

DOI: 10.19650/j.cnki.cjsi.J2413444

稀疏数据驱动的涡轮叶片表面裂纹长度提取方法*

李茂月^{1,2}, 雷金超^{1,2}, 张成龙^{1,2}, 刘泽隆^{1,2}

(1. 哈尔滨理工大学先进制造智能化技术教育部重点实验室 哈尔滨 150080; 2. 哈尔滨理工大学
机械动力工程学院 哈尔滨 150080)

摘要: 航发涡轮叶片裂纹的长度测量是裂纹危险等级评判的基础和修复的前提。针对涡轮叶片表面裂纹形状不规则、目标小、数据集样本稀少和裂纹成像角度失真等问题, 提出一种稀疏数据驱动的涡轮叶片表面裂纹长度提取方法。首先, 为提升 Unet 模型在处理稀疏数据时的精度, 采用 GeLu 函数与 Vgg16 网络结合的方法提取裂纹特征, 将输出作为 Unet 网络解码部分的输入, 保证模型匹配的前提下, 在随机初始化权重中引入预训练权重, 并在跳跃连接层中引入高效金字塔压缩注意力模块, 增强模型在复杂背景下对裂纹特征的聚焦能力。然后, 为了得到裂纹的单位像素特征曲线, 在精分割后提出使用八邻域骨架化保留裂纹的主干特征结构。最后, 深入分析了相机成像原理, 讨论了叶片弦线角和相机自身参数对裂纹长度的测量影响, 采用张正友标定法求解相机内部参数, 建立了像素尺寸与实际尺寸转换模型。实验结果表明, 与 X 光测量相比, 该方法在测量距离为 100~300 mm 时, 得到的裂纹长度最大误差为 6.8%, 证明该方法在测量涡轮叶片表面裂纹长度中对 X 光检测技术具有可替代性; 与原算法相比, 改进的算法在针对稀疏数据检测时精度显著提高, 平均交并比提升了 7.14%。所提出的涡轮叶片裂纹长度提取方法, 为叶片质量评估及后续修复提供了理论基础和数据支持。

关键词: 稀疏数据; 深度学习; 裂纹; 涡轮叶片; 相机标定

中图分类号: TH741 **文献标识码:** A **国家标准学科分类代码:** 460.4035

A sparse data-driven method for extracting surface crack length of turbine blade

Li Maoyue^{1,2}, Lei Jinchao^{1,2}, Zhang Chenglong^{1,2}, Liu Zelong^{1,2}

(1. Key Laboratory of Advanced Manufacturing and Intelligent Technology, Ministry of Education, Harbin University of Science and Technology, Harbin 150080, China; 2. School of Mechanical and Power Engineering, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: The measurement of crack length is fundamental to the evaluation of crack risk and a prerequisite for crack repair. Aiming at the problems of irregular shapes, small target, sparse data sets and distortions of crack imaging angle, a sparse data driven method was proposed to extract the surface crack length of turbine blades. Firstly, to enhance the Unet model's precision in handling sparse data, we employ a combination of the GeLu function with the Vgg16 network for feature extraction. The extracted features then serve as inputs for the Unet network's decoding process. To ensure model compatibility, we incorporate pre-trained weights into the randomly initialized weights and integrate an efficient pyramid compression attention module into the skip connection layer. This approach significantly improves the model's capability to focus on crack characteristics amidst complex backgrounds. Then, in order to get the unit pixel characteristic curve of the crack, after the fine segmentation, a skeleton structure with eight neighborhood is proposed to preserve the crack backbone characteristic structure. Finally, through an in-depth analysis of camera imaging principles, we discuss the impact of blade chord angles and camera parameters on crack length measurements, establishing a conversion model between pixel size and actual dimensions. Experimental results indicate that when the measuring distance ranges from 100 to 300 mm, the maximum error in crack length is 6.8%. Compared to X-ray measurements, our method proves to be a viable alternative for measuring the surface crack length of turbine blades. Moreover, the enhanced algorithm demonstrates greater accuracy than the original algorithm in detecting sparse data,

收稿日期: 2024-11-03 Received Date: 2024-11-03

* 基金项目: 黑龙江省自然科学基金(LH2022E085)、国家自然科学基金(51975169)项目资助

with an average cross-over ratio improvement of 7.14%. The proposed method offers a theoretical foundation and data support for evaluating blade quality and guiding subsequent repairs.

Keywords: sparse data; deep learning; crack; turbine blades; camera calibration

0 引 言

航空发动机作为飞机的“心脏”,对飞机的安全性有着不可估量的影响^[1],涡轮叶片作为其核心零件,工作环境恶劣,表面很容易产生疲劳裂纹,裂纹的扩展易使叶片发生断裂^[2]。裂纹的长度和宽度测量在涡轮叶片的定期检测过程中极为重要^[3],这是因为涡轮叶片裂纹长度和宽度测量可以判断其危险等级,实现对航空发动机的寿命监测预警,并且可以判断叶片是否满足修复的条件^[4]。目前,测量裂纹长度和宽度的方法主要是以人工检测为主,其他工具检测为辅,例如,目视检测、超声检测、可见/红外等传统的无损检测方法^[5],其检测成本高,容易受到主观因素的影响。因此,研究一种快速、低成本、高精度的裂纹长度检测方法已成为航空工业发展过程中一个急需解决的问题。

机器视觉近年来被广泛应用在各个领域^[6],其非接触式、快速高效的检测技术,可以实现对航发涡轮叶片等复杂零件的裂纹长度测量。根据所使用的方法将传统的机器视觉测量方法分为:基于阈值的方法^[7]和基于聚类的方法。Monicka 等^[8]结合大津算法和 Canny 算子, Jiang 等^[9]采用以同样的方法构建阈值自适应分割算法,通过对比度的增加,分别对太阳能电池板和岩体裂纹进行识别,这种方法具有很低的信噪比和非常快的执行时间,但其检测容易受环境影响。周波等^[10]对 K-均值聚类算法(K-means clustering algorithm, K-Means)进行了改进,添加了麻雀搜索优化算法,而 Nnolim^[11]提出一种将模糊聚类与阈值结合起来的方法。然而,聚类技术的计算复杂度很大程度上依赖于图像的大小^[12],随机的裂纹形状和宽度,以及扫描图像中大量的噪声(包括不稳定的光照条件、阴影、污迹和服役后的“伤痕”等),给阈值和聚类这类传统的图像处理技术带来了一些挑战。

卷积神经网络(convolutional neural network, CNN)广泛用于图像检测领域,特别是医学图像分割^[13]。Luo 等^[14]结合传统的 Canny 算子与 DeepLabV3+(deeplab version 3 plus, DeepLabV3+)网络,弥补了传统机器视觉稳定性和泛化能力差的缺点。Di Benedetto 等^[15]提出了一种基于 U 型卷积神经网络(U-shaped convolutional neural network, Unet)模型架构和残差网络 50(residual network 50, ResNet50)编码器开发的残差结构的语义裂缝图像分割技术,它在相对复杂的背景下也能有效发挥作用。然而,在实际的航发叶片裂纹检测环境中,面临以下挑战:叶片裂纹比混凝土裂缝小得多;正负样本分布不

均衡;容易受到复杂背景的干扰;由于叶片属于保密件,样本数量少且数据质量较差。Chu 等^[16]提出了一种具有注意力机制的多尺度特征融合网络,以保留微小裂纹的边缘细节。张上等^[17]提出 LSC-PoolFormer 算法分割锻件表面裂纹,降低了小目标裂纹丢失的概率,整体检测精度达到 79.97%。Nguyen 等^[18]针对裂缝分割中的类不平衡数据问题,进行了大规模的性能比较,调节损失函数有助于优化网络模型结果。Dong 等^[19]改进 Unet 模型,能以更少的训练次数和更简单的模型结构获得更好的疲劳裂纹分割效果。

随着裂纹分割检测技术的发展日益成熟,未来的研究重点将更加关注裂纹的量化检测。Li 等^[20]使用数字图像相关技术测量了疲劳裂纹的宽度、长度和形态,但对有分支和复杂的裂纹无法测量。Jin 等^[21]提出了柔性核及剪枝的方式提取裂纹主骨架,计算裂纹宽度。Dang 等^[22]将裂纹分割和砖块检测技术结合起来,实现了真实裂纹长度测量。然而,仍存在计算精度低、裂纹的评价指标模糊、需要在裂纹旁放置标尺量化等问题。Cui 等^[23]提出一种基于加速稳健特征的图像拼接方法,通过拍摄不同视角的图像拼接成一张完整的裂纹图像,有效减少结构曲面带来的误差,但是存在弯曲裂纹两端深度信息丢失的问题。Ji 等^[24]提出了裂缝长度、平均宽度、最大宽度、面积和比率 5 个评价指标。目前,尽管在测量路面和混凝土裂纹方面已经取得了显著进展,但航发叶片裂纹更为细微且隐藏得更深,检测难度也相应增加,与之相关的文献及数据样本也非常稀缺。因此,路面和混凝土裂纹分割测量技术可以为涡轮叶片裂纹分割测量提供重要的理论基础。

“稀疏数据”一词最早源于数据库领域,指的是数据集中大多数数值缺失或为零。该研究对象具有以下特点:涡轮叶片裂纹呈线状或规则形状,可能产生沟槽或分叉,在整张图像中像素占比 0.11% 左右,导致涡轮叶片裂纹数据具有正负样本不均衡的特点^[25];数据量相对较少,涡轮叶片作为航空领域的核心部件,其数据集采集和公开受到一定的限制,导致涡轮叶片裂纹数据具有小样本的特点^[26]。结合涡轮叶片裂纹数据的两个特点,提出了“稀疏数据驱动的涡轮叶片表面裂纹长度提取方法”这一新型类比概念。首先,利用改进的 Unet 算法实现稀疏的涡轮叶片数据裂纹分割,并通过精分割优化分割结果。然后,使用八邻域骨架化算法得到裂纹的骨架线。同时,为降低像素尺寸与实际尺寸换算误差,建立成像偏移角度模型,分析偏移角度和相机参数对测量结果的影

响。最后,通过 X 射线检测与本文提出的裂纹长度优化提取方法对比,验证其方法的有效性。

1 稀疏数据驱动的 Unet 分割算法改进

目前,常用的图像分割网络有全卷积网络 (fully convolutional networks, FCN)、基于掩码区域的卷积神经网络 (mask region based convolutional neural network, Mask-RCNN)、Unet 和 DeepLab3+ 等,其中 Unet 网络^[27]在完成小样本图像分割任务时具有优秀的分割效果和较快的训练速度,因此选择 Unet 作为裂纹分割的基础模型。Unet 网络由编码器、解码器和跳跃连接组成,编码部分输入图像尺寸为 512 pixels,宽为 512 pixels,通道数为 3,经过两次卷积和一次最大池化变为长 256 pixels,宽 256 pixels,通道数为 64 的特征图,一共经过 4 次下采样,获得 5 个有效特征层。解码部分经过

4 次上采样使图像恢复到原图像大小,同时利用 5 个有效特征层进行上采样和特征融合。编码器和解码器之间的跳跃连接引入了大量的参数,增加了迭代次数,使得收敛速度变慢。涡轮叶片裂纹具有稀疏数据的特点,导致网络在训练中容易过拟合或无法学习到足够的特征,从而降低预测能力。

针对上述问题,本研究网络从两方面进行改进:1) 利用改进的视觉几何群网络 (visual geometry group 16 layer network, Vgg16) 作为裂纹图像主干特征提取网络,但仅采用卷积和最大池化部分,与原网络结构多了 3 个卷积层和 3 次激活操作,并引入预训练权重;2) 为避免参数量对小样本的影响,在跳跃连接层的拼接部分加入高效金字塔压缩注意力模块,增强对裂纹特征的提取能力。改进的网络结构如图 1 所示,图中 BN (batch normalization) 为批量归一化操作, K 表示卷积核大小; S 表示卷积核滑动的步长。




图 1 EPSA-Vgg-Unet 网络结构

Fig. 1 EPSA-Vgg-Unet network architecture

1.1 主干特征提取网络的改进

由于叶片裂纹样本稀少,获取完整的数据集较为困难,且目前公开数据集中没有相关的预训练权重数据。在小样本的条件下,基于 Unet 网络的编码器难以学习到足够泛化的特征,解码器在恢复和重建空间细节时也面

临挑战,导致权重停滞在某些局部最优点。为此,采用迁移学习方法,将在大型数据集 ImageNet 上预训练得到的权重应用于航空叶片裂纹分割模型的训练,以提高模型的初始性能。为了增强网络对权重参数的适配性,本文采用 Vgg16 对图像进行特征提取,将每一层得到的特征

图作为输入,用于特征解码和整合,使得替换后的网络既具有高分辨率的特征图,又具备在小样本条件下的学习能力。

Vgg16模型在神经元反向传播时,由于卷积神经网络层数比较多,导致更新的权重梯度逐渐衰减,位于前面几层的权重无法更新。为了解决这个问题,将原有的线性修正单元(rectified linear unit, ReLu)函数改为高斯误

差线性单元(gaussian error linear units, GeLu),具体形式如式(1),使得在输入为负时,部分神经元不会永远关闭,改进的Vgg16模型如图2所示。

$$GELU(x) = 0.5x \left[1 + \tanh \left(\sqrt{\frac{2}{\pi}} (x + 0.047715x^3) \right) \right] \quad (1)$$




图2 改进的Vgg16网络结构
Fig. 2 Improved Vgg16 network architecture

在解码器阶段,通过跳跃连接将Vgg16编码器的卷积层输出与解码器的上采样结果进行连接:

$$S_i^{vgg} = \text{concat}(C_{2i}^{vgg}, U_i) \quad (2)$$

式中: C_i^{vgg} 为第*i*层卷积操作的输出特征图; U_i 为Unet解码的第*i*层的上采样操作输出特征图。

解码器通过上采样操作恢复特征图的空间分辨率,并结合跳跃连接后的特征进行卷积操作:

$$D_m = \text{Conv2D}(S_m^{vgg}, W_{n+i}) + b_{n+i} \quad (3)$$

式中: W_{n+1} 为加码器第*i*层卷积操作的权重; b_{n+1} 为解码器第*i*层卷积操作偏置项。

1.2 融入高效金字塔压缩注意力模块

涡轮叶片裂纹一般表现为不规则曲线状,且尺度极为细小,属于小目标大背景。服役后的叶片背景复杂,不仅要区分“哪个是”裂纹,还需要找到裂纹

“在哪里”,感受野的大小决定了神经网络在处理图像时能够感知的区域范围,直接影响到模型捕捉图像中缺陷特征的能力。小的卷积核无法捕获更广泛的上下文信息,使用大的卷积核可以增大感受野,同时增加了模型中的参数量,导致模型计算成本增加,还会使细节和边缘信息模糊,由于网络参数量对小样本的影响很大,所以不能单纯地增大卷积核来解决小目标的问题。为了解决这个问题,在不改变其他特征图尺寸的前提下,在跳跃连接层的拼接部分添加了高效金字塔压缩注意力机制。高效金字塔压缩注意力机制(efficient pyramid squeeze attention block on convolutional neural network, EPSANet)^[28]是由空间注意力机制和通道注意力机制组成的高效金字塔压缩注意力模块,如图3所示。




图3 EPSANet注意力机制
Fig. 3 EPSANet attention mechanism

其实现步骤为:

1) 将输入的特征图分割(split)成众多子特征图,子特征图继承父特征图的通道数;

2) 子特征图经过不同卷积核的卷积操作(K_0 、 K_1 、 K_2 、 K_3 为卷积核大小),得到多尺度的空间信息;


3) 将不同尺度的空间信息拼接在一起得到多尺度单一维度的特征图,作为金字塔分割注意力(pyramid split attention, PSA)模块的输入;

4) 使用挤压与激励权重(squeeze and excitation weight, SEWeight)模块提取通道注意力机制的权重信息;


5) 采用 Softmax 算法对上述权重信息进行归一化,使其求和为 1,再将归一化的权重与对应的特征图进行点乘运算。

上述步骤中组与核的大小关系为: $G = 2^{(K-1)/2}$, 采用软注意力选择不同空间尺度的通道,并通过 Softmax 生成通道的多尺度重新校准权重,其中软分配的权重为:

$$\text{Softmax}(Z_i) = \frac{\exp(Z_i)}{\sum_{i=0}^{S-1} \exp(Z_i)} \quad (4)$$



(a) 裂纹像素边缘情况
(a) Crack pixel edge condition



(b) 裂纹骨架线
(b) Crack skeleton line

图4 裂纹骨架线

Fig. 4 Crack skeleton line

在实际测量裂纹尺寸时,即使镜头几乎对准了裂纹所在的平面,但由于叶片自身具有曲率的原因,实际上很难保持完全的对准。这种情况下,成像角度通常会存在一定的偏差。接下来通过相机成像原理深入分析成像角度对裂纹特征提取的影响。

2.2 像素坐标系与相机坐标系关系建立

前述得到的裂纹骨架线是在像素坐标系下的尺寸,单位是像素(pixel)。为得到相机坐标系下裂纹的真实尺寸,建立相机坐标系和像素坐标系之间的精确转换关系至关重要。成像坐标和像素坐标之间是通过缩放和原点平移得到的,结合相似三角形定理

式: Z_i 为不同尺度特征图的注意值。该模块采用金字塔的形式获取多尺度特征图,增强了网络的感受野和非线性表达能力。

在 Unet 网络的跳跃连接层实现空间和通道的多尺度特征权重重新分配,整合了多个层级的特征,利用不同大小的卷积核进行处理,可以捕捉不同尺度的特征信息和增强小目标的检测。

2 涡轮叶片裂纹长度提取方法

2.1 裂纹骨架线

叶片裂纹的长度和最大宽度是裂纹扩展和安全性能的重要指标。通过 EPSA-Vgg-Unet 分割裂纹区域,然而分割结果与真实裂纹存在误差,影响特征计算精度。为优化分割效果,首先利用掩码获取裂纹的外接矩形并扩展,然后在矩形区域内进行自适应阈值分割。由于光照不均匀等问题导致的噪声,需通过连通域分析去除。最后,对裂纹边缘进行平滑处理,利用骨架化算法得到裂纹骨架线,如图 4 所示。

可得:

$$\begin{cases} u = f_x \times \frac{X_c}{Z_c} + C_x \\ v = f_y \times \frac{Y_c}{Z_c} + C_y \end{cases} \quad (5)$$

式中: f_x 、 f_y 、 C_x 和 C_y 被称为相机的内部参数,在相机出厂时就已经被确定好。

裂纹检测时,应使投影平面和裂纹平面尽量保持平行,可以将相机坐标系下点的坐标 Z_c 相同,从而得到相机坐标系中线段长 m 与像素坐标系线段长 n 之间的换算关系如式(6)所示。

$$\frac{m}{n} = \frac{\sqrt{(X_{C1} - X_{C2})^2 + (Y_{C1} - Y_{C2})^2}}{\sqrt{(u_1 - u_2)^2 + (v_1 - v_2)^2}} \quad (6)$$

将式(5)代入得:

$$m = Q \times Z_c \times n \quad (7)$$

$$Q = \frac{\sqrt{(X_{C1} - X_{C2})^2 + (Y_{C1} - Y_{C2})^2}}{\sqrt{f_x^2 (X_{C1} - X_{C2})^2 + f_y^2 (Y_{C1} - Y_{C2})^2}} \quad (8)$$

式中: (X_{C1}, Y_{C1}, Z_{C1}) 和 (X_{C2}, Y_{C2}, Z_{C2}) 为线段 m 的两端点, Z_c 为相机坐标系上长为 m 的线段处于的平面与像素坐标系平行时, 焦点到 m 线段所在的平面距离。

由式(8)可知, 需要求取相机的内部参数 f_x, f_y (其与每个相机自身参数有关), 因此需要对相机进行标定, 以获取相机的内部参数。

2.3 像素尺寸与实际尺寸精确换算及误差分析

在实际测量中, 镜头平面与叶榫平面平行, 由于叶片自身具有曲率, 导致裂纹所在平面与成像平面存在一定的偏移。将其视作是裂纹平面偏斜造成的影响, 并且裂纹偏斜可以看作是绕中心旋转。根据以上分析建立二维成像角度偏移模型, 如图5所示。




图5 成像角度偏移模型

Fig. 5 Imaging angle offset model

图5中, AB 表示裂纹长度或宽度, 其在像素平面上的相应尺寸为 ab , θ 表示偏移角度, cd 表示平面偏移后 CD 对应像素平面上的尺寸, G 点表示焦点。随着偏移角不断增大, 在像素平面上的尺寸会逐渐减小, 人工依靠经验使投影平面和裂纹平面保持平行, 往往会出现一个很小的偏移角度。根据平行关系可得, $cd/ab = CE'/AB = (CE - EE')/AB$, 由 $CE/AB = \cos\theta$ 和相似三角形可知, $cd/ab = \cos\theta - (\sin\theta \cdot FE')/FG$, 在实际测量时, 测量距离远大于裂纹长度, 即 $FG \gg FE'$ 。因此 $cd/ab = \cos\theta$, 裂纹的测量值 < 真实值, 随着叶片弦线角的增大, 测量误差也逐渐增大。为减小偏移角度造成的影响, 对式(7)进行优化。

$$m = Q \times Z_c \times n \times \cos^{-1}\theta \quad (9)$$

式中: Z_c 是相机焦点到裂纹平面的距离。

但是, 在测量时 Z_c 往往被代替成相机镜头平面到测

量平台的距离, 而忽略了相机镜头的光学参数和物理参数, 由此进一步表示为:

$$m = Q \times (Z + f + a) \times n \times \cos^{-1}\theta \quad (10)$$

式中: Z 为相机镜头到待测件平面的距离; f 为相机的焦距; a 为镜头物理参数; θ 表示偏移角度。如图6所示, 测量时的误差与涡轮叶片的弦线角有关。




图6 涡轮叶片几何参数

Fig. 6 Sketch of turbine blade geometry parameters

3 实验验证

3.1 图像数据准备

训练集数据一部分来源于实验室对服役后的叶片裂纹拍摄, 另一部分来源于公开的金属裂纹数据集, 共125张。为增强模型的泛化性能和鲁棒性, 减少过拟合的影响, 对数据集进行数据增强, 包括增亮、对比度增强、旋转和翻转, 最终得到625张图像。使用Labelme图像标注工具对裂纹进行标注, 如图7所示。

训练集与测试集按照4:1的比例划分, 通过大量实验对比, 最后选用 $batch-size = 4$, $Epoch = 100$, 学习率为0.001, 模型训练中采用Adam优化器防止权重衰减导致模型过拟合, 损失函数采用相似度量函数(dice loss), 其余参数均为默认。

整体实验环境, 如图8所示。实验编程语言为python3.7, 深度学习框架为Pytorch, 采用win11操作系统, CPU为12th Gen Intel(R) Core(TM) i7-12700 H @ 2.30 GHz, GPU为6 G的NVIDIA GeForce RTX3060 SUPER。

交并比(intersection over union, IoU)、平均交并比(mean IoU, mIoU)、像素准确率(pixel accuracy, P_a)、平均像素准确率(mean P_a , mP_a)和F1值是评价分割性能的重要指标, 在图像分割的算法中, 正负样本数据不平衡, 单一利用交并比和准确率无法很好的评估网络性能, 需要结合F1值综合反应精确率和召回率。

$$IoU = \frac{T_p}{T_p + F_p + F_n} + \frac{T_n}{T_n + F_n + F_p} \times 100\% \quad (11)$$




图 7 裂纹数据集

Fig. 7 Crack data set




图 8 实验环境

Fig. 8 Experimental environment

$$mIoU = \frac{1}{2} \sum_{i=1}^n IoU_i \quad (12)$$

$$P_a = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \times 100\% \quad (13)$$

$$mP_a = \frac{1}{2} \sum_{i=1}^n P_{ai} \quad (14)$$

$$F1 = \frac{2T_p}{2T_p + F_p + F_n} \times 100\% \quad (15)$$

式中: T_p 为样本真实类别是裂纹,同时模型正确识别裂纹; F_n 为样本真实类别是裂纹,但是模型错误识别; F_p 为样本真实类别是背景,模型将其识别为裂纹; T_n 为样本真实类别是背景,模型将其识别为背景。

3.2 网络性能验证

1) 不同注意力机制比较实验

为了验证在主干网络中引入的注意力机制模块对模型性能的影响,将图像分割常用的坐标注意力机制 (coordinate attention, CA)、卷积块注意力模块 (convolutional block attention module, CBAM)、挤压与激励网络注意力机制 (squeeze and excitation network, SENet)、高效通道注意力机制 (efficient channel attention network, ECA net)、单发对齐网络 (single shot alignment network, S2Anet) 和 EPSANet 注意力模块进行对比实验, Unet 引入不同注意力机制模块前后的分割性能对比如表 1 所示。实验结果表明,对于小目标裂纹检测引入简单的注意力机制会使网络的平均精度下降,但是 Unet 在加入 EPSANet 注意力机制模块后,裂纹分割的精度最高, $mIoU$ 提高了 1.9%。

2) 不同主干网络比较实验

在航发叶片裂纹分割任务中,为加快模型训练时的收敛速度和获得更好的泛化能力,采用迁移学习的方式将在大型数据集 ImageNet 上预训练得到的权重应用到裂纹分割模型中,表 2 为不同主干特征提取网络对模型的影响。在实验中,与 ResNet50 相比,选用 Vgg16 作为主干提取网络的 $mIoU$ 和 $F1$ 分数分别提升了 4.63% 和

表 1 引入不同注意力机制算法分割性能对比
Table 1 Comparison table of segmentation performance of algorithms with different attention mechanisms (%)

模型	$mIoU$	mP_a	F1 值
Unet	78.91	82.61	69.67
Unet-CA	74.83	76.98	66.81
Unet-CBAM	79.81	83.84	71.25
Unet-SENet	76.55	79.18	69.81
Unet-ECANet	78.29	82.19	71.24
Unet-S2Anet	78.08	80.84	72.34
Unet-EPSANet	80.81	83.56	73.54

1.12%,这是因为 ResNet50 中的残差块使得模型的参数量增大,导致在小样本的检测中部分特征过拟合。

3) 输入图像尺寸比较实验

Unet 在上采样和下采样的过程中,它的最大采样率




表 2 不同主干网络对模型的影响
Table 2 The influence of different backbone networks on the model (%)

模型	$mIoU$	mP_a	F1 值
Unet	78.91	82.61	69.67
Unet-Vgg16	84.72	92.16	83.47
Unet-ResNet50	80.09	92.17	82.35

都为 32,如果在某个采样层输入的图像尺寸不是 32 的倍数,会导致特征图的大小不一致,进而影响网络的准确性。为了解决这个问题,将输入的图像进行预处理,使其尺寸为 32 的倍数。本研究将输入图像尺寸设置为 32 倍(D1)和非 32 倍(D2)进行实验对比,由图 9 可知,在模型训练时,D1 的收敛速度明显优于 D2,这说明输入图像的尺寸大小是影响数据集质量的关键因素。综上所述,本研究采用的数据集图像尺寸为 32 倍,此时网络损失由 0.12 降低到 0.008, $mIoU$ 提高了 1.29%。




图 9 网络性能
Fig. 9 Network performance

4) 消融实验

为进一步分析本研究改进的算法对航发叶片裂纹分割的优势,通过重构网络中的某些组成部分,更好地验证改进各个模块对 Unet 网络的影响,消融实验结果如表 3 所示。与实验 1 相比,实验 2 的 $mIoU$ 、 mP_a 和 F1 分数分别提升了 5.81%、9.55% 和 13.8%,这是因为在编码部分参数量保持不变的情况下,与 Vgg16 所适配的预训练权重中包含了裂纹特征,并且 GeLu 函数使反向传播的梯度变化更连续。实验 3 搭建的高效金字塔压缩注意力模块 $mIoU$ 、 mP_a 和 F1 分数分别提升了 1.9%、0.95% 和 3.87%,该模块利用小目标的空间位置信息和通道位置信息进行多尺度信息提取,增强了网络小目标的提取能力。在实验 4 中同时改进两个模块,使得改进的两个部分对原 Unet 网络均有所提升,改进后的算法比原算法 $mIoU$ 提升了 7.14%。

表 3 消融实验结果
Table 3 Ablation results (%)

序号	Unet	Vgg16	EPSA	$mIoU$	mP_a	F1
1	✓			78.91	82.61	69.67
2	✓	✓		84.72	92.16	83.47
3	✓		✓	80.81	83.56	73.54
4	✓	✓	✓	85.51	93.91	83.77

5) 不同分割模型对比实验

为进一步验证改进后的 EPSA-Vgg-Unet 算法对小样本、小目标的裂纹分割检测性能,选择与近几年在分割领域最新和最经典的算法进行对比,将本研究算法与 Unet++、Res-Unet、Unet、Mask-RCNN、Deeplabv3+ 和 Unet3+这 6 种算法进行了实验对比。实验结果如表 4 所

示,分割结果如图 10 所示。Mask-RCNN 和 Deeplabv3+是一个两阶段的检测模型,由于数据样本少,候选区域无法获取更多的特征,导致最终分割裂纹失败;而 Unet 系列网络属于单阶段的检测模型,在小样本训练时仅依赖现有数据集中裂纹特征,初始权重具有随机性,对小目标的特征提取不充分以及空间位置捕捉较弱,并且卷积的感受野和多尺度融合过于传统,难以在稀疏数据背景下准确分割目标,从而导致分割精度下降。




图 10 不同模型分割结果
Fig. 10 Segmentation results of different models

结果表明,本研究改进的 EPSA-Vgg-Unet 算法分割效果最好,与原算法相比 $mIoU$ 提升了 7.14%,从图 10(c)可以看出,本文提出的算法对叶片裂纹分割具有良好的效果,保证了裂纹分割边缘的准确性和连续性。

3.3 特征提取

使用张正友标定法^[29]对相机进行标定,求取相机的内部参数。使用的棋盘格规格为 9×12,每个小格边长为 20 mm,采用大恒 MER-130-30UM-L 相机,镜头焦距为 12~36 mm 的海康威视 MV1236M-5MP,在进行标定及实验采集时调节镜头焦距为最小 12 mm,即 $f=12$ mm,并保持不变,采集 18 张不同角度的图像,标定的相机参数见表 5。

从表 5 中可知 $f_x=2\,273.4$, $f_y=2\,277.9$, $\frac{2\,273.4^2}{2\,277.9^2}=0.996\,052\,9$,将其代入式(10)近似得:

$$m = \frac{1}{2\,277.9} \times (Z + f + a) \times n \times \cos^{-1}\theta \tag{16}$$

式中: f 为相机焦距; a 为镜头物理参数,通过镜头说明书可知 $a=5$ mm。本实验所用的叶片平均弦线角 $\theta \approx 5.5^\circ$ 。

使用 EPSA-Vgg-Unet 对航发叶片裂纹的分割,可以初步获得裂纹分割图像,接下来还需要对其分割结果进行精

表 4 不同模型的对比实验

Table 4 Comparison experiment of different models (%)			
模型	$mIoU$	mP_a	$F1$ 值
Unet	78.91	82.61	69.67
Res-Unet	80.18	92.17	82.35
Unet++	76.83	73.1	59.50
Unet3+	70.41	77.94	58.70
EPSA-Vgg-Unet	86.05	93.95	83.77

表 5 相机标定参数

Table 5 Camera calibration parameters				
参数	数值			
内参矩阵	2 273.4	0	651.7	
	0	2 277.9	665.3	
	0	0	1	
畸变系数	[-0.296 9 0.996 7 0.004 8 0.001 9]			

分割,从而再次提高裂纹分割精度。利用图 11(a)~(d)的算法流程分割结果,得到裂纹骨架线。根据航发叶片裂纹的长度特征,可以将骨架线长度视为裂纹的长度。最后,使用中轴变换和八邻域骨架化算法对其进行骨架化,如图 11(d)所示,骨架线的像素长度为 189,代入式(16)可以由像素尺寸换算为实际几何尺寸,其计算值为 18.07 mm。

为了评估提出的航发叶片裂纹长度提取方法的精度和验证其有效性,采集裂纹图像时通过控制不同的采集距离得到多个裂纹图像,其采集距离 $d=100\sim300$ mm,如图 12 所示。本文采用真实裂纹进行验证,但无法得到标准的裂纹长度,而 X 光检测裂纹长度技




图 11 裂纹长度计算
Fig. 11 Calculation of crack length




图 12 不同距离采集裂纹图像二值图像
Fig. 12 The binary images of crack images were collected from different distances

术比较成熟, 现已投入市场使用, 其精度可以达到 0.2 mm。为了对比验证本文提出方法的有效性, 使用 X 光对两个裂纹的长度进行了检测, 实验现场如图 13 所示。

最后, 利用提出的方法和 X 光无损检测方法对比, 平均测量误差计算如式 (17) 所示。

$$\Delta = \sum_{i=1}^n \left| \frac{E_i - L}{L} \right| \times 100\% \quad (17)$$

式中: E_i 为本文方法测量结果; L 为采用 X 光方法测量结果; $n = 1, 2, 3, \dots$, 本研究 n 取 5。

通过表 6 可知, 对相机成像原理和测量误差进行了深入地分析, 最后得到像素尺寸与实际尺寸换算关系, 实验结果表明, 本研究所提出的航发叶片裂纹特征提取方法, 通过与 X 光检测裂纹长度的实验进行对比, 在不同采集距离下, 测量裂纹长度最大误差为 7.2%, 该方法可以实现裂纹长度的测量, 证明该方法在测量涡轮叶片表面裂纹长度中对 X 光检测技术有一定的替代性。




图 13 X-ray 检测
Fig. 13 X-ray detection

表 6 不同采集距离下裂纹长度测量结果

Table 6 Measurement results of crack length under different sampling distance

	距离/mm	像素长度/pixel	本文方法测量结果/mm	测量误差/%	平均测量误差/%
1 号 13.615 mm	100	264.35	13.641	0.2	1.88
	150	188.77	13.903	2.1	
	200	141.18	13.511	0.8	
	250	109.4	12.882	5.4	
	300	96.48	13.488	0.9	
2 号 6.145 mm	100	113.7	5.867	4.5	4.52
	150	81.98	6.038	1.7	
	200	62.33	5.965	2.9	
	250	48.68	5.732	6.7	
	300	40.97	5.728	6.8	

4 结 论

在航空发动机叶片缺陷检测中,虽然定性化检测技术已逐渐趋向成熟,但对裂纹长度的精确量化仍然是亟待解决的关键科学问题之一。由于涡轮叶片裂纹具有稀疏数据的特点和成像角度偏移误差,提出了一种稀疏数据驱动的涡轮叶片裂纹长度提取方法,以应对这一挑战。研究结果表明:

1)通过深入分析相机成像原理,测量结果的误差主要由成像角度偏移的误差($\cos\theta$ 值)和相机镜头自身的物理参数所决定。实验结果表明,当偏移角度为 25.84° 时,测量误差达到 10%,当偏移角度为 60° 时,测量误差达到 50%;误差导致裂纹的测量值始终比真实值小;随着叶片弦线角与测量的误差成正比。该方法可以实现裂纹长度的测量,测量裂纹长度最大误差为 6.8%,证明该方法在该邻域对 X 光检测技术有一定的替代性。

2)为提升裂纹分割的精度,通过实验对比不同输入图像尺寸(32 倍与非 32 倍),优化了输入图像的像素尺寸。这一优化显著加快了模型的收敛速度,使损失值从 0.12 降低至 0.008。进一步将改进后的 EPSA-Vgg-Unet 算法与原始 Unet 算法进行对比实验,结果表明 $mIoU$ 提升了 7.14%。这一改进充分证明了算法在裂纹分割中的优越性,并为后续的裂纹长度精确计算奠定了坚实基础。

本研究所提出的方法适用于航发叶片单片测量,后续可通过透视变换对图像进行校准,让其可以不保持平行,进而实现连续多目标检测。未来,针对测量裂纹深度、不在同一平面的裂纹、多裂纹交叉等情况时,本文将研究测量其三维信息的方法,并通过部署在终端设备中

的算法,结合实时反馈,进行检测,从而为航发叶片的寿命精确预测和修复奠定基础。

参考文献

[1] 李茂月, 赵伟翔, 马康盛, 等. 结构光检测点云精简与重构参数自动调节方法[J]. 仪器仪表学报, 2022, 43(8): 122-130.

LI M Y, ZHAO W X, MA K SH, et al. Automatic adjustment method of structural light detection point cloud reduction and reconstruction parameters [J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 122-130.

[2] 盛昌文, 姜永正, 黄磊, 等. 基于叶尖定时的风机叶片裂纹故障识别研究[J]. 仪器仪表学报, 2024, 45(4): 57-65.

SHENG CH W, JIANG Y ZH, HUANG L, et al. Research on crack fault identification of fan blade based on tip timing[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 57-65.

[3] LI X, WANG CH, JU H J, et al. Surface defect detection model for aero-engine components based on improved YOLOv5[J]. Applied Sciences, 2022, 12(14): 7235.

[4] ZHANG X CH, LI W, LIOU F. Damage detection and reconstruction algorithm in repairing compressor blade by direct metal deposition[J]. The International Journal of Advanced Manufacturing Technology, 2018, 95(5/8): 2393-2404.

[5] 范淼淼, 赖宁磊, 晏张平, 等. 基于 SVM-D-EWT 的超

- 声组织谐波成像算法研究[J]. 仪器仪表学报, 2024, 45(6): 231-239.
- FAN M M, LAI N L, YAN ZH P, et al. Research on ultrasonic tissue harmonic imaging based on SVMDEWT[J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 231-239.
- [6] 刘爽, 陈立新, 张钧栋, 等. 基于机器视觉的正碰假人胸部的研究[J]. 中国光学(中英文), 2023, 16(3): 673-681.
- LIU SH, CHEN L X, ZHANG J D, et al. Study of touching dummy's chest based on machine vision[J]. Chinese Optics(Chinese and English), 2023, 16(3): 673-681.
- [7] 宋晔, 吴一全. 基于无人机航拍的风力发电机叶片表面缺陷检测综述[J]. 仪器仪表学报, 2024, 45(10): 1-25.
- SONG Y, WU Y Q. Review of wind turbine blade surface defect detection based on UAV aerial photography[J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 1-25.
- [8] MONICKA S G, MANIMEGALAI D, KARTHIKEYAN M. Detection of microcracks in silicon solar cells using Otsu-Canny edge detection algorithm[J]. Renewable Energy Focus, 2022, 43: 183-190.
- [9] JIANG F, WANG G, HE P, et al. Application of Canny operator threshold adaptive segmentation algorithm combined with digital image processing in tunnel face crevice extraction[J]. Journal of Supercomputing, 2022, 78(9): 11601-11620.
- [10] 周波, 万熠, 梁西昌, 等. 基于麻雀搜索优化的背景分割算法的板簧尺寸检测方法[J]. 电子测量技术, 2023, 46(16): 73-77.
- ZHOU B, WAN Y, LIANG X CH, et al. Detection method for plate spring size based on sparrow search optimization background segmentation algorithm[J]. Electronic Measurement Technology, 2023, 46(16): 73-77.
- [11] NNOLIM U A. Automated crack segmentation via saturation channel thresholding, area classification and fusion of modified level set segmentation with Canny edge detection[J]. Heliyon, 2020, 6(12): e05748.
- [12] HERRERA M L, MURGUIA C I M, QUINTANA R A J, et al. AENCIC: A method to estimate the number of clusters based on image complexity to be used in fuzzy clustering algorithms for image segmentation[J]. Soft Computing, 2023, 28(15/16): 8561-8577.
- [13] MOUSAVI M, HOSSEINI S. A deep convolutional neural network approach using medical image classification[J]. BMC Medical Informatics and Decision Making, 2024, 24(1): 239-256.
- [14] LUO J, LIN H ZH, WEI X X, et al. Adaptive Canny and semantic segmentation networks based on feature fusion for road crack detection[J]. IEEE Access, 2023, 11: 51740-51753.
- [15] DI BENEDETTO A, FIANI M, GUJSKI L M. U-Net-Based CNN architecture for road crack segmentation[J]. Infrastructures, 2023, 8(5): 90-103.
- [16] CHU H H, WANG W, DENG L. Tiny-Crack-Net: A multiscale feature fusion network with attention mechanisms for segmentation of tiny cracks[J]. Computer Aided (IVI) and Infrastructure Engineering, 2022, 37(14): 1914-1931.
- [17] 张上, 邹扬, 张岳. 轻量化锻件表面小目标裂纹分割算法[J]. 电子测量技术, 2024, 47(21): 178-187.
- ZHANG SH, ZOU Y, ZHANG Y. Lightweight segmentation algorithm for small target cracks on forging surface[J]. Electronic Measurement Technology, 2024, 47(21): 178-187.
- [18] NGUYEN Q D, THAI H T. Crack segmentation of imbalanced data: The role of loss functions[J]. Engineering Structures, 2023, 297: 116988.
- [19] DONG CH ZH, LI L D, YAN J, et al. Pixel-level fatigue crack segmentation in large-scale images of steel structures using an encoder-decoder network[J]. Sensors, 2021, 21(12): 4135-4152.
- [20] LI D R, CHENG B, SHI L Z, et al. An automated measurement method for the fatigue crack propagation based on decorrelated digital image correlation[J]. International Journal of Fatigue, 2024, 183: 108265.
- [21] JIN S, LEE S E, HONG J W. A vision-based approach for autonomous crack width measurement with flexible kernel[J]. Automation in Construction, 2020, 110: 103019.
- [22] DANG L M, WANG H X, LI Y F, et al. Deep learning-based masonry crack segmentation and real-life crack length measurement[J]. Construction and Building

- Materials, 2022, 359(12): 129438.
- [23] CUI D SH, ZHANG CH W. Crack detection of curved surface structure based on multi-image stitching method[J]. Buildings, 2024, 14(6): 1657.
- [24] JI AN K, XUE X L, WANG Y, et al. An integrated approach to automatic pixel-level crack detection and quantification of asphalt pavement [J]. Automation in Construction, 2020, 114: 103176-103191.
- [25] LI D W, LI Y D, XIE Q, et al. Tiny defect detection in high-resolution aero-engine blade images via a coarse-to-fine framework [J]. IEEE Transactions On Instrumentation and Measurement, 2021, 70: 3512712.
- [26] LI X B, WANG W Q, SUN L H, et al. Deep learning-based defects detection of certain aero-engine blades and vanes with DDSC-YOLOv5s [J]. Scientific Reports, 2022, 12: 13067-13081.
- [27] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [28] ZHANG H, ZU K K, LU J, et al. EPSANet: An

efficient pyramid squeeze attention block on convolutional neural network[C]. Proceedings of the Asian Conference on Computer Vision, 2022: 1161-1177.

- [29] ZHANG ZH Y. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330-1334.

作者简介



李茂月(通信作者),2004 年于南京林业大学获得学士学位,2007 年于长安大学获得硕士学位,2012 年于哈尔滨工业大学获得博士学位,现为哈尔滨理工大学教授、博士生导师,主要研究方向为智能加工与光学检测技术。

E-mail:lmy0500@163.com

Li Maoyue(Corresponding author) received his B. Sc. degree from Nanjing Forestry University in 2004, received his M. Sc. degree from Chang'an University in 2007, received his Ph. D. degree from Harbin Institute of Technology in 2012. Now he is a professor and doctoral tutor in Harbin University of Science and Technology. His main research interests include intelligent machining and optical detection technology.