

## 金属发动机叶片微小缺陷超分辨图像重建方法

葛鑫鑫<sup>1</sup>, 崔海华<sup>1\*</sup>, 徐振龙<sup>1</sup>, 贺敏岐<sup>2</sup>, 韩学志<sup>3</sup><sup>1</sup>南京航空航天大学机电学院, 江苏 南京 210016;<sup>2</sup>西安航空动力股份有限公司, 陕西 西安 710021;<sup>3</sup>中国航发哈尔滨东安发动机有限公司, 黑龙江 哈尔滨 150066

**摘要** 针对金属发动机叶片细微缺陷边界对比度低、描述符不足等造成的检测困难问题,提出一种基于超分辨图像重建技术实现微小缺陷强化的方法。首先,为弥补固定分辨率常规图像量化能力不足的短板,设计基于光度立体的图像重建方法,在图像量化层面实现了叶片表面高对比度法向贴图重建;然后,针对微小缺陷采样描述符不足的问题,通过真实叶片图像来构建多角度、多姿态的数据集,采用基于像素损失的 Charbonnier 损失来改进超分模型的损失函数,从而实现图像的高分辨率重建,强化采样分辨率,最终实现量化以及采集两个层面的微小缺陷超分辨增强;最后,使用传统的 Canny 算子识别叶片表面缺陷边界。实验结果表明,所提方法可以免疫二维歧义性,相较于传统方法,最高可提升金属叶片表面微小缺陷检出率达 24.3%。

**关键词** 图像处理; 图像重建; 超分辨率; 光度立体; 表面形貌; 机器视觉

**中图分类号** TP391.41

**文献标志码** A

**DOI:** 10.3788/AOS221263

## 1 引言

金属航空发动机叶片生产制造和使用过程中可能产生各类细小缺陷,其对产品的外观甚至整体功能将产生巨大影响,因此金属表面的微小缺陷检测对于整体产品的质量控制和用件损耗评估具有重要的意义。现阶段的检测方法多以人工检测为主,可靠性低。缺陷难以被准确识别的主要因素包括:缺陷的特征边界不清晰,其轮廓和背景之间对比度低;图像中包含其他噪声或存在图像二维歧义性干扰;缺陷细小,图像描述符不足,难以准确识别。针对上述问题,研究人员从图像增强和融合重建的角度提出了对应的解决方案。

当前,针对低对比度图像的增强和特征提取的基础方法有直方图均衡化<sup>[1]</sup>、Retinex 模型算法<sup>[2]</sup>、同态滤波法<sup>[3]</sup>、小波变换法<sup>[4]</sup>等。Tang 等<sup>[5]</sup>在针对钢板表面微小缺陷图像增强和分割中提出一种基于小波-同态滤波的预处理方法,其在低对比度的微小缺陷边缘检测中取得了良好的效果。Liu 等<sup>[6]</sup>运用一种递归网络进行低照度图像增强,该网络使用双重注意力模块提取通道特征信息和空间特征信息,可以更好地恢复图像细节。Hao 等<sup>[7]</sup>采用一种学习基于 CNN 的低光显著图像和深度图像的网络进行图像增强重建,提升了

图像的主观感知,提升了细节特征。图像融合也是提升图像中有效信息的常用方法,Martínez 等<sup>[8]</sup>针对高精密金属组件表面的缺陷检测,提出一种基于图像融合的成像强化方法,通过多个低角度光源获取一组图像,融合合并为一幅图像,从融合图像中提取有效信息,获得比一般方法更好的效果。Liu 等<sup>[9]</sup>为了提高图像中目标的显著性对比度,同时保留细节信息,提出一种基于混合曲率滤波的图像融合算法来获取不同图像层的属性并对图像进行融合,证明该方法更有利于人眼的视觉感知和计算机分析。Xiang 等<sup>[10]</sup>针对金属表面的钢印字符检测容易受到腐蚀、镜面反射等因素的干扰,提出一种多尺度图像融合算法来恢复金属表面的图像信息,该方法可以增强图像的对对比度、饱和度以及曝光程度,增强后的图像更有利于提升字符识别的准确性。综合看待传统图像增强方法和传统图像融合重建方法对于图像内信息的提取效果,两类方法都是从图像整体信息入手,如对直方图、对比度等图像综合属性进行调整,从而强化目标的特征,容易造成负优化、受图像二维歧义性干扰等问题。

本文从成像技术原理上进行图像增强,设计了融合式图像采集和量化的二维超分辨增强技术。针对现有方法存在的问题,结合光度立体具有精细化法向贴

收稿日期: 2022-06-06; 修回日期: 2022-07-14; 录用日期: 2022-07-29; 网络首发日期: 2022-08-09

基金项目: 航空科学基金(2020Z050052002)、江苏省自然科学基金(BK20191280, BK20210299)、南京航空航天大学研究生科研与创新计划项目(xcxjh20210513)

通信作者: \*cuihh@nuaa.edu.cn

图重建的特点,提出一种基于光度立体和图像超分的图像增强重建技术,针对数字化过程中量化层面的不足,使用光度立体技术进行高对比显示,凸显图像轮廓特征,解决了以往图像细小特征对比度低、易受二维歧义性干扰的短板;针对图像数字化过程中采样分辨率层面的不足,引入图像超分重建方法,解决传统光度立体技术中由硬件瓶颈导致的细节不足、图像描述子离散的问题。本文首先对图像超分辨量化采样技术进行原理推导和技术点分析;然后,阐述实验环境和实验流程;最后,根据实验结果,对所提方法的采样量化超分辨强化特性进行对比验证,融合重建得到的表面细节更为丰富,微小细节描述更为准确。所提方法可以在图像预处理阶段进行,可以嵌入到传统缺陷检测识别算法中,便于推广,对提高检测精度有积极意义。

## 2 图像的超分辨量化采样强化技术

图像的数字化包括采样和量化两个过程,以 8 位灰度图为例,将图像空间连续坐标的离散化称为采样,空间中部分点的灰度值代表图像,这些点又被称为采

样点;采样后各像素点的灰度值从模拟量到离散量的转换称为图像灰度的量化,量化过程决定了图像的灰度级分辨率。针对金属表面微小缺陷的图像超分辨量化采样增强技术主要是针对图像微小特征细节的对比度加强、分辨率加强和二维光照均匀化以及消除污渍影响,在保留图像原有清晰特征的同时,能够将低对比度、边界不清晰的细节以更易被人眼和计算机识别的方式显现出来。

### 2.1 基于光度立体的量化对比度增强

图像数字化的量化过程中,由于硬件以及拍摄对象等的限制,图像中的细节纹理、边界特征等容易因对比度低而无法被准确判断。量化对比度是指图像数字化之后不同亮度层级所呈现的细节程度,量化对比度低的图像所导致的结果就是纹理、边界不清晰,细节难判断;反之,则是图像纹理清晰、边界分明。量化对比度低的图像如图 1 所示,此类图像不利于直接进行特征识别。为了获取边界清晰、纹理丰富的图像,传统方法往往需要挑选合适光源,多次调整拍摄角度才能获得理想的图像数据,操作繁琐。使用光度立体技术可以相对便捷地使用法向贴图强化表面细节。




图 1 通过多角度光源采集的金属灰度图。(a)从右侧;(b)从下侧;(c)从左侧;(d)从上侧

Fig. 1 Gray images of metal collected from multiple angles of light. (a) From the right; (b) from the bottom; (c) from the left; (d) from the top

光度立体技术最早由 Woodham 教授提出,其针对阴影恢复法进行改进,在相机视场不变的情况下,利用不同方位布置的光源采集不同图像来还原物体的形貌特征。各硬件按照图 2(a)布置,中间上方的摄像机垂直向下放置,其周围放置多个光源[图 2(a)中放置 4 个],实验采用平行光模型,如图 2(b)所示,其中  $L$  为待求的光源方向向量, $R$  为光源向量的反射向量, $V$  为视角观察方向, $N$  为高亮点处的法向量。由于采用正投影相机模型,当图像上能够观察到高亮点时,光源反射向量和视角观察方向一致,即

$$R = V. \quad (1)$$

根据图 2 所示的三角关系,可以推导出

$$L = 2(N \cdot R)N - R. \quad (2)$$

由于相机被放置在正上方,可通过以下方法进行光源向量  $L$  的求解。图 3 为求解高亮点法向量的示意图。

如图 3 所示,记光源引起的高亮点为  $P(P_x, P_y, P_z)$ ,球心点为  $O(C_x, C_y, 0)$ ,标定球半径  $R_c$  已知,从相机视角拍摄的俯视图中可以计算出水平距离  $r$  为

$$r = \sqrt{(P_x - C_x)^2 + (P_y - C_y)^2}, \quad (3)$$

在正视图中,同样利用勾股定理能够求得




图 2 光度立体硬件示意图。(a)硬件布置图;(b)光源向量标定图

Fig. 2 Schematic of photometric stereo hardware. (a) Hardware layout diagram; (b) light source vector calibration diagram




图 3 求解高亮点法向量示意图

Fig. 3 Schematic for solving normal vector of highlighted points

$$P_z = z = \sqrt{R_c^2 - r^2}, \quad (4)$$

$$\mathbf{n} = \frac{\mathbf{N}}{\rho}. \quad (10)$$

因此  $P$  点处的法向量为

$$\mathbf{N} = (P_x - C_x, P_y - C_y, P_z). \quad (5)$$

将式(5)代入式(2),便可以求得光源的方向向量。对于理想的朗伯体表面,其任意一点的亮度值  $I$  可以表示为

$$I = \rho \mathbf{n} \cdot \mathbf{L}, \quad (6)$$

式中:  $\rho$  为物体表面的反射率;  $\mathbf{n}$  为该点的表面法向量。将表面法向量写成分量形式  $\mathbf{n} = [n_x, n_y, n_z]^T$ , 由于存在 3 个未知量, 式(6)为某点法向量的线性方程, 建立 3 个以上的光源就可以确定其中一点的法向量  $\mathbf{n}_0$ , 并建立各个方向光源图像的相关方程, 得到

$$\begin{cases} I_1 = \rho(n_x \cdot L_{1x} + n_y \cdot L_{1y} + n_z \cdot L_{1z}) \\ I_2 = \rho(n_x \cdot L_{2x} + n_y \cdot L_{2y} + n_z \cdot L_{2z}) \\ \vdots \\ I_n = \rho(n_x \cdot L_{nx} + n_y \cdot L_{ny} + n_z \cdot L_{nz}) \end{cases}. \quad (7)$$

对于同一待测对象, 其表面反射率为相同值, 取  $N = \rho \mathbf{n}$ , 使用最小二乘法求解方程, 可得

$$\mathbf{N} = (\mathbf{L}_{\text{all}}^T \mathbf{L}_{\text{all}})^{-1} \mathbf{L}_{\text{all}}^T \mathbf{I}, \quad (8)$$

式中:  $\mathbf{I}$  为单位矩阵;  $\mathbf{L}_{\text{all}}$  为各组光源组成的矩阵。由于  $\mathbf{n}$  为单位向量, 其范数为 1, 故

$$\rho = |\rho \mathbf{n}| = |\mathbf{N}|, \quad (9)$$

使用实验台进行多角度图像采集, 得到的图像组如图 1 所示, 由于通过不同角度的光源获取的图像表层信息不同, 因此采用上述公式计算表面法向量。对每个点进行上述运算, 准确计算出每一点的法向量便可以获得物体表面的法向强化贴图。图像中, 由物体表面每一点的法向量组成的图被称为法向贴图, 为了便于观察, 利用 RGB 三通道将法向贴图映射到图像中表面法向量  $(x, y, z)$  三个分量的绝对值, 那么表面的主要朝向就会呈现出来。图 4 为光度立体法重建的表面法线贴图。当遇到裂纹等形貌变化的微小细节时, 由于法向量的分量发生变化, 法向贴图对应的颜色分量也会急剧变化, 鲜明的颜色变化从量化对比度层面强化了物体表面的图像信息, 改善了传统图像数字化过程中灰度图显示的轮廓不清晰、明暗对比不鲜明的情况。

## 2.2 基于超分辨率技术的图像采样效果增强

### 2.2.1 基于超分辨率技术的图像采样分辨率增强

数字图像的质量主要受采样点数量的影响, 采样点数量越多, 图像的质量越好; 相反, 采样点数量减少时, 图像中的块状效应就会逐渐增强。针对采样点对图像质量的影响, 提出了基于超分辨率技术的图像采样分辨率增强方法。在进行光度立体重建之前, 将不同角度光源的图像输入到超分辨率模型中, 模型对图像进行基于特征金字塔的抽象特征提取, 将提取的特征进行上采样, 通过超分网络的作用, 上采样的图像被




图 4 光度立体法重建的表面法线贴图

Fig. 4 Surface normal map reconstructed by photometric stereo method

重建为高分辨率图像。网络经过设置,高分辨率图像的长宽一般为输入图像的 2~3 倍。将该批经超分辨率技术处理的高分辨率图像输入光度立体重建模型,最终得到物体表面包含高对比度特征的增广法向图。

### 2.2.2 图像超分辨率模型的基本原理

图像超分辨率技术<sup>[11]</sup>是使用某种网络模型完成低分辨率图像到高分辨率图像转变的技术,经典的超分

分辨率技术通常基于数字图像处理技术,将图像从时域、空域等多个维度提取其包含的特征,进而计算高分辨率图像对应位置的像素值,最终重建出真实程度更好的高分辨率图像。近年来,随着深度学习技术的快速发展,涌现了诸多以深度学习为基础的图像超分辨率技术(以下简称“图像超分技术”),并且产生了一套完整的超分效果评价体系。一些算子例如 EDSR<sup>[12]</sup>、RDN、SRCNN<sup>[13]</sup>、SRGAN<sup>[14]</sup>等就在开放计算机视觉库 OpenCV 的 dnn\_supress 模块中进行集成,通过语句可以轻松进行网络搭建,相较于使用 Cuda 和 Cudnn 搭建的繁琐框架,集成后的各式算子可以更加便捷地供人调用,也有利于传播技术。

表 1 所示为不同超分网络的特点比较。为了强化重建细小缺陷的边缘特征,本研究在图像分辨率表述方面进行扩充提升,同时为了保留图像原本特征感官上的真实性,选取了重建效果好的 RDN<sup>[15]</sup>模型作为基本研究框架,并优化网络损失函数和超参数,使其可以在金属表面边界细节特征的图像中具有更好的重建恢复能力。

表 1 几种超分网络的特点比较

Table 1 Comparison of the characteristics of several super-resolution networks

Super-resolution network	Size	Characteristic
ESPCN	100.0 kB	The model is small in size and fast in training speed, but its super-resolution effect is poor
SRGAN	15.8 MB	The super-resolution effect is good, but the training speed is slow
SRCNN	20.0 kB	The model is small in size and fast in training speed, but its super-resolution effect is poor
RDN	22.1 MB	The super-resolution effect is good, but the training speed is a little slow
EDSR	38.5 MB	The super-resolution effect is good, but the network model is large and the training speed is slow

针对光度立体重建所需的一组照片进行单幅图像超分,RDN 针对单幅图像使用保存在模型参数中的训练经验和低分辨率图像信息重建出与其对应的高分辨率图像。以下将低分辨率图像和高分辨率图像分别表述为“低分图”和“高分图”,那么高分重建过程的关系可表述为

$$I_l = f(I_h; \delta), \quad (11)$$

式中: $f$ 为退化函数; $I_h$ 为高分图; $I_l$ 为低分图; $\delta$ 为参数。由式(11)可见,高分图 $I_h$ 在退化过程中,在一系列参数 $\delta$ 的共同作用下退化为低分图 $I_l$ ,本研究将其表述为一个下采样过程,那么对于图像的超分操作就是高分图退化操作的逆操作,即

$$\hat{I}_h = F(I_l; \delta'), \quad (12)$$

式中: $F$ 为退化函数的逆变换; $\hat{I}_h$ 为从低分图 $I_l$ 通过退化操作的逆操作重建出的高分图; $\delta'$ 为逆操作的参数。一般而言,基于低分图重建的高分图不会和原始高分图一致,因此使用 $\hat{I}_h$ 和 $I_h$ 作区分。在图像重建领域,通常采用结构相似度(SSIM)和峰值信噪比(PSNR)两个指标来评价高分图重建效果。SSIM是衡量两幅相

近图像近似度的指标,将两幅图像的失真建模看作亮度、对比度和结构这 3 个因素的组合。假设两幅输入图像分别为 $X$ 和 $Y$ ,那么 SSIM 的数学定义为

$$S_{\text{SIM}}(X, Y) = \frac{(2\mu_X\mu_Y + c_1)(2\sigma_{XY} + c_2)}{(\mu_X^2 + \mu_Y^2 + c_1)(\sigma_X^2 + \sigma_Y^2 + c_2)}, \quad (13)$$

式中: $\mu_X$ 为 $X$ 的平均值; $\mu_Y$ 为 $Y$ 的平均值; $\sigma_X^2$ 为 $X$ 的方差; $\sigma_Y^2$ 为 $Y$ 的方差; $\sigma_{XY}$ 为 $X$ 与 $Y$ 的协方差; $c_1 = (k_1l)^2$ ,  $c_2 = (k_2l)^2$ ,这两个常量用来维持稳定, $l$ 为像素的动态范围, $k_1 = 0.01$ ,  $k_2 = 0.03$ 。评价结果分布在 $[-1, 1]$ ,  $-1$ 表示两幅图像完全不同,  $1$ 表示两幅图像完全相同。

PSNR 在图像压缩领域中用均方误差(MSE)定义,本研究将均方误差用来衡量图像超分重建后的质量。首先需要计算均方误差,给定一个大小为 $m \times n$ 的干净图像 $O$ 和噪声图像 $K$ ,两者的均方误差( $E_{\text{MS}}$ )为

$$E_{\text{MS}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [O(i, j) - K(i, j)]^2. \quad (14)$$

那么峰值信噪比的定义为

$$R_{\text{PSN}} = 10 \lg \left( \frac{M_o^2}{E_{\text{MS}}} \right) = 20 \lg \left( \frac{M_o}{\sqrt{E_{\text{MS}}}} \right), \quad (15)$$

式中:  $M_o$  为图像可能的最大像素值。若每个像素均为 8 位二进制码, 那么其最大像素值为 255, 因此  $E_{\text{MS}}$  越小, 则  $R_{\text{PSN}}$  越大, 图像的质量也就越好。

在现实场景中使用相机拍摄图像时, 可以看作是连续真实世界通过下采样方法获取离散化数据的过

程, 这一过程中, 对连续的图像进行退化处理, 可以表述为

$$f(I_h; \delta) = (I_h) \downarrow_s, \{s\} \subset \delta, \quad (16)$$

式中:  $\downarrow_s$  表示比例因子为  $s$  的降采样操作。基于 RDN 的主网络, 使用图 5 所示的网络结构, 通过上采样过程将多个特征图的元素对应到新的特征图中, 如图 6 所示。




图 5 超分倍率为 2 的模型网络结构

Fig. 5 Model network structure with super division ratio of 2




图 6 网络上采样过程中, 4 个特征层中的元素对应到新的特征图中

Fig. 6 In the process of upsampling on the network, the elements in the four feature layers correspond to the new feature layer graph

选择 RDN 为超分网络主体后, 为了能够评判重建高分图的准确性, 通常使用像素绝对差值衡量重建高分图和原图之间的差异, 即  $L_1$  损失, 它是网络中原本使用的损失函数。这种方法计算方便, 但是仅在像素层面进行了预测值和原始像素值的比较, 同时, 在零点处不平滑, 容易放大误差值。  $L_1$  损失的表达式为

$$L_1 = \frac{1}{n} \sum_{i=1}^n |\hat{I}_{h,i} - I_{h,i}|. \quad (17)$$

$L_2$  损失是另外一种计算方式, 将模型输出的估计值和真值(原始值)取绝对值得到的结果进行平方, 并将其作为输出结果。  $L_2$  损失函数的优点是在零点处能够快速收敛, 缺点是容易受离群点影响, 特征的权重容易产生波动。  $L_2$  损失的表达式为

$$L_2 = \frac{1}{n} \sum_{i=1}^n |\hat{I}_{h,i} - I_{h,i}|^2. \quad (18)$$

为了能够让模型在各个区域具有更好的收敛性, 防止出现梯度爆炸的情况, 主流的超分网络引入了 Charbonnier 损失来改良  $L_1$  损失, 通过添加一个正则项  $\epsilon$  使损失函数能够同时实现加速收敛、平滑梯度, 能够更好地处理异常值、优化图像重建的结果。

Charbonnier 损失的表达式为

$$L_c = \sqrt{|I_h - \hat{I}_h|^2 + \epsilon^2}. \quad (19)$$

## 3 实验分析

### 3.1 实验流程与准备

本文方法的整体流程如图 7 所示: 在标定系统相关参数后, 首先对金属叶片表面进行多角度光源的图像采集, 利用先前训练好的超分模型对图像进行高分辨率重建, 实现采样分辨率强化, 改善图像微小特征描述符信息; 然后, 采用光度立体融合重建的方式实现图像表面法向贴图增强重建, 最终得到二维强化的融合重建图像。重建图像拥有多个层面的图像信息, 相较于原始图像包含更多细节信息, 更有利于人眼判断和计算机识别。

本文的实验环境与参数配置如下: 计算机 CPU 为 Intel i9-9900X, 显卡为 RTX 2080Ti, 所有代码基于 Pytorch 的深度学习框架, 内存为 32 GB; 工业相机型号为映美精 DMK 33GX264, 拍摄使用分辨率为 1920 pixel  $\times$  1080 pixel, 为获取金属叶片的高分图, 使

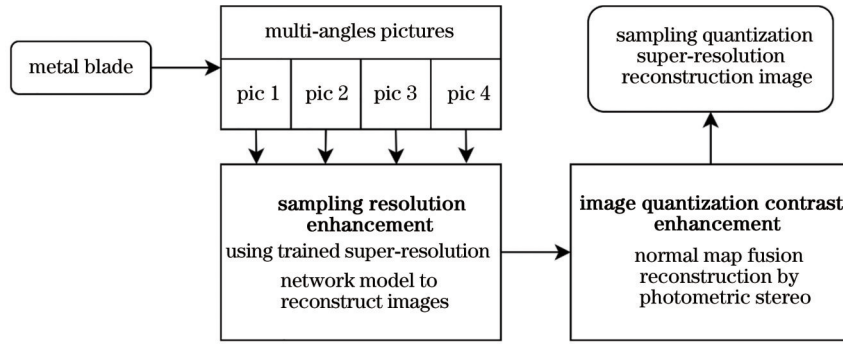


图 7 本文方法的流程

Fig. 7 Flow chart of proposed method

用相机在光度立体的实验台进行拍摄,获得含缺陷叶片图像共计 984 幅,每次采集的时候移动叶片,重新布置其位置,同时将叶片的分布场景进行不同的布置,使其在图像中的位置和形态各不相同,以获取更多的纹理特征。为了使模型具备更好的泛化性能,在对不同叶片的拍摄过程中,需要对相机进行标定。为了提升叶片特征的提取范围,在保持相机位置不变的情况下,小幅度调整镜头的对焦环和光圈,让超分网络对过亮、过暗、虚化图像能够具有更好的重建能力。超分网络训练过程中使用的超参数如表 2 所示。

表 2 超分网络训练过程的超参数配置

Table 2 Hyper parameters selection in the training process of super-resolution networks

Hyper parameter	Value
Epoch	10
Batch	96
Iteration	300000
Learning rate	0.0001
Decrease rate of learning rate	0.5

实验过程中评价缺陷检测方法性能的指标各有优劣,本研究采用分类混淆矩阵作为评价指标,混淆矩阵的具体含义如表 3 所示,其中,Positive 表示正样本, Negative 表示负样本, TP 表示实际为正样本,并且判断

也为正样本,即判断正确; FP 表示实际为负样本,但是判断为正样本,即误判。其余情况以此类推。仅 TP 和 TN 为判断正确,以此来计算检测正确率( $A_{CC}$ ),计算公式为

$$A_{CC} = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (20)$$

式中:  $N_{TP}$  为 TP 的数量;  $N_{FP}$  为 FN 的数量;  $N_{FN}$  为 FN 的数量;  $N_{TN}$  为 TN 的数量。

表 3 检测结果混淆矩阵

Table 3 Test result confusion matrix

Ground truth	Predicted result	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

### 3.2 图像量化超分辨重建测试

采用图 8 所示实验台进行量化超分辨重建测试。图 9 所示为灰度图成像细节。图 9(a) 中存在两处人为添加的墨迹痕迹,对灰度图进行拍摄时容易产生二维歧义性,难以判断是墨迹特征还是叶片本身的气模孔特征,同时右上角存在边界不清晰的划痕;图 9(b) 中存在二维歧义性的墨迹痕迹;图 9(c) 中由于灰度图本身的对比度问题,侧面 3 个凹孔的边界不清晰;图 9(d) 中存在表面灰尘引起的二维歧义性,同时上中部的一个微小凹痕在灰度图中边界不清晰。




图 8 量化超分辨重建测试平台。(a)实验台;(b)拍摄结果

Fig. 8 Quantitative super-resolution reconstruction test platform. (a) Experiment platform; (b) shooting result

保持物体静止,采集不同角度下光源的叶片灰度图(图 10)后,对灰度图进行光度立体量化超分辨重

建,并将重建的法向贴图结果与灰度图成像效果进行对比。




图 9 灰度图成像细节展示。(a)叶片灰度图;(b)~(e)对应局部区域图

Fig. 9 Imaging detailed display of gray image. (a) Blade gray image; (b)~(e) corresponding local area pictures




图 10 不同光源角度采集的灰度图

Fig. 10 Gray scale images collected from different light source angles

图 11 所示为彩色法向贴图。通过对比图 9(b) 和图 11(b), 可以清晰看出通过光度立体融合重建的图

像能够避免墨迹干扰, 同时图 11(b) 中显示出右上区域的微小划痕。




图 11 量化超分辨重建细节对比图。(a)叶片法向贴图;(b)~(e)对应局部区域图

Fig. 11 Detailed comparison of quantitative super-resolution reconstruction. (a) Blade normal map; (b)~(e) corresponding local area pictures

图 12 为融合重建前后特征边界对比图。可以看出, 光度立体可以克服二维图像中的歧义性和低对比度的弊端, 用法向贴图实现图像对比显示层面的强化。用 Canny 算子<sup>[16]</sup>进行边界提取, 结果如图 13 所示。其中, A0、B0、C0、D0 分别为图 9(b)~(e); A1、B1、C1、D1 分别为 A0、B0、C0、D0 的边界特征提取效果; A2、B2、C2、D2 分别为图 11(b)~(e); A3、B3、C3、D3 分别为 A2、B2、C2、D2 的边界特征提取效果。

图 13 中首行(均有数字 0, 称 0 行; 下同)表示图 9(b)~(e), 1 行图像是对 0 行图像的特征边界进行提取的结果。从首列(均有字母 A, 称 A 列; 下同)的特征提取情况可以看出, 图像表面污渍不会改变物体形貌的纹理, 因此法向贴图可以去除图像二维歧义性带来的无用信息干扰, C 列、D 列中由于微小特征边界的不清

晰难识别, 通过法向贴图可以高效快速地定位特征位置, 描述特征边界, 去除干扰信息。由此可见, 所提方法是一种维度增强方法, 称为量化对比度特征增强方法。

### 3.3 图像采样超分辨重建测试

在实验台采集到真实的高分图后, 需要对每幅高分图进行下采样, 以获取对应的低分图, 使用相机拍摄这一方法难以实现, 因此使用一种比较便捷的下采样方法: 使用基于 BiCubic 基函数的双三次插值进行降采样处理, 双三次插值方法通过找到一种关系, 将对应采样点周围 16 个点的灰度值进行三次插值, 不仅考虑了直接相邻 4 个点的灰度影响, 还考虑了各零点灰度值变化率的影响。BiCubic 基函数的表达式为

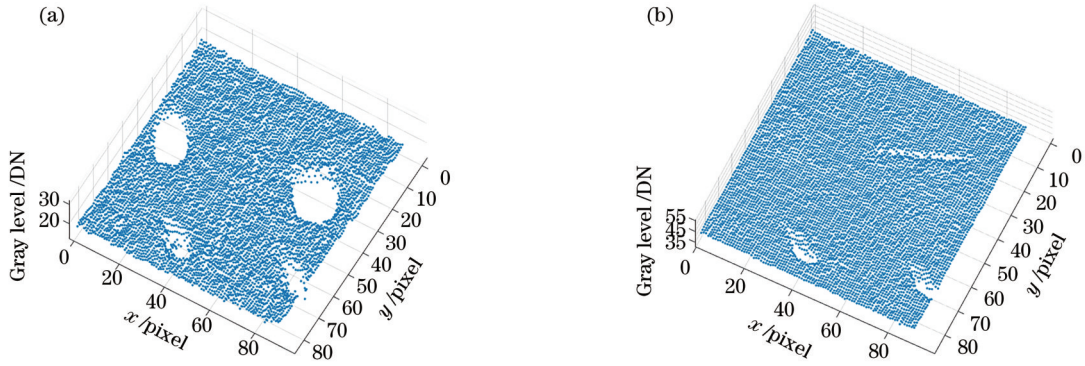


图 12 融合重建前后特征边界对比图。(a)图 9(b)区域;(b)图 11(b)区域

Fig. 12 Comparison of feature boundaries before and after fusion reconstruction. (a) Fig. 9 (b) area; (b) Fig. 11 (b) area




图 13 边界提取效果对比

Fig. 13 Comparison of boundary extraction effects

$$W(x) = \begin{cases} (a+2)|x|^3 - (a+3)|x|^2 + 1, & |x| \leq 1 \\ a|x|^3 - 5a|x|^2 + 8a|x| - 4a, & 1 < |x| < 2, \\ 0, & \text{otherwise} \end{cases} \quad (21)$$

式中： $a$ 为基函数的系数，取 $-0.5$ 。处理之后可以较好地模拟低分辨率相机所采集的图像，从而与真实高分图组成低分图和高分图的图像对，如图 14 所示。

为了加快模型的训练速度，提升模型的训练效果，在载入数据的预处理阶段对图像进行随机裁剪分块<sup>[17]</sup>，通过编写程序，将图像按照步长将原始图像裁剪为  $480 \text{ pixel} \times 480 \text{ pixel}$  的等宽高小图像；在加载数据集阶段累叠小图像，方便图像进行训练；增广训练集时，随机水平、垂直翻转小图像，并且调整亮度以及对比度，用于模拟现实拍摄中可能出现的多种纹理和外部条件。随机初始化网络参数，采用表 2 的超参数进行多次训练，最终得到 10 个超分模型。经过研究发现，上述操作能够有效提高重建高分图和原图的结构

相似度和峰值信噪比。针对金属叶片表面的纹理特征，使用不同网络进行训练，选取对应效果最好的重建结果作为高分图，高分图对靶标局部图像的长和宽分别缩小 50% 后得到。峰值信噪比与结构相似度由对应高分图和局部图像计算得到，对比结果如图 15 所示，数据对比如表 4 所示。从表 4 可以观察到，本文模型的两项指标值均较高，同时在训练过程中发现由于优化了 RDN 网络原本的损失函数，加快了收敛速度，边缘没有出现锯齿状的失真现象。相较于局部图像，高分图可以丰富离散图像中的像素数目，实现图像像素  $x$ - $y$  层面的细节加强，能够实现叶片表面特征描述子的增强，称为图像采样信息超分辨增强。

### 3.4 叶片表面缺陷检测测试

使用不同的图像增强与重建方法对采集图像进行处理，利用 Canny 算子对金属叶片表面的缺陷进行检测对比，调整硬件，采集到的原始金属叶片图像如图 16 所示。图 16 中的主要缺陷类型为凹坑，图 16(b) 箭头所指为黑色污渍，并非缺陷。通过不同的方法强






图 14 真实图像中高分图和低分图对比。(a)原始图像;(b)局部高分辨率图像;(c)局部下采样低分辨率图像

Fig. 14 Comparison of high-resolution and low-resolution images in real images. (a) Original image; (b) local high-resolution image; (c) local down sampling low-resolution image




图 15 不同超分网络金属叶片表面图像超分效果对比。(a)原始图像;(b)局部区域的图像;(c)~(g)使用RDN、SRGAN、EDSR、SRCNN、本文方法得到的局部效果

Fig. 15 Comparison of the effect of different super dividing networks on the surface image of metal blades. (a) Original picture; (b) local picture; (c)-(g) effects of local area using RDN, SRGAN, EDSR, SRCNN, and proposed method

表 4 金属叶片多种超分效果对比

Table 4 Comparison of various super-resolution effects of metal blades

Model	RDN	SRGAN	EDSR	SRCNN	Ours
PSNR	41.4	38.1	38.1	40.8	41.5
SSIM	0.96	0.93	0.96	0.96	0.96

化金属叶片表面的缺陷特征,采集的图像如图 17 所示。

图 17(a)所示为采用文献[10]方法得到的强化结果,该融合重建方法是一种比较常用的传统方法,采集多个角度光源图像进行处理,融合成一幅噪声少、特征清晰的叶片图像;图 17(b)所示为采用文献[5]的特征提取方法得到的强化结果,该方法在传统方法上进行了创新,通过小波变换-同态滤波方法进行图像增强,使用二次小波变换提取低频信息,对低频图像采用同态滤波进行强化,对高频图像进行高通滤波,并进行二

次小波逆变换得到强化后的图像;图 17(c)所示为采用本文方法进行超分辨率图像重建的结果,本文方法屏蔽了二维歧义性的干扰,同时使用法向贴图进行缺陷凹坑特征强化,使用超分网络提高了分辨率,更有利于人眼和算法识别。采用 Canny 边缘检测算子进行特征提取实验,结果如图 18 所示。

图 18(a)所示的原始叶片表面容易受到金属反光和细小颗粒的影响,同时也容易受到图像二维歧义性的干扰,导致误将污渍识别为缺陷;如图 18(b)、(c)所示,图像增强对缺陷的检出率有一定提升作用,但还是受到二维歧义性干扰,同样将污渍误检为缺陷,对微小凹坑也有漏检现象;从图 18(d)可以看到,本文方法能够从量化对比度层面强化缺陷的特征,从采样分辨率层面强化缺陷的描述符,提升微小缺陷的可见性,获得更好的效果。

图 19 所示为对灰度照片与融合重建后的图像进




图 16 金属叶片图像及表面缺陷。(a)原图;(b)局部图像

Fig. 16 Metal blade image and surface defects. (a) Original picture; (b) local picture




图 17 不同方法的强化结果。(a)文献[10]方法;(b)文献[5]方法;(c)本文方法

Fig. 17 Strengthening results of different methods. (a) Method of Ref. [10]; (b) method of Ref. [5]; (c) proposed method




图 18 使用不同方法检测缺陷的结果。(a)检测的原始图像;(b)文献[10]方法的检测结果;(c)文献[5]方法的检测结果;(d)本文方法的检测结果

Fig. 18 Defect detection results by different methods. (a) Original detection image; (b) detection result by method of Ref. [10]; (c) detection result by method of Ref. [5]; (d) detection result by proposed method

行微小缺陷提取的效果对比。图 19(a)中左侧箭头指代轮廓不清晰导致的漏提取情况,右侧箭头指代污渍等二维歧义性导致的误提取情况。图 19(b)所示为采用超分辨率增强重建后对图像微小缺陷的提取结果。为了方便观察,将图 19(a)、(b)未检测出而强化后检测出的微小缺陷进行 10 倍放大对照,分别如图 19(c)、(d)所示。可以观察到,强化后的微小缺陷在对比度、

像素密集程度两个层面均优于原图,表明相较于传统方法,本文方法可将缺陷检出率提升 24.3%,体现出图像超分辨率增强重建的效果。根据前文阐述的准确度计算方式,本文方法的缺陷提取准确度如表 5 所示。由上述分析可知,所提出的面向金属叶片表面微小缺陷识别的图像超分辨率增强技术对微小缺陷的强化和识别有较好的提升效果。




图 19 图像超分辨率增强重建后微小缺陷边界提取效果。(a)局部图像边界提取;(b)增强重建特征提取;(c)(d)细节放大图

Fig. 19 Effect of micro defect boundary extraction after image super-resolution enhancement and reconstruction. (a) Local picture boundary extraction; (b) enhanced reconstruction feature extraction; (c)(d) detail enlarged view

表 5 不同方法提取叶片表面缺陷效果的对比

Table 5 Comparison of extraction effect of blade surface defects by different methods

Method	Ground truth	Detection number		Accuracy / %
		Flaw	Not flaw	
Origin picture	Flaw	27	6	72.9
	Not flaw	4	0	
Method of Ref. [10]	Flaw	28	5	75.7
	Not flaw	4	0	
Method of Ref. [5]	Flaw	30	3	81.1
	Not flaw	4	0	
Proposed method	Flaw	32	1	97.2
	Not flaw	0	4	

## 4 结 论

应用所提出的图像超分辨率重建技术可以有效提高金属叶片表面缺陷的识别率,降低二维歧义性导致的误检率。从实验结果可见:所提方法对金属叶片表面微小缺陷的识别率相较于传统方法可提升 24.3%,尤其在叶片表面存在污渍、灰度图光照效果差的情况下,图像量化对比度增强可以屏蔽污渍等非缺陷特征并提升表面的显示对比度,图像采样信息增强可以提升像素密集度,减少缺陷因像素太低而被忽略的情况,所提方法在工业静态检测中有较好的应用前景,但是在动态检测过程中因现有设备体积较大而受到影响。

与现有的工作方法相比,所提出的方法应用在图像输入预处理阶段,可以方便地集成到缺陷检测算子

之前,有利于推广以及普及。所提出的方法目前仍旧存在一些局限性,如图像超分过程中耗时较长,可以通过采用精简轻量化的网络对检测对象进行针对性数据训练,集成光度立体的硬件结构,拓展图像融合重建二维信息增强的适用范围,提高鲁棒性。

## 参 考 文 献

- [1] 曾艳阳, 谢高森, 张建春. 基于截距直方图和 Otsu 融合的弱光图像分割[J]. 激光与光电子学进展, 2021, 58(20): 2010016.
- [2] Zeng Y Y, Xie G S, Zhang J C. Weak-light image segmentation based on intercept histogram and Otsu fusion[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2010016.
- [3] Wang Y, Chen J, Han Y J, et al. Combining attention mechanism and Retinex model to enhance low-light images[J]. Computers & Graphics, 2022, 104: 95-105.
- [4] Al Sobhahi R, Tekli J. Low-light homomorphic filtering network for integrating image enhancement and classification[J]. Signal Processing: Image Communication, 2022, 100: 116527.
- [5] 王珏, 张秀英, 蔡玉芳, 等. 联合小波变换和 RSF 模型的 CT 图像分割方法[J]. 光学学报, 2020, 40(21): 2110003.
- [6] Wang J, Zhang X Y, Cai Y F, et al. CT image segmentation method combining wavelet transform and RSF model[J]. Acta Optica Sinica, 2020, 40(21): 2110003.
- [7] Tang B, Kong J Y, Wang X D, et al. Image enhancement and segmentation algorithm for low-contrast small defects on steel plate[J]. Journal of Image and Graphics, 2020, 25(1): 81-91.
- [8] Liu F J, Hua Z, Li J J, et al. Low-light image enhancement network based on recursive network[J]. Frontiers in Neurobotics, 2022, 16: 836551.
- [9] Hao P C, Yang M, Zheng N N. Subjective low-light image enhancement based on a foreground saliency map model[J]. Multimedia Tools and Applications, 2022, 81(4): 4961-4978.
- [10] Martínez S S, Vázquez C O, García J G, et al. Quality inspection of machined metal parts using an image fusion technique[J]. Measurement, 2017, 111: 374-383.
- [11] Liu G T, Zhou J H, Li T, et al. Infrared and visible image fusion through hybrid curvature filtering image decomposition[J]. Infrared Physics & Technology, 2022, 120: 103938.

- [10] Xiang Z, Wu H X, Zhou D. Metallic debossed characters industrial online non-segmentation identification based on improved multi-scale image fusion enhancement and deep neural network[J]. IET Image Processing, 2022, 16(3): 852-868.
- [11] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution[M]//Fleet D, Pajdla T, Schiele B, et al. Computer vision-ECCV 2014. Lecture Notes in Computer Science. Cham: Springer, 2014, 8692: 184-199.
- [12] 胡芬, 林洋, 侯梦迪, 等. 基于深度学习的细胞骨架图像超分辨率重建[J]. 光学学报, 2020, 40(24): 2410001.  
Hu F, Lin Y, Hou M D, et al. Super-resolution reconstruction of cytoskeleton image based on deep learning[J]. Acta Optica Sinica, 2020, 40(24): 2410001.
- [13] Ward C M, Harguess J, Crabb B, et al. Image quality assessment for determining efficacy and limitations of Super-Resolution Convolutional Neural Network (SRCNN) [J]. Proceedings of SPIE, 2017, 10396: 1039605.
- [14] Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [15] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2472-2481.
- [16] 闫河, 赵其峰, 谢敏, 等. 自适应 Canny 算子 PCBA 元器件边缘检测及修复[J]. 光学学报, 2021, 41(5): 0515003.  
Yan H, Zhao Q F, Xie M, et al. Edge detection and repair of PCBA components based on adaptive canny operator[J]. Acta Optica Sinica, 2021, 41(5): 0515003.
- [17] 崔海华, 徐振龙, 杨亚鹏, 等. 一种基于深度学习图像超分的环形靶标稳定检测方法[J]. 中国机械工程, 2021, 32(23): 2861-2867.  
Cui H H, Xu Z L, Yang Y P, et al. A circular target stability detection method based on deep learning image super-resolution [J]. China Mechanical Engineering, 2021, 32(23): 2861-2867.

## Super-Resolution Image Reconstruction Method for Micro Defects of Metal Engine Blades

Ge Xinxin<sup>1</sup>, Cui Haihua<sup>1\*</sup>, Xu Zhenlong<sup>1</sup>, He Minqi<sup>2</sup>, Han Xuezhi<sup>3</sup>

<sup>1</sup>College of Mechanical & Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, Jiangsu, China;

<sup>2</sup>Aecc Aviation Power Co., Ltd., Xi'an 710021, Shaanxi, China;

<sup>3</sup>AECC Harbin Dongan Engine Co., Ltd., Harbin 150066, Heilongjiang, China

### Abstract

**Objective** Aiming at the difficulty of detection caused by low contrast and insufficient descriptors of micro defects in metal engine blades, this paper proposes a super-resolution image reconstruction technique to enhance micro defects. Various kinds of tiny defects may occur during the manufacturing and use process of metal aero-engine blades, which will have a huge impact on the appearance of the product or even the overall function. Therefore, the detection of tiny defects on the metal surface has profound significance for the overall product quality control and loss assessment of parts. Current detection methods are mostly based on manual detection, which has low reliability. The main factors that make it difficult to identify defects accurately are unclear feature boundaries and low contrast between defect contours and background, other noise in images or the two-dimensional ambiguity interference, and tiny defects with insufficient image descriptors for accurate identification. To address the above problems, researchers have proposed corresponding solutions from the perspective of image enhancement and fusion reconstruction. However, both image enhancement and image fusion methods start from the overall image information, such as adjusting the histogram, contrast, and other comprehensive attributes of the image to strengthen the features of the target, which are prone to problems such as negative optimization and two-dimensional ambiguity interference. Therefore, this paper performs image enhancement from the imaging principle and designs the image feature enhancement technique from the quantization and sampling aspects of image digitization respectively.

**Methods** The image digitization includes two processes: sampling and quantization. With 8 bit grayscale images as examples, the discretization of the continuous coordinates of the image space is called sampling, and the grayscale values of some points, also called sampling points, in the space represent the image. The conversion of the grayscale values of the sampled pixels from analog to discrete quantities is called the quantization of the image grayscale, which determines the gray-level resolution of the image. The super-resolution quantization sampling enhancement technique for images of tiny defects on metal surfaces mainly focuses on contrast enhancement, resolution enhancement, elimination of two-dimensional illumination unevenness, and stain effects of tiny feature details of images. It can reveal low-contrast and

border-unclear details in a way that can be more easily recognized by human eyes and computers while retaining the original clear features of images. In this paper, image enhancement is performed from the principle of imaging technology, and a two-dimensional super-resolution enhancement technique with fused image acquisition and quantization is designed. As the photometric stereo has the characteristics of refined normal mapping reconstruction, this paper proposes an image enhancement reconstruction technique based on photometric stereo and image hyper-segmentation to address the problems of existing methods. For the shortcomings of the quantization level in the digitization process, it uses photometric stereo technology for the high-contrast display to highlight the image contour features, overcoming the deficiency in the previous image with low contrast of fine features and vulnerability to two-dimensional ambiguity interference. For the deficiency of sampling resolution level in the image digitization process, the image hyper-segmentation reconstruction method is introduced to solve the problems of insufficient details and discrete image descriptors caused by the hardware bottleneck in the traditional photometric stereo technology.

**Results and Discussions** Firstly, to compensate for the shortage of quantization capability of fixed-resolution conventional images, the paper designs a photometric stereo-based image reconstruction method to achieve high-contrast normal mapping reconstruction of the blade surface at the image quantization level (Fig. 11). In addition, in terms of insufficient sampling descriptors for small defects, the multi-angle and multi-pose dataset is constructed from real blade images, and the loss function of the super-resolution model is improved by Charbonnier loss based on pixel loss. Additionally, the appropriate hyper-parameters are configured to reconstruct the high resolution and enhance the sampling resolution. The resolution-enhanced images can improve the original image pixel count to two to four times the original (Fig. 15), enhancing image details. Eventually, the super-resolution of small defects at both quantization and acquisition levels is enhanced (Fig. 19). The proposed enhanced reconstruction method finally uses the traditional Canny operator to identify the defect boundary of the blade surface. The experimental results show that the proposed method is immune to two-dimensional ambiguity and can improve the detection rate of minor defects on the metal blade surface by up to 24.3% (Table 5) compared to the traditional method.

**Conclusions** The application of the image super-resolution reconstruction technique proposed in this paper can effectively improve the recognition rate of metal blade surface defects and reduce the false detection rate caused by two-dimensional ambiguity. The experimental results show that the recognition rate of minor defects on the metal blade surface can be improved by 24.3% compared with the traditional method. Especially in the case of stains on the blade surface and poor lighting effect of grayscale images, the image quantization contrast enhancement can shield the non-defective features such as stains and strengthen the display contrast of the surface, and the image sampling information enhancement can be pixel intensive and reduce the defects ignored due to too few pixels. The proposed method has a good prospect of application in industrial static inspection. Compared with the existing methods, the proposed method is applied in the image input preprocessing stage and can be easily integrated before the defect detection operator, which is conducive to promotion and popularization. Subsequently, it is possible to extend the applicability and improve the robustness of image fusion reconstruction with two-dimensional information enhancement by utilizing a streamlined and lightweight network to conduct targeted data training on detection objects and integrating the hardware structures of photometric stereo.

**Key words** image processing; image reconstruction; super-resolution; photometric stereo; apparent morphology; machine vision