

DOI: 10.19650/j.cnki.cjsi.J2311240

叶片型面视觉检测系统设计与实现*

杨亚东¹, 刘鹏², 周光亮¹, 陈启军¹, 李游²

(1. 同济大学电子与信息工程学院 上海 201804; 2. 中航商用航空发动机有限责任公司 上海 200241)

摘要:航空发动机压气机叶片审理和验收是其研制周期中不可或缺的环节,为改善传统人工叶片审理流程费时费力、不确定性高等问题,设计了一种基于机器视觉的发动机叶片型面检测系统。首先,针对工业生产中普遍使用的三坐标检测仪叶片测量法,完成对便携文件格式的批量图像提取,并利用颜色匹配和霍夫变换的方法完成叶片图像的超差判断;其次,对于无超差的叶片图像,利用颜色匹配和形态学算子等手段完成叶片图像的增强,提高有效信息占比,并训练残差网络完成叶片前后缘形态异常的分类任务;最后,针对大量图像数据的标注任务,设计普适性高的图像分类标注程序,并设计叶片质量检测程序在叶片图像数据集上验证了系统对叶片超差判断和异常识别的有效性。实验表明,该系统对叶片有超差和无超差异常的识别准确率分别达到100%和92.9%,可以满足工业生产实际需求。

关键词:残差网络;图像处理;发动机叶片;计算机视觉

中图分类号: TH164 TH721 **文献标识码:** A **国家标准学科分类代码:** 460.40

Design and implementation of the blade profile detection system based on computer vision

Yang Yadong¹, Liu Peng², Zhou Guangliang¹, Chen Qijun¹, Li You²

(1. College of Electronics and Information Engineering, Tongji University, Shanghai 201804, China;

2. AECC Commercial Aircraft Engine Co. Ltd., Shanghai 200241, China)

Abstract: The review of aero-engine compressor blades is an indispensable part of its development cycle. To improve the traditional manual blade review process, which is time-consuming, laborious, and highly uncertain, an engine blade profile detection system based on computer vision is designed. Firstly, to achieve the blade measurement of three-coordinate detector commonly used in industrial production, the batch image extraction for portable document format is completed. The out-of-tolerance judgment of blade image is completed by using color matching and Hough transform. Secondly, for the blade image within tolerance, color matching and morphological operators are used to enhance the blade image, which improves the ratio of valuable information. A residual network is trained to complete the task of morphological anomaly detection of the blade edges. Finally, to facilitate the labeling task on a massive image dataset, a universal image classification and labeling program is designed, and a blade quality detection program is designed to verify the effectiveness of the system for blade out-of-tolerance judgment and anomaly recognition on the blade image dataset. The experiment shows that the accuracy of the system for identifying anomalies in blades with or without out-of-tolerance reaches 100% and 92.9%, respectively, which could satisfy actual needs of industrial production.

Keywords: residual network; image processing; engine blade; computer vision

0 引言

航空发动机压气机叶片审理和验收是其研制周期中不可或缺的环节。发动机叶片工作时处于高温、高压和

高转速的极端环境中,叶片受力恶劣、承载最大,故其加工质量优劣直接关系到发动机的性能和可靠性。因此,对叶片型面进行检测以控制叶片加工质量尤为重要。

当前工业生产中普遍采用三坐标检测仪测量发动机叶片不同截面的叶缘轮廓,并基于此人工判断叶片质量。

三坐标测量仪作为坐标测量技术的典型代表,是一种集机械、电子、光学、计算机、数字控制等先进技术于一体的大型高精度智能化测量仪器。该仪器通过坐标测量机测量叶片轮廓上各被测点的坐标值,并利用数据建模等分析手段,可得到被测叶片的几何形状和形状误差等参数。利用该仪器进行叶片测量,具有检测精度高、检测重复性好、自动化程度高等优点,是当前叶片检测手段中精度最高的一种^[1-2]。

在信息化和工业化深度融合的背景下,传统的人工审查体系已经难以满足工业生产的需求。在传统的叶片审理流程中,审查人员根据叶片供应商利用三坐标检测仪检测得到的不同叶高截面的叶型评价参数和叶型轮廓检测图,逐一进行审查。该过程不仅效率低,消耗大量人力资源,且由于不同审查人员的主观标准差异,容易造成验收叶片质量的参差不齐。此外,人工审查还会引入人为因素,带来漏判、误判等不确定性误差,给叶片验收工作带来不便。

图像处理、卷积神经网络(convolutional neural network, CNN)等计算机技术的迅速发展赋能发动机叶片质量检测系统。近年来,深度学习发展迅速,基于卷积神经网络的算法被大量用于计算机视觉任务,叶片检测任务也是如此。图像处理技术和深度学习算法已经被应用于发动机叶片缺陷检测^[3-11],并取得一定成果,但主要是针对叶身裂缝识别,在叶型审理上应用不多。

基于卷积神经网络的典型图像分类算法包括:LeNet^[12]、AlexNet^[13]、VGG^[14]、GoogLeNet^[15]、ResNet^[16]和 MobileNet^[17]。

Lecun 等^[12]提出了一种基于卷积神经网络的手写数字识别方法 LeNet-5 是卷积神经网络模型的鼻祖。LeCun 等利用卷积神经网络提取手写数字图像中的特征信息,并迭代优化网络参数,训练模型拟合数字分类映射,在当时银行支票自动化识别中得到了广泛应用。

Krizhevsky 等^[13]提出了一种深度卷积神经网络模型 AlexNet,是第一个现代深度卷积模型。该网络首次使用 GPU 进行网络加速;使用 ReLU 激活函数和局部归一化缓解梯度消失问题;引入 Dropout 层防止过拟合。在 2012 年大规模视觉识别挑战(large scale visual recognition challenge, LSVRC)竞赛中位列第一。

Simonyan 等^[14]提出了一系列卷积神经网络模型 VGG,在 2014 年 LSVRC 竞赛中位列第二。相较于 AlexNet 模型,VGG 深度更深,参数更多,验证通过增加网络层数提高网络性能的可能性。但也正由于其规模较大,对硬件资源的要求较高,不适合低算力系统。

Szegedy 等^[15]提出一种深层卷积神经网络模型 GoogLeNet,在 2014 年 LSVRC 竞赛中位列第一。GoogLeNet 模型首创 Inception 模块,形成了串并联新网络结构,引入稀疏特性,降低参数数量,提高模型的泛化能力,有效防止过拟合现象的产生。

VGG 和 GoogLeNet 均通过增加网络层数来增强网络对复杂特征的学习能力,以此提高网络分类准确性。然而,实验中发现网络性能存在饱和,之后继续增加层数性能不升反降,被称为网络的退化问题。He 等^[16]提出了一种 ResNet 网络模型,借助跳跃连接(skip connection)的结构有效解决了网络退化问题。

针对低算力平台,Howard 等^[17]提出一种规模较小且效率较高的卷积网络模型 MobileNet。在 ImageNet 数据集上的实验结果表明,相较于 VGG-16 模型,其在分类准确率下降 0.9%的同时,模型参数仅为 3.1%,大大提高了网络训练和推理速度,便于嵌入式平台移植。

由于以上社会因素和科技因素的推动作用,本文旨在设计一种叶片质量自动审理系统,助力工业社会的信息化进程。本系统的使用将取代传统人工审理模式,对于释放人力资源、提高验收效率、消除人为误差和提高叶片验收质量具有重要价值。

本论文主要内容分为 4 部分:1)分析总结影响叶片质量的主要参数,根据异常是否含超差将其归类为超差异常和形态异常,并对超差异常和形态异常分别做了简要的介绍;2)针对工业生产中普遍使用的三坐标检测仪叶片测量法,系统首先完成 PDF 格式文件的批量图像提取,并利用颜色匹配和霍夫变换的方法判断叶片是否存在超差;对于无超差的叶片图像,利用颜色匹配和形态学算子等手段完成叶片图像的增强,消除公差带和坐标轴,加粗叶片轮廓曲线,然后训练 ResNet 网络完成叶型形态异常的检测任务;3)针对大量图像数据的标注任务,设计了普适性好的图像分类标注和训练可视化程序,并设计易用性和可操作性好的叶片质量检测可视化程序;4)收集并整理了某公司长期沉淀的叶型轮廓数据样本,制作叶片识别数据集,并在该数据集上验证了系统对叶型超差异常和形态异常识别的有效性,准确率分别达到 100%和 92.9%,可以满足工业生产需求。

1 发动机叶片型面异常概述

发动机叶片型面异常是指叶片的截面轮廓与标准轮廓相差较大或叶片的空气动力学特性对发动机的正常运转造成不良影响。

根据主要评价参数的不同,叶片型面异常主要可以分为两类:超差异常和形态异常。表 1 中参数 1~7 具有明确的公差范围限制,超出上下公差带将直接导致叶片的物理结构不符合要求,可能影响叶片的安装等;而参数 8~12 则会影响叶片的空气动力特性,导致发动机运转不平衡,形成风量小,振动大,噪音高,从而缩短使用寿命。

表 1 叶型评价主要参数表

Table 1 Major evaluation parameters of blade profile

编号	参数列表
1	最大厚度(MAX THICK)
2	前缘厚度(LE THICK)
3	尾缘厚度(TE THICK)
4	弦长(CHORD)
5	位置度 X(STACK X)
6	位置度 Y(STACK Y)
7	位置度(SFT T)
8	弯曲度(BOW TOTAL)
9	换算扭转角(ALT WARP)
10	前缘轮廓度(LP)
11	尾缘轮廓度(TP)
12	叶身轮廓度(AP)

超差异具有明确的量化手段和判断标准。叶片生产时对主要的 9 个截面都计算了理论轮廓位置,并根据最大公差确定上下公差带,利用三坐标检测仪测量叶片截面轮廓,其任意部分超出上下公差带范围都将导致叶片存在超差异。图 1 是某一截面叶型的理论轮廓、实际轮廓与上下公差带示意图。




图 1 某一截面叶型轮廓图

Fig. 1 Profile drawing of a certain section

而与此不同的是,形态异常没有明确的量化标准,更多依赖审理和验收人员的经验和认识。如图 2 所示,形态异常主要可以分为“歪头”、“缩颈”、“尖头”、“平头”、“鼓包”、“切角”6 类。通常叶片的形态异常为这 6 类的相互组合,无法单一归类为某一具体类别,故本文对这 6 种情形不做具体区分,统一归类为形态异常。

2 叶型异常检测算法

本文设计了一套发动机叶片叶型轮廓的异常检测算法如图 3 所示,涵盖了上述所定义的超差异和形态异常。算法首先检查叶片是否存在超差异,没有超差则




图 2 形态异常示意图

Fig. 2 Diagram of morphological anomalies




图 3 叶型异常检测算法流程

Fig. 3 Flowchart of the blade anomaly detection algorithm

进一步检查叶片是否存在形态异常,最终审理判定叶型轮廓为正常或异常。

2.1 叶片数据批量提取

叶片供应商在利用三坐标检测仪完成其叶片的测量后,所提供的叶片数据文件通常为 PDF 格式,无法直接用于图像处理任务,故首先需要从中提取叶缘轮廓图像。以 10 级压气机,每一叶片检测 9 个截面为例,叶型轮廓检测图约有 15 000 张之多,人力提取费时费力,因此使用计算机技术批量化提取。

本文使用 PyMuPDF 工具从 PDF 文件中截取图像。该模块可为 Python 提供 MuPDF 的实例功能,以其渲染 PDF 文件的顶尖性能和杰出质量而著称。在提取图像前需配置渲染参数位置参数,其中包括旋转角度、横纵缩放比和截取坐标位置,可根据所用三坐标检测仪的品牌和型号自行设置。以工业生产中常用的 Blade Pro 三坐标检测仪输出文件为例,其旋转角度为 0, x 和 y 方向缩放系数均为 3,叶片图像左上角和右下角的归一化坐标为 (0.035,0.100) 和 (0.650,0.922),效果如图 4 所示。




图 4 PDF 页面提取效果
Fig. 4 PDF page extraction rendering

2.2 叶型超差异常检测

叶缘轮廓图中超差部分以红色显示,因此对叶型的超差异常检测基于图中红色像素完成。本文根据图像的颜色特征,设定阈值检测红色像素,并利用霍夫直线检测提取其中的线段部分,排除圆形偏差极值指示点的干扰。

如图 5 所示,设定红、绿、蓝三通道阈值分别为 $R>190$, $G<100$ 和 $B<100$,基于此阈值对原始图像的像素逐一进行判断提取后得到二值化的红色像素图像如图 5(b)所示。由于图中圆形轮廓的干扰无法直接根据二值化图像中是否包含白色前景像素点判断叶片是否超差,因此需要利用霍夫直线变换检测其中的线段部分。




图 5 超差检测效果

Fig. 5 Out-of-tolerance detection rendering

霍夫变换是一种提取待检测图像中图形形状特征的方法,如直线、圆和椭圆等,被广泛应用于数字图像处理和计算机视觉等领域。这一识别过程在“霍夫空间”中进行,并通过累加器的局部最大值提取所期望的形状特征。其优点在于抗噪声能力强,且不受图形间断的影响。二维直线的霍夫检测方法如下:

将直线 $y = mx + b$ 表示成 Hesse 法线式的形式为:
$$\rho = x \cos \theta + y \sin \theta \tag{1}$$

其中, ρ 为坐标系原点到直线的距离, θ 为原点到直线的垂线段与 x 轴的夹角。该式将一条直线与霍夫空间中的一对参数 (ρ, θ) 相关联。而将点映射到霍夫空间将对应一组参数,表现为一条曲线,从而将检测直线的问题转化为求相交次数最多的霍夫空间内一点的问题。

本文中设定霍夫直线检测距离分辨率为 1,角度分辨率为 1° ,累加器阈值参数为 15,最短检测线段长度为 10,线段间最大间隔为 5,最后得到的直线检测结果如图 5(c)所示。由于圆形轮廓被转换至霍夫空间后,代表原轮廓上各点的曲线之间交点较为稀疏,而同一条直线上各点经转换后形成的曲线间交点更为集中,在霍夫空间内根据预设的分辨率遍历所有点,并利用累加器判断各点的曲线相交次数,就可以判断原始像素点是否属于直线,实现圆和直线的分离。如图 5(c)所示,利用霍夫直线检测成功滤去了圆形轮廓,因此后续可直接根据图像中是否剩余前景像素判断叶型是否超差,例如该图中存在白色的前景像素,则表明该叶型存在超差。

2.3 叶型形态异常检测

提取到的叶缘轮廓图像利用超差判断排除含有超差的图像后,剩余的叶片图像中仍可能存在尖头、平头和切角等异常情况。这些异常叶片在气动力学上不符合工业生产标准,容易老化损坏,甚至造成生产事故,故需进一步对这些异常叶片进行识别。叶型形态异常检测主要分为图像预处理与分类推理两部分。

叶型形态异常主要由理论轮廓和实际轮廓之间的关系,以及实际轮廓的弯曲度等因素决定。而原图像中两条轮廓曲线较细,在整幅图中占比较小,有效信息过于稀疏,且图中还存在着灰色公差带和黑色坐标轴以及文字标识等与判断叶片异常无关的冗余信息,容易对叶片异常识别造成干扰,因此首先需要对原始图像进行预处理。预处理步骤首先遍历图中像素,判断 RGB 三通道像素值相等以匹配灰、黑色像素,并将 RGB 三通道全部设为 255,修改其为白色;其次利用核大小为 5 的形态学腐蚀算子加粗轮廓曲线,放大曲线特征;最后缩放图像尺寸至原图像的 1/4,以降低网络推理计算量,提高推理速度。图 6 中展示了预处理的图像增强效果。




图6 叶缘预处理效果

Fig. 6 Blade edge preprocessing rendering

叶型形态异常的分类推理部分利用卷积神经网络 ResNet^[16]模型完成。传统神经网络随着层数的增加会发生梯度消失、梯度爆炸和网络退化的问题,因而深层网络的推理能力反而不及较浅层网络。ResNet 则很好地解决了这一问题,使得增加网络层数可以直接提高网络性能,被广泛应用于各类图像分类任务。

ResNet 中的残差模块由 2 个卷积层组成,且模块直接从输入引出一条路径连接至输出部分充当恒等映射层,降低了原网络利用各层非线性变换拟合恒等映射的难度,网络学习的目标从原来的目标映射 $H(x) = F(x) + x$,变为目标映射 $H(x)$ 与已经学习到的内容 x 之间的残差 $F(x) = H(x) - x$,大大提高了网络性能。

当多个残差模块连接成为残差网络时,可推导网络的前向传递关系:

$$x_L = x_l + \sum_{i=l}^{L-1} F(x_i) \quad (2)$$

任意深层 L 和浅层 l 之间的输入之间仅相差中间各层的残差之和 $\sum_{i=l}^{L-1} F(x_i)$,也就是说浅层的信息可以更容易地被传递至高层,也就减少了网络间信息传递过程中信息损失。由此可以推出网络的反向传播关系:

$$\frac{\partial \text{loss}}{\partial x_l} = \frac{\partial \text{loss}}{\partial x_L} \frac{\partial x_L}{\partial x_l} = \frac{\partial \text{loss}}{\partial x_L} + \frac{\partial \text{loss}}{\partial x_L} \frac{\partial}{\partial x_l} \sum_{i=l}^{L-1} F(x_i) \quad (3)$$

该关系表明深层梯度信息 $\frac{\partial \text{loss}}{\partial x_L}$ 可以直接反向传播回浅层,且 $\frac{\partial}{\partial x_l} \sum_{i=l}^{L-1} F(x_i)$ 不恒等于 -1 ,因此避免了梯度消失的问题。

经典的 ResNet 网络结构有 ResNet-18、ResNet-34、ResNet-50、ResNet-101、ResNet-152 这 5 种,网络层数和参数量逐级增加,受限于目标部署平台算力,本文使用 ResNet-18 这一轻量级残差网络模型,实验表明这一轻量级模型可以满足实际需求。

ResNet-18 整体包含 8 个残差模块,每个残差模块包含 2 层卷积,加上图像输入的 1 个卷积层和输出的 1 个全连接层,总计共 18 层网络。本文训练 ResNet18 模型拟合叶缘图像形态分类器,设置网络输入为预处理后的

增强图像,其维度为 $3 \times 224 \times 224$,输出为 4 个类别,即图像属于前缘正常、前缘异常、后缘正常和后缘异常的置信度。依据各类的置信度就可以初步判别叶型是否存在形态异常。

系统最终的目的是尽可能多地筛选出可能存在异常的叶片,防止漏检造成经济损失,因此网络的分类结果不能直接作为输出。对于分类正常的叶型轮廓,还需进一步检查置信度,只有置信度足够高的正常叶型才会被最终归类为正常,否则都将被判定为异常叶型。如本文中,若残差网络的输出结果中,叶型为前缘正常或后缘正常的置信度最高,需进一步判断属于正常的置信度高于 0.9,否则将作为对应前或后缘位置的异常叶型处理。

3 系统设计与实现

本文利用 PyQt 和多线程技术设计并实现了标注训练系统与异常检测系统,分别供开发调试和实际检测使用。

3.1 标注及训练系统

为方便叶型形态异常检测训练工作,本文设计和实现了叶型的标注和训练程序如图 7 所示,其功能特点如下:

1) 叶型标注。程序可批量提取叶型轮廓图像,自动剔除超异常叶型轮廓,并对无超差的叶型轮廓进行图像增强处理,显示于程序界面中。用户可直接选择其类别进行分类,程序将根据该类别保存图像至指定位置。对于数据量太多一次难以标注完成的,程序支持断点续标功能。

2) 数据集生成。根据用户指定已分类图像地址和输出数据集地址,以及预先设定训练集验证集比例,程序可一键随机按比例生成用于分类网络训练的训练集和验证集。

3) 网络训练。程序可设定训练代数以及批大小,结合预先设定网络模型,可一键以子线程的形式开始网络训练,并于程序消息窗口实时滚动输出训练详细信息。

一般的图像分类任务均包括人力标注,划分数据集和网络训练 3 个部分,因此该标注及训练可视化界面不仅适用于本文异常叶型检测任务,也普遍适用于一般的图像分类任务,具有很好的可拓展性和可复用性。

3.2 异常检测系统

本叶型异常检测系统纵向可分为 4 层,由下至上分别为数据层、技术层、业务层和交互层。数据层包含本文中所收集的三坐标检测仪发动机叶片数据,在本文数据




图 7 标注及训练系统

Fig. 7 Labeling and training system

驱动的叶片检测系统中处于基石地位;技术层涵盖了图像处理与计算机视觉方面的一系列技术手段,支撑本系统的开发实现;业务层为本系统功能的具体实现,如上

1 节所介绍;此外,为了提高系统的易用性和可操作性,本文还开发了交互层如图 8 所示,便于用户使用。该系统具备以下功能特点:




图 8 异常检测系统

Fig. 8 Anomaly detection system

- 1) 自动填充。程序保存历史检测叶片种类、PDF 类型和输入输出路径,并于程序启动时读取历史信息,若存在则自动填充。使用时即可将待检测文件放入指定文件夹一键开始,减少重复操作步骤。
- 2) 文件检索。输入路径既可以是待检测文件精确路径,也可以是包含文件的文件夹路径。当用户指定输入

- 路径为文件夹时,程序自动遍历文件夹内所有文件及所有子文件夹内文件,检索全部叶型轮廓 PDF 文件,并对文件内每页进行截取检测,实现批量化检测,提高效率。
- 3) 多线程技术。叶片的数据提取、超差判断、图像增强和形态异常识别均在子线程中进行,并通过标志位返回检测状态,避免对主程序界面的响应性造成影响。

- 4) 图像查看。检测过程中保存所有异常叶型轮廓,包括超差异常和形态异常;并对轮廓图像进行图像增强,以突出显示叶缘轮廓,方便人工二次审理。软件中可循环查看本次检测所有异常轮廓图,且能够进行自适应缩放。
- 5) 状态反馈。基于信号槽技术实时获取检测线程的状态和检测结果,于程序消息窗口中滚动显示。
- 6) 结果输出。向指定的结果路径保存本次检测的详细信息,包含所有文件异常叶型的数量和具体位置。

4 实验验证

4.1 叶型异常数据集

网络的训练往往需要大量数据的支撑,这其中涉及到庞大、枯燥的标注工作,且本文叶缘图像还需要进行数据提取和预处理等操作,工序繁杂。本文收集了工业生产过程中沉淀的大量叶型轮廓图数据样本,并进行了数据标签的映射,整理出用于叶型异常检测的数据集,具体信息总结如表 2 所示。其中 le_good, le_bad, te_good, te_bad 分别表示前缘正常,前缘异常,后缘正常和后缘异常。

表 2 叶片识别数据集统计表

Table 2 Statistical table of blade detection dataset				
图像类别	le_good	le_bad	te_good	te_bad
轮廓图/张	1 858	2 288	2 202	2 178

4.2 形态异常检测网络训练

网络训练数据集和验证集为总数据集的 80%,剩余 20% 留作测试集。网络中的各项参数取值总结如表 3 中所示。

表 3 网络训练参数表

Table 3 Parameters for network training		
参数	取值	说明
arch	resnet18	网络架构
epochs	32	代数
batch_size	5	批大小
lr	4×10^{-4}	学习率
momentum	0.9	动量
weight_decay	1×10^{-4}	权重衰减
optimizer	SGD	优化器
criterion	CrossEntropyLoss	损失函数
scheduler	ReduceLROnPlateau	调度器

网络训练过程中损失函数的变化曲线和验证集上准确率的变化曲线如图 9 所示。其中随着网络迭代次数的增加,损失函数的取值整体呈下降趋势,表明网络能够正确学习图像特征并优化网络参数;而验证准确率在前 31 个 epoch 上升,并达到最大值 99.97%,随后的下降则说明网络发生过拟合现象,泛化能力降低。




图 9 网络训练曲线

Fig. 9 Network training results diagram

4.3 叶型超差异常检测实验

实验对总计 3 000 张的叶片图像进行了超差判断实验,其中有超差的图像 273 张,无超差的图像 2 727 张,最终所有的叶片图像均能正确判断超差,在超差判断上的准确率可达到 100%。其混淆矩阵如图 10 所示。图 11 为部分叶片的超差检测结果局部放大图,其中虚线圈出的部分即为叶片存在超差的位置,算法有效地识别到了叶型中存在的超差异常。




图 10 超差判断混淆矩阵

Fig. 10 Confusion matrix of out-of-tolerance judgement




图 11 超差检测结果局部放大图

Fig. 11 Partial enlarged out-of-tolerance detection results

4.4 叶型形态异常检测实验

实验在所收集的叶片数据集上进行了异常识别测试,测试集中的数据独立于训练集和验证集。待分类的叶片图像共有4类,分别为叶片前后缘的正常和异常,图12为在各类上的精度和召回曲线。由于叶片前缘曲率较大,其异常情况较为明显,故模型对前缘异常识别的精度和召回整体高于后缘。此外,实验绘制了各类的精度-召回曲线如图13所示,前缘上性能较好,曲线整体包围后缘,同时各类曲线下面积均接近于1,整体识别效果满足需求。




图12 异常识别精度与召回曲线

Fig. 12 Precision and recall curve of anomaly recognition




图13 异常识别 P-R 曲线

Fig. 13 P-R curve of anomaly recognition

图14为叶片异常识别的混淆矩阵。由图14可知模型对前缘异常和正常的分类准确率接近100%,而对后缘分类的准确率分别为84.6%和89.8%;所有错误情况均为同一部位叶片的正常、异常判断错误问题。




图14 异常识别混淆矩阵

Fig. 14 Confusion matrix of anomaly recognition

表4为各类准确率统计表。其中准确率最高的是前缘异常类达到100.0%,准确率最低的是后缘异常类仅有84.6%,在叶片异常识别上的平均分类准确率为92.9%,基本满足工业生产需求。

表4 异常识别分类准确率统计

Table 4 Statistical table of anomaly recognition accuracy

图像类别	le_bad	le_good	te_bad	te_good	均值
样本数/正确识别数	458/458	363/372	369/436	395/440	1 585/1 706
准确率/%	100.0	97.6	84.6	89.8	92.9

图15展示了部分实际叶片的叶型异常检测结果,由图15可知网络并非仅仅依据理论与实际两条轮廓曲线相对误差进行判断,而是综合考虑了实际轮廓的形状轮廓的平滑度,显示出算法对叶型异常检测的有效性。




图15 叶型异常检测结果局部放大图

Fig. 15 Partial enlarged images of anomaly detection results

5 结 论

本文设计了一种基于机器视觉的发动机叶片质量检测系统,可提高叶片审理环节效率和准确率。该系

统首先完成 PDF 格式文件的批量图像提取,并利用颜色匹配和霍夫变换的方法判断叶片是否存在超差;其次,对于无超差的叶片图像,经过图像预处理完成叶片图像的增强,并训练 ResNet 网络完成叶片前后缘形态异常的分类任务;此外,本文还设计了普适性较好的图像分类标注程序,以及叶片质量检测的推理程序,易用性和可操作性高;最后,在叶片图像数据集上验证了系统对叶片超差异常和形态异常识别的有效性,准确率分别达到 100% 和 92.9%。下一步的工作需要在数据提取时精炼数据,直接提取各条曲线轮廓信息而非整张图像,进一步降低信息冗余度,减小计算开销,提高审理效率。

参考文献

- [1] 俞学兰, 叶佩青. 航空发动机压气机叶片型面检测技术[J]. 航空制造技术, 2007(11):44-48.
- YU X L, YE P Q. Aero-engine compressor blade profile detection technology [J]. Aeronautical Manufacturing Technology, 2007(11):44-48.
- [2] 李进. 航空发动机叶片的型面质量测量方法对比[J]. 中国新技术新产品, 2015(18):6.
- LI J. Comparison of measurement methods for aeroengine blade profile quality [J]. New Technology & New Products of China, 2015(18):6.
- [3] 唐震, 彭业萍, 王伟江, 等. 融合 Hough 直线检测和 Grab-cut 的风机叶片自适应分割方法[J]. 电子测量与仪器学报, 2021, 35(4):161-168.
- TANG ZH, PENG Y P, WANG W J, et al. Adaptive segmentation method for wind turbine blades combining Hough line detection and Grab-cut algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(4):161-168.
- [4] 何赞泽, 张帆, 刘昊, 等. 风机叶片无人机红外热图像拼接方法[J]. 电子测量与仪器学报, 2022, 36(7):44-53.
- HE Y Z, ZHANG F, LIU H, et al. Infrared image stitch method of wind turbine blade based on UAV[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7):44-53.
- [5] LI X, WANG W, SUN L, et al. Deep learning-based defects detection of certain aero-engine blades and vanes with DDSC-YOLOv5s[J]. Sci Rep, 2022(12):13067.
- [6] 孙彬, 王建华, 赫东锋, 等. 基于激光测量的航发叶片表面几何缺陷识别技术[J]. 自动化学报, 2020, 46(3):594-599.
- SUN B, WANG J H, HE D F, et al. Identification of aero-engine blade surface geometric defects with laser measurement [J]. Acta Automatica Sinica, 2020, 46(3):594-599.
- [7] 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. DOI: 10.1016/j.ast.2022.107473.
- [8] WANG M H, LU S D, HSIEH C C, et al. Fault detection of wind turbine blades using multi-channel CNN[J]. Sustainability. 2022, 14(3):1781.
- [9] XIE T, WANG T Z, HE Q, et al. A review of current issues of marine current turbine blade fault detection[J]. Ocean Engineering, 2020, 218:108194.
- [10] PAN X, XIANG T, HE Y, et al. A crack detection method for aero-engine blade based on air-flow thermography[J]. Journal of Nondestructive Evaluation, 2023, 42:22.
- [11] TAN X, ZHANG G. Research on surface defect detection technology of wind turbine blade based on UAV image[J]. Instrumentation, 2022, 9(1):41-48.
- [12] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6):84-90.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014.
- [15] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper

with convolutions [C]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015;1-9.

- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2016;770-778.
- [17] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. ArXiv Preprint, 2017, DOI:10.48550/arXiv.1704.04861.

作者简介



杨亚东, 2022 年于同济大学获得学士学位, 现为同济大学电子与信息工程学院控制科学与工程专业硕士研究生, 主要研究方向为计算机视觉与图像处理。

E-mail: 2230701@tongji.edu.cn

Yang Yadong received his B.Sc. degree from Tongji University in 2022. He is currently pursuing his M. Sc. degree in the College of Electronics and Information Engineering at Tongji University. His main research interests include computer vision and image processing.



E-mail: guitar_liu@163.com

Liu Peng received his B.Sc. degree in 2015 from Northwestern Polytechnical University, received his M.Sc. degree in 2018 from Northwestern Polytechnical University, now he is an engineer in charge in AECC CAE. His main research interest is compressor aerodynamic design.



知等。

E-mail: qjchen@tongji.edu.cn

Chen Qijun (Corresponding author) received his B.Sc. degree from Huazhong University of Science and Technology in 1987, M.Sc. degree from Xi'an Jiaotong University in 1990, and Ph.D. degree from Tongji University in 1999. He is currently a full professor in the College of Electronics and Information Engineering at Tongji University. His research interests include robotics control, environmental perception, et al.

刘鹏, 2015 年于西北工业大学获得学士学位, 2018 年于西北工业大学获得硕士学位, 现为中航商用航空发动机有限责任公司主管工程师, 主要研究方向为压气机气动设计。

陈启军 (通信作者), 1987 年于华中科技大学获得学士学位, 1990 年于西安交通大学获得硕士学位, 1999 年于同济大学获得博士学位, 现为同济大学电子与信息工程学院教授, 主要研究方向为机器人控制、环境感知等。