷隔 AP 提升 9.09%,特别是针对断芯、气孔、裂纹和冷隔的 AP 高达 100%,冷隔缺陷的识别精度提升显著,而针对夹渣缺陷的识别精度偏低,夹渣缺陷 AP 下降 0.04%。

进一步研究了裁剪方法和数据增强对 DBFF-YOLOv4 模型检测性能的影响。表 7 给出了使用本研究提出的裁剪方法和数据增强的测试对比结果。结果表明,通过对缺陷图像的 9 次裁剪和数据增强,得到的缺陷检测模型的 mAP 和 mAR 均有显著提高。尤其是本研究的缺陷图像 9 次裁剪方法,使得训练数

据集数量大幅度增加,缺陷检测模型的性能得到了大幅度提高,mAP,0.5 置信度分数下 mAP 和 mAR 分别提高了 59.19%,27.01% 和 62.49%。本研究的数据增强方法(旋转、翻转、亮度增减)也有效提高了模型检测和分类的预测精度。结果表明,在使用 9 次缺陷裁剪的基础上再采用旋转、翻转、亮度增减的数据增强方法,使得模型的 mAP 从 97.05% 提高至 99.58%,提高了 2.53%。

虽然 DBFF-YOLOv4 模型在航空发动机叶片缺陷检测方面取得了令人满意的效果,但仍然存在漏检和误检。图 9 给出了可视化的测试结果示例,前两行为正确的缺陷检测结果(其中“S”表示夹渣,“DX”表示断芯,“DYW”表示剩余,“A”表示气孔,“C”表示裂纹,“CI”表示冷隔),后两行为漏检图片。结果表明,该缺陷检测模型无法检测出尺寸极小、轮廓过于模糊的缺陷。上述缺陷的特征非常微弱,包含的特征信息也很少,并且缺陷与背景相似,因而导致了检测失败。

上述建立的 DBFF-YOLOv4 缺陷检测模型的输入是像素尺寸为 256×256 的叶片裁剪图像,然而在实际的涡轮叶片 X 射线图像缺陷检测中,需要针对单个完整叶片图像进行检测。对此,在 DBFF-YOLOv4 缺陷检测模型之前和之后分别添加了一个图像切割模块和图像拼接模块,建立了针对完整涡轮叶片 X 射线图像直接进行缺陷检测及可视化输出的缺陷检测识别系统。该系统对完整涡轮叶片 X 射线图像进行缺

Table 5 Comparison results of mAP, mAR and FPS on different defect detection frameworks (%)

Model	mAP	mAR(T=0.5)	FPS
ResNet-50	96.63	68.53	47
CSPDarknet-53	98.04	91.85	38
DBFF-YOLOv4	99.58	91.87	26

Table 6 Comparison results of AP on each defect in different frameworks (%)

Model	Defect					
	Slag inclusion	Remainder	Broken core	Gas cavity	Crack	Cold shut
CSPDarknet-53	98.85	98.52	99.97	100	100	90.91
DBFF-YOLOv4	98.81	98.69	100	100	100	100

Table 7 Comparison results of mAP and mAR using data augmentation method (%)

One time of cropping	Nine times of cropping	Data augmentation	mAP	mAP (T=0.5)	mAR (T=0.5)
✓			37.86	70.71	28.78
✓		✓	40.72	73.16	33.44
	✓		97.05	97.72	91.27
	✓	✓	99.58	99.90	91.87

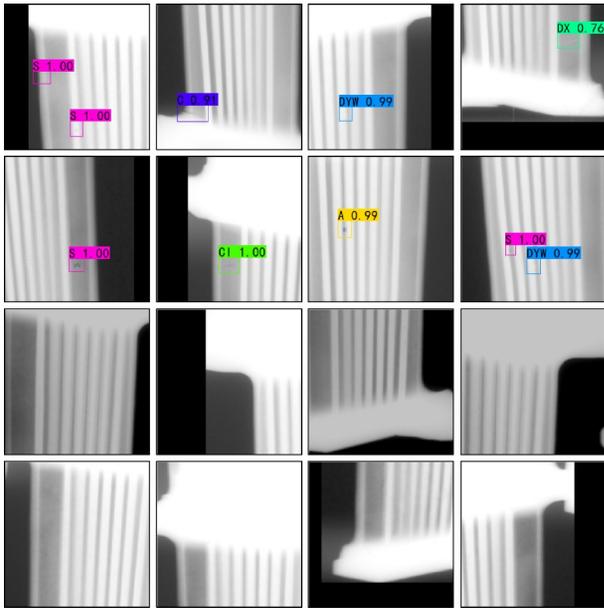


Fig. 9 Examples of visual test results

陷检测的流程为:(1)涡轮叶片 X 射线图像首先输入至检测系统的图像切割模块,切割模块计算输入图像尺寸,给图像四周加入黑边后进行固定尺寸为 256×256 的图像切割;(2)切割图像顺次输入至 DBFF-YOLOv4 缺陷检测模块进行缺陷检测识别,可视化输出每个切割图片的缺陷检测结果(缺陷类型、预测框);(3)拼接模块对可视化检测结果图片进行原位拼接,删除重合缺陷预测框,输出完整涡轮叶片 X 射线图像的最终检测结果。完整涡轮叶片 X 射线图像的缺陷检测流程如图 10 所示。最后选取了原始 427 张缺陷叶片图和 100 张完好叶片图对该检测系统进行了测



Fig. 10 Flow chart of defect detection of single turbine blade X-ray image

试,结果发现,在 0.5 的置信度分数下缺陷检测系统与 DBFF-YOLOv4 缺陷检测模型的查全率保持一致,为 91.87%,而查准率(检测精度)由原来的 99.9% 下降至 96.7%,针对 100 张完好叶片图像,系统误检率为 7%。该测试结果不难理解,缺陷检测系统在检测包含缺陷的固定像素尺寸(256×256)切割图片的同时,还检测了大量无缺陷的切割图片,对于一些形状、尺寸、对比度、明暗度与缺陷特征相似的部位(伪缺陷),DBFF-YOLOv4 缺陷检测模型将其预测成了缺陷,导致误检率上升,查准率下降。

4 结 论

本研究基于 YOLOv4 目标检测算法发展了一种双主干特征融合缺陷检测模型 DBFF-YOLOv4,并进行了模型测试和评估,可以得到以下结论:

(1)采用双主干特征提取网络及包含所有特征映射的级联 PAN 构建的 DBFF-YOLOv4 缺陷检测模型能有效提取涡轮叶片 X 射线图像的缺陷特征,对不同类别缺陷的平均查准率(*mAP*)可以达到 99.58%,在 0.5 的置信度分数下可以获得 99.9% 的 *AP* 和 91.87% 的 *AR*。

(2)与直接利用缺陷叶片图像训练 YOLOv4 模型相比,提出的 DBFF-YOLOv4 框架提高了模型复杂度,使得缺陷检测速度变慢,但缺陷检测性能得到了大幅度提升(*mAP* 提高了 68.31%)。

(3)本研究提出的缺陷图像 9 次裁剪和数据增强方法能大幅度提高模型的缺陷检测性能,*mAP* 分别得到了 59.19% 和 2.53% 的提升。

(4)建立的针对完整涡轮叶片 X 射线图像直接进行缺陷检测及可视化输出的缺陷检测识别系统在 0.5 的置信度分数下能够达到 91.87% 的平均查全率、96.7% 的平均查准率以及 7% 的误检率。

目前的缺陷检测模型在小尺寸和轮廓模糊的缺陷上仍然存在漏检和误检。进一步的工作将集中于小尺寸缺陷检测和微弱特征信息提取技术的研究。

致 谢:感谢中国航空发动机集团产学研合作项目及西北工业大学博士论文创新基金的资助。特别感谢中国航发西安航空发动机集团有限公司无损检测中心周文博、周笔文等,西北工业大学动力与能源学院于艾洋、唐珂、周磊等参与本研究的讨论及提供的帮助。

参考文献

[1] BALLAL D R, ZELINA J. Progress in aeroengine technology (1939-2003) [J]. Journal of Aircraft, 2004, 41

- (1): 43-50.
- [2] 李洪松, 刘永葆, 贺 星, 等. 考虑耦合损伤的燃气轮机叶片材料高低周复合疲劳寿命研究[J]. 推进技术, 2022, 43(2): 7-13. (LI H S, LIU Y B, HE X, et al. Combined high and low cycle fatigue life of Gas turbine blade materials considering coupling damage [J]. Journal of Propulsion Technology, 2022, 43(2): 7-13.)
- [3] PATTNAIK S, KARUNAKAR D B, JHA P K. Developments in investment casting process—a review[J]. Journal of Materials Processing Technology, 2012, 212(11): 2332-2348.
- [4] LAKSHMI M R V, MONDAL A K, JADHAV C K, et al. Overview of NDT methods applied on an aero engine turbine rotor blade [J]. Insight-Non-Destructive Testing and Condition Monitoring, 2013, 55(9): 482-486.
- [5] WU B, ZHOU J, JI X, et al. Research on approaches for computer aided detection of casting defects in X-Ray images with feature engineering and machine learning [J]. Procedia Manufacturing, 2019, 37: 394-401.
- [6] 马 源, 陈茂荣, 计效园, 等. 基于阈值分割的钛合金铸件 X 光图像缺陷检测[C]. 武汉: 2019 中国铸造活动周, 2019.
- [7] MERY D. Computer vision technology for X-Ray testing [J]. Insight(Northampton), 2014, 56(3): 147-155.
- [8] MERY D, ARTETA C. Automatic defect recognition in X-Ray testing using computer vision [C]. Santa Rosa: 2017 IEEE Winter Conference on Applications of Computer Vision(WACV), 2017.
- [9] FERGUSON M, AK R, LEE Y T, et al. Automatic localization of casting defects with convolutional neural networks[C]. Boston: 2017 IEEE International Conference on Big Data(big data), 2017.
- [10] FERGUSON M, AK R, LEE Y T, et al. Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning [J]. Products and Services, 2018, 2(1).
- [11] 时佳悦. 基于工业 CT 图像的工件缺陷智能检测技术研究[D]. 兰州: 兰州交通大学, 2017.
- [12] 常海涛, 苟军年, 李晓梅. Faster R-CNN 在工业 CT 图像缺陷检测中的应用[J]. 中国图像图形学报, 2018, 23(7): 1061-1071.
- [13] FUCHS P, KRÖGER T, DIERIG T, et al. Generating meaningful synthetic ground truth for pore detection in cast aluminum parts[C]. Padova: 9th Conference on Industrial Computed Tomography, 2019.
- [14] FUCHS P, KRÖGER T, GARBE C S. Self-supervised learning for pore detection in CT-scans of cast aluminum parts[C]. Fürth: International Symposium on Digital Industrial Radiology and Computed Tomography, 2019.
- [15] DU W, SHEN H, FU J, et al. Automated detection of defects with low semantic information in X-Ray images based on deep learning [J]. Journal of Intelligent Manufacturing, 2020, 32(1): 141.
- [16] DU W, SHEN H, FU J, et al. Approaches for improvement of the X-Ray image defect detection of automobile casting aluminum parts based on deep learning [J]. NDT & E International, 2019, 107: 102144.
- [17] LIN T, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Hawaii: 2017 IEEE Conference on Computer Cision and Pattern Recognition, 2017.
- [18] 马奇友, 刘可薇, 杜 坚, 等. 基于深度长短期记忆网络的发动机叶片剩余寿命预测 [J]. 推进技术, 2021, 42(8): 1888-1897. (MA Q Y, LIU K W, DU J, et al. Prediction of residual life of engine blades based on deep short term memory network [J]. Journal of Propulsion Technology, 2021, 42(8): 1888-1897.)
- [19] YAO Q, WANG J, YANG L, et al. A fault diagnosis method of engine rotor based on random forests [C]. Ottawa: 2016 IEEE International Conference on Prognostics and Health Management(ICPHM), 2016.
- [20] PANG S, YANG X, ZHANG X. Aero engine component fault diagnosis using multi-hidden-layer extreme learning machine with optimized structure [J]. International Journal of Aerospace Engineering, 2016, 2016(33): 1-11.
- [21] FENTAYE A D, BAHETA A T, GILANI S I, et al. A review on gas turbine gas-path diagnostics: state-of-the-art methods, challenges and opportunities [J]. Aerospace, 2019, 6(7): 83.
- [22] CHEN Z, JUANG J. AE-RTISNet: aeronautics engine radiographic testing inspection system net with an improved fast region-based convolutional neural network framework [J]. Applied Sciences, 2020, 10(23): 8718.
- [23] CHEN Z, JUANG J. Yolov4 object detection model for nondestructive radiographic testing in aviation maintenance tasks [J]. AIAA Journal, 2022, 60(1): 526-531.
- [24] ZHANG D, ZENG N, LIN L. Detection of blades damages in aero engine [C]. Shanghai: 2020 Chinese Automation Congress(CAC), 2020.
- [25] KIM Y, LEE J. Videoscope-based inspection of turbofan engine blades using convolutional neural networks and image processing [J]. Structural Health Monitoring, 2019, 18(5-6): 2020-2039.
- [26] SHEN Z, WAN X, YE F, et al. Deep learning based framework for automatic damage detection in aircraft engine borescope inspection [C]. Honolulu: 2019 International Conference on Computing, Networking and Communications(ICNC), 2019.

- [27] CHEN L, ZOU L, FAN C, et al. Feature weighting network for aircraft engine defect detection[J]. International Journal of Wavelets, Multiresolution and Information Processing, 2020, 18(3): 2050012.
- [28] HE W, LI C, NIE X, 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.
- [29] SHANG H, SUN C, LIU J, et al. Deep learning-based borescope image processing for aero-engine blade in-situ damage detection[J]. Aerospace Science and Technology, 2022, 123: 107473.
- [30] BOCHKOVSKIY A, WANG C, LIAO H M. Yolov4: optimal speed and accuracy of object detection [J/OL]. Computer Science, 2020, DOI: 10.48550/arXiv.2004.10934.
- [31] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Las Vegas: IEEE Conference on Computer Vision & Pattern Recognition, 2016.
- [32] KINGMA D P, BA J. Adam: a method for stochastic optimization [J/OL]. J-Stage, 2014, DOI: 10.48550/arXiv.1412.6980.

(编辑:白 鹭)

Automatic radiographic testing for aeroengine turbine blades based on deep learning

WANG Donghuan, XIAO Hong, WU Dingyi

(School of Power and Energy, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: Radiographic testing for aeroengine turbine blades usually depends on artificial detection. To avoid the influence of various artificial factors such as experience difference, eye fatigue and standard understanding, and to solve the problem of high cost, time consuming and low efficiency, a defect detection algorithm named DBFF-YOLOv4 was proposed for aeroengine turbine blade X-ray images by employing two backbones to extract hierarchical defect features based on YOLOv4. A novel concatenation form containing all feature maps was designed as the neck of defect detection framework. An automatic defect detection model for turbine blade X-ray images was established. Nine cropping cycles for one defect, flipping, brightness increasing and decreasing were applied for expansion of training samples and data augmentation. Finally, an automatic defect detection model was trained and test based on these defect samples. The results show that the defect detection model, which obtained 96.7% average precision and 91.87% average recall within the score threshold of 0.5 for complete turbine blade, outperformed others built by using the common object detection algorithm YOLOv4 directly. In addition, cropping nine times and data augmentation methods can significantly improve the defect detection accuracy of the model (mean average precision increased by 59.19% and 2.53% respectively). This study provides a new method of automatic radiographic testing for turbine blades.

Key words: Aeroengine; Turbine blade; Deep learning; Defect detection; Radiographic testing; X-ray images

Received:2022-10-10; Revised:2023-03-20.

DOI:10.13675/j.cnki.tjjs.2210024

Foundation items: Industry-University-Research Collaboration Project of AECC(HFZL2019CXY008-1; HFZL2021CXY017).

Corresponding author: XIAO Hong, E-mail: xhong@nwpu.edu.cn