

基于多尺度双阶段网络航空发动机 涡轮叶片故障检测研究

王 斌, 许萌敏, 唐绪之
(上海飞机制造有限公司, 上海 201324)

摘要: 工业相机在图像采集过程中受到各种噪声的干扰, 导致故障检测的 FPR-MRCI 值下降; 对此, 研究基于多尺度双阶段网络航空发动机涡轮叶片故障检测方法; 机器视觉利用工业相机与镜头、环型 LED 光源及异形夹持装置, 通过中空旋转平台带动叶片旋转实现全方位图像采集; 针对采集到的图像利用多尺度双阶段网络进行超分辨率重建; 双阶段设计将特征提取和上采样分开处理, 在特征提取阶段深入挖掘图像的本质特征, 上采样阶段则专注于图像的重建和细节优化; 通过本体建模构建涡轮叶片故障检测知识图谱, 实现系统性的故障检测知识整合; 构建基于特征嵌入的涡轮叶片故障检测卷积神经网络模型, 将实体向量与超分辨率重建图像输入特征嵌入模块, 实现涡轮叶片故障检测; 测试结果表明, 设计系统对于检测难度较高的晶界腐蚀、颗粒磨损以及气动磨损故障的检测结果均正确; 设计系统的 FPR-MRCI 整体高于 0.6, 说明设计系统具有较高的故障特征识别率, 同时误报率相对较低。

关键词: 机器视觉; 图像超分辨率重建; 知识图谱; 航空发动机; TransD 模型; 特征嵌入; 涡轮叶片故障检测

Design of an Automatic Fault Detection System for Aircraft Engine Turbine Blades Based on Multi-scale Two-stage Networks

WANG Bin, XU Mengmin, TANG Xuzhi

(Shanghai Aircraft Manufacturing Co., Ltd., Shanghai 201324, China)

Abstract: Industrial cameras are susceptible to various noise interference during image acquisition, resulting in a decrease in the FPR-MRCI value for a fault detection. However, research is conducted on a multi-scale two-stage network based fault detection method for aircraft engine turbine blades. Machine vision utilizes industrial cameras and lenses, circular LED light sources, and irregular clamping devices to achieve omnidirectional image acquisition by driving blade rotation through a hollow rotating platform. Use a multi-scale two-stage network for super-resolution reconstruction of the collected images. The two-stage design separately handles feature extraction and upsampling to deeply explore the essential features of the image during the extraction stage, while the upsampling stage focuses on image reconstruction and detail optimization. Construct a knowledge graph for turbine blade fault detection through ontology modeling, achieving systematic integration of fault detection knowledge. Build a convolutional neural network model for turbine blade fault detection based on feature embedding, inputting entity vectors and super-resolution reconstructed images into the feature embedding module to achieve turbine blade fault detection. The test results indicate that, the design system provides accurate detection results for grain boundary corrosion, particle wear, and aerodynamic wear faults with high difficulty. The design system reaches the FPR-MRCI by over 0.6, with a high fault feature recognition rate and a relatively low false alarm rate.

Keywords: machine vision; image super-resolution reconstruction; knowledge graph; aircraft engine; TransD model; feature embedding; turbine blade fault detection

收稿日期: 2025-02-17; 修回日期: 2025-04-07。

基金项目: 2023 年航空专用先进数字化制造系统基础软件项目 (ZTZB-23-990-027); 上海市经济和信息化委员会课题 (201101004); 上海市科学技术委员会课题 (11DZ1120600)。

作者简介: 王 斌 (1985-), 男, 硕士, 高级工程师。

引用格式: 王 斌, 许萌敏, 唐绪之. 基于多尺度双阶段网络航空发动机涡轮叶片故障检测研究[J]. 计算机测量与控制, 2026, 34(3): 1-8, 17.

0 引言

涡轮叶片作为航空发动机的重要组成部分,在高速旋转时会把高温高压的气流引入燃烧器,维持内部气流正常运转,以保证发动机引擎的正常工作^[1]。在发动机高速运转时,涡轮叶片需要承受高温和较大的机械负荷,这些恶劣的工作环境容易导致叶片表面发生应力集中,从而出现疲劳裂纹等缺陷。这些缺陷不仅会影响发动机的性能,还可能威胁飞机的安全^[2]。例如,裂纹扩展可能导致叶片断裂,进而引发严重的飞行事故。因此,研究一种能够自动、快速、准确地检测航空发动机涡轮叶片故障的系统显得尤为重要^[3]。它不仅可以提高检测效率和精度,还可以降低检测成本和人员风险,为航空工业的发展提供有力的技术支持。

涡轮叶片故障检测领域目前正处于快速发展阶段,研究者们正致力于探索更高效、更智能的检测策略,旨在提升检测精度与效率,确保涡轮叶片的可靠性和安全性,满足航空工业日益增长的安全需求。文献 [4] 聚焦于航空发动机涡轮叶片的射线图像,利用 YOLOv4 模型创新性地提出了一种双主干特征融合策略,用于缺陷的自动化检测。具体来说,该文献通过构建一种包含全面特征映射的新型连接架构,打造了一个专为涡轮叶片射线图像设计的缺陷检测网络。为了丰富样本数据,针对每个缺陷,实施了包括 9 次裁剪、旋转及亮度调整在内的图像增强手段,并在此坚实基础进行了模型的训练与验证。在文献 [4] 中,提出的双主干特征融合策略虽然具有创新性,但当两个主干网络提取的特征集之间相关性低时存在特征融合不当的风险,可能导致检测精度下降。文献 [5] 侧重于由于商用风力涡轮机不可用而导致的小型风力发电机组叶片的缺陷检测。该研究比较了流行的对象定位架构 YOLO 和 Mask R-CNN,以确定检测常见 WTB 缺陷(包括裂纹、孔洞和侵蚀)的最有效模型。尽管 YOLO 和 Mask R-CNN 在对象定位方面表现出色,但它们的泛化能力可能受到训练数据集质量和数量的限制。如果数据集中缺陷类型或形态不够全面,模型可能无法准确识别未知或罕见缺陷,导致其缺陷检测准确性偏低。文献 [6] 深入探索了高压涡轮叶片的缺陷检测技术。该文献采用微焦点工业 CT 技术对其进行精细扫描与三维重建。通过运用滤波反投影算法处理投影图像,成功获取叶片的三维数据及断层图像。此外,该文献还详细分析了透照间隔角度对缺陷识别效果的影响,并对如疏松等内部结构缺陷进行了直观的可视化分析。然而微焦点工业 CT 技术的三维重建精度容易受到多种因素的影响,如果重建精度不足,将影响缺陷识别的准确性。文献 [7] 在涡轮叶片表面裂纹的超声红外热成像检测研究中,通过理论剖析与实验

证相结合的方式,深入探讨了超声红外热成像的检测机理。在此基础上,构建了一个超声红外热成像检测系统,并对含有已知裂纹类型的涡轮叶片进行了针对性的检测。然而超声红外热成像技术虽然具有检测涡轮叶片表面裂纹的潜力,但其检测机理相对复杂。如果检测参数设置不当,会影响其检测准确性。因此设计基于多尺度双阶段网络航空发动机涡轮叶片故障检测研究。具体研究思路如下。

1) 全方位数据采集系统:

采用工业相机+环形 LED 光源+异形夹持装置构成机器视觉模块进行数据采集。

2) 双阶段超分辨率重建:

特征提取阶段:通过多尺度卷积挖掘裂纹/腐蚀等缺陷的深层特征;上采样阶段:采用亚像素卷积层实现细节优化。

3) 故障知识图谱构建:

针对上超分辨率重建后的叶片图像,基于知识图谱进行叶片故障知识图谱的构建,并基于故障图谱结合深度学习模型实现故障检测。

1 航空发动机涡轮叶片故障自动检测设计

1.1 基于机器视觉的航空发动机涡轮叶片图像采集

机器视觉模块由工业相机、工业光学镜头、光源、夹持装置构成,利用其采集航空发动机涡轮叶片图像。综合考虑工业相机的相机数据接口类型、相机分辨率、相机帧率后,选用 CMOS 传感器、较高分辨率与相机帧、Gige 传输接口的海康威视工业相机 MV-CE200-10GM^[8]。由于 MV-CE200-10GM 的接口为 C 型接口,选用同样为 C 型接口的工业光学镜头,同时综合考虑景深、光圈与焦距,选择型号为 MV-DK11160-20MP 的海康威视镜头。为获得更加均匀的照明,减少阴影与反光,使涡轮叶片故障更易被发现,选用环型 LED 光源。接下来设计光源的打光方式,如图 1 所示。

在一个不透明的长方形箱子内放入通过夹持装置夹持的航空发动机涡轮叶片,在靠近航空发动机涡轮叶片的三面粘贴 90°环型 LED 光源,以提供充足照明。为便于相机的图像采集,在涡轮叶片正上方开一个开放天窗。将工业相机与工业光学镜头组装后安装在可滑动调节位置的相机架上。将相机与镜头置于开放天窗正上方并调节其位置以获得清晰的航空发动机涡轮叶片图像。其中夹持装置的设计如下:鉴于航空发动机涡轮叶片的检测面为曲面,设计一种异形夹持装置以适应其形状^[9]。应用双爪卡盘夹持涡轮叶片,夹持部位为涡轮叶片燕尾榫部分,以确保不会损伤涡轮叶片表面,从而影响采集通过结果。中空旋转平台带动涡轮叶片旋转,实




图1 光源的打光方式设计

现全方位的涡轮叶片图像采集。利用电机控制涡轮叶片旋转时的定位,完成图像采集后继续旋转至下一个采集位置,不断循环,获得航空发动机涡轮叶片的全方位采集图像,用下式来表示:

$$K_{LR} = \{K_{LR1}, K_{LR2}, \dots, K_{LRn}\} \quad (1)$$

式中, K_{LRn} 是指第 n 张采集的航空发动机涡轮叶片图像^[10]。利用 K_{LR} 为后续航空发动机涡轮叶片故障检测提供基础数据。

1.2 基于多尺度双阶段网络的叶片图像超分辨率重建

由于工业相机在图像采集过程中,不可避免地会受到各种噪声的干扰,如电子噪声、热噪声等。这些噪声会在图像中表现为随机分布的亮点或暗点,影响图像的清晰度和质量。特别是在低光照条件下,噪声的影响会更加明显,使得故障特征的识别变得更加困难。为此,基于上述获取的航空发动机涡轮叶片图像,进行图像超分辨率重建。双阶段设计将特征提取和上采样分开处理,在特征提取阶段,利用不同尺度的卷积操作对图像进行处理。在上采样阶段,通过短跳跃连接和级联的FRM操作,进一步对图像进行细节处理和优化,抑制噪声的干扰,最终获得重建图像用于故障自动检测。

1) 训练数据集构建。

设训练数据分布为:

$$D = \{[I_{LR}^i, I_{HR}^i]\}_{i=1}^N \quad (2)$$

式中, I_{LR}^i 是指低分辨率输入, I_{HR}^i 是对应的高分辨率真值。

2) 特征提取阶段。

浅层特征提取模块,利用其实现发动机涡轮叶片图像超分辨率重建中的浅层特征提取。其设计如下:本模块集成了多种尺寸的卷积核,它们并行工作以从输入的低分辨率发动机涡轮叶片图像中提取特征^[11]。具体而言,部署了两个 3×3 、一个 5×5 以及一个 7×7 的卷积

层,用于捕捉低分辨率发动机涡轮叶片图像的浅层特征,分别输出特征集 G_0 、 G_1 及 G_2 :

$$G_0 = \varphi\{V_3[\varphi(V_3(K_{LR}))]\} \quad (3)$$

$$G_1 = \varphi\{V_5[\varphi(V_5(K_{LR}))]\} \quad (4)$$

$$G_2 = \varphi\{V_7[\varphi(V_7(K_{LR}))]\} \quad (5)$$

式中, φ 是指 Re LU 函数,是浅层特征提取模块的激活函数; K_{LR} 是指输入的低分辨率发动机涡轮叶片图像即上节的涡轮叶片图像采集结果; V_3 是指 3×3 的卷积运算; V_5 是指 5×5 的卷积运算; V_7 是指 7×7 的卷积运算。其中,较大尺度的卷积核可以捕捉图像的整体结构信息,而较小尺度的卷积核则可以关注图像的细节信息。通过这种方式,网络能够区分出噪声和真实的图像特征,减少噪声对特征提取的影响。

深层特征提取模块的设计如下:鉴于注意力机制在图像超分辨率领域的显著成效,本部分创新性地引入了融合注意力模块 CBAM,旨在高效整合发动机涡轮叶片图像的浅层特征。深层特征提取模块的第一分支通过三大路径实现^[12]。第一路径专注于 3×3 与 5×5 卷积的深层特征挖掘,两者输出融合后,通过额外卷积层进一步提取发动机涡轮叶片 DR 图像特征集特征,随后引入 CBAM 以增强特征提取的针对性,生成发动机涡轮叶片图像特征集 G_3 。其表达式具体如下式:

$$G_3 = B\{\varphi[V_3(G_0 \cdot G_1)]\} + G_1 \cdot G_2 \quad (6)$$

式中, B 是指 CBAM 操作^[13]。全局压缩比 r 影响 CBAM 的通道压缩率, $r = \left[\frac{I(F_i; F_j)}{H(F)} \times C \right]$ 。

第二路径利用 7×7 卷积独立实施发动机涡轮叶片 DR 图像深层特征提取。第三路径结合 1×1 卷积与长跳跃连接,首先对发动机涡轮叶片图像深层特征实施降维处理,随后通过一系列残差卷积块 (RCB) 对 G_3 实施更深层次的特征提取,得到发动机涡轮叶片图像特征集 G_4 。表达式具体如下式:

$$G_4 = \delta[E_1(G_3)], E_2[E_1(G_3)], \dots, E_m[E_{m-1}(G_3)] \quad (7)$$

式中, δ 是指 Concatenate 连接操作; E_m 是指第 m 个 RCB 操作。

最终,利用 1×1 卷积对发动机涡轮叶片图像特征集 G_4 实施维度缩减,获得该第一分支的最终特征集 G_5 :

$$G_5 = \varphi[V_1(G_4)] \quad (8)$$

式中, V_1 是指 1×1 卷积。

深层特征提取模块的第二分支主要运用 DFEB 继续实施第一分支输出的发动机涡轮叶片图像特征信息的深层特征提取,从而获得发动机涡轮叶片图像特征集 G_6 ,具体表达式如下:

$$G_6 = H_d \cdots H_d[H_d(G_3 + G_5)] \quad (9)$$

式中, H_d 是指 DFEB 操作^[14]。

第三分支是 1×1 卷积层和一个长跳跃连接组成的。

为解决深层网络中发动机涡轮叶片影像特征可能因层级加深而逐渐损失的问题,以及避免梯度衰减与梯度激增的问题,特别采用了从原始低分辨率发动机涡轮叶片影像直接引入的长跨度连接,其间运用 1×1 卷积调整通道维度,最终提炼出发动机涡轮叶片影像的特征集 G_7 ,具体表达式如下:

$$G_7 = V_1(K_{LR})C \quad (10)$$

式中, C 是指输出通道,通过特征维度分析确定,即

$$\arg \min_c \left\| \frac{\sum_{i=1}^c \lambda_i}{\sum \lambda_{\text{total}}} - 0.95 \right\|, \lambda \text{ 是指特征值. 深层特征提取}$$

模块的输出为:

$$G_8 = G_5 + G_6 + G_7 \quad (11)$$

3) 损失函数.

在训练过程中,每次迭代都会使用优化器来更新模型的参数.而优化器的更新是基于当前批次数据的损失函数值.因此,需要优先定义损失函数,在训练循环中计算损失并进行反向传播和参数更新.

像素级 MAE 损失,作用在像素空间,均匀梯度,稳定训练:

$$\tau_{\text{MAE}} = \frac{1}{CHW} \sum_{i,j} |I_{HR}(i,j) - I_{SR}(i,j)| \quad (12)$$

式中, CHW 是指通道数、高度、宽度.结构相似性损失 (SSIM),作用在局部窗口:

$$\tau_{\text{SSIM}} = 1 - \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (13)$$

式中, μ_x, μ_y 是指局部均值, σ_{xy} 是指协方差, C_1, C_2 是指亮度稳定常数与对比度稳定常数.

则总损失函数为:

$$\tau = \alpha\tau_{\text{MAE}} + \beta\tau_{\text{SSIM}} + \gamma\|\Theta\|_2 \quad (14)$$

式中, $\alpha=0.7, \beta=0.3, \gamma=0.1, \Theta$ 为正项.

则优化器动态 (AdamW 更新规则) 为:

$$\Theta_t = \Theta_{t-1} - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} - \kappa\Theta_{t-1} \quad (15)$$

式中, η 是指学习率调度, \hat{m}_t 是指动量参数, \hat{v}_t 是指自适应学习率参数, ϵ 是指数值稳定常数, κ 是指衰减系数.

4) 上采样阶段.

上采样阶段由发动机涡轮叶片影像初步重建模块与特征细化模块构成.在发动机涡轮叶片的图像初步重构模块中,仅采用了一个亚像素卷积层与 5×5 大小的卷积核.其中卷积核的尺寸随着不同上采样的倍数而变化.将该模块发动机涡轮叶片影像初步重建结果记为 G_9 ,具体表达式如下:

$$G_9 = V_5[\epsilon(G_8)] \quad (16)$$

式中, ϵ 是指亚像素卷积操作.

特征细化模块融合了短跳跃连接与级联的 FRM,并通过一个 1×1 卷积层来融合发动机涡轮叶片图像特征信息.该模型旨在实施重建后的发动机涡轮叶片图像细节上的处理与优化,以改善重建后的效果,获得最终的发动机涡轮叶片重建图像 J_{SR} :

$$J_{SR} = V_1[H_{FRB} \cdots H_{FRB}(G_9) + G_9] \quad (17)$$

式中, H_{FRB} 是指 FRB 操作.

利用发动机涡轮叶片图像超分辨率重建结果 J_{SR} 实现航空发动机涡轮叶片故障自动检测.采集的航空发动机涡轮叶片图像的超分辨率重建结果如图 2 所示.




图 2 超分辨率重建结果

图 2 展示了经过设计的图像超分辨率重建算法处理后的航空发动机涡轮叶片图像.从图中可以明显看出,图像的质量得到了显著提升.叶片的每一个细节都变得异常清晰,包括叶片的纹理、边缘以及存在的微小瑕疵或损伤.

1.3 基于知识图谱的涡轮叶片故障检测

针对上超分辨率重建后的叶片图像,基于知识图谱进行叶片故障知识图谱的构建,并基于故障图谱结合深度学习模型实现故障检测.

1.3.1 涡轮叶片故障检测知识图谱构建

具体的故障检测步骤如下:为提高涡轮叶片故障检测的准确性,通过构建涡轮叶片故障检测知识图谱实现系统性的涡轮叶片故障检测知识整合.通过本体建模的方式实现航空发动机涡轮叶片检测知识图谱构建,对航空发动机涡轮叶片故障检测知识数据概念、概念属性描述和概念分类之间的关系实施抽象和约束.构建的航空发动机涡轮叶片故障检测知识图谱如下式:

$$\begin{cases} \varphi = \{\varphi, \gamma, \eta, \iota, \kappa\} \\ \varphi = \{\varphi_1, \varphi_2\} \\ \gamma = \{\gamma_1, \gamma_2\} \\ \gamma_1 = \varphi_1 \\ \gamma_2 = \{\varphi_{21}, \varphi_{22}\} \\ \eta = \{\eta_1, \eta_2, \eta_3\} \\ \eta_1 = \{\eta_{11}, \eta_{12}, \eta_{13}, \eta_{14}, J_{SR}\} \\ \eta_2 = \{\eta_{21}, \eta_{22}, \eta_{23}\} \\ \eta_3 = \{\eta_{31}, \eta_{32}, \eta_{33}\} \\ \kappa = \{\kappa_1, \kappa_2\} \end{cases} \quad (18)$$

式中, φ 是指航空发动机涡轮叶片故障检测中的两个一

级概念, 分别为涡轮叶片本体 φ_1 与涡轮叶片故障本体 φ_2 ; γ 是指 φ_1 与 φ_2 的子概念, 分别为 γ_1 与 γ_2 , 其中 γ_1 是指涡轮叶片实体; γ_2 由故障现象实体 φ_{21} 与故障原因实体 φ_{22} 构成; η 是指涡轮叶片实体 γ_1 、故障现象实体 φ_{21} 与故障原因实体 φ_{22} 的关键属性, 分别用 η_1 、 η_2 、 η_3 表示, 其中 η_1 由涡轮叶片的名称 η_{11} 、型号 η_{12} 、序列号 η_{13} 、安装位置 η_{14} 、高分辨率图像重建结果 J_{SR} 构成, η_2 由故障名称 η_{21} 、故障类型 η_{22} (单故障, 多故障)、及故障严重程度 η_{23} (注意、异常、严重) 构成; η_3 由故障名称 η_{31} 、故障分类 η_{32} 、故障处理方式 η_{33} 构成; ι 是指航空发动机涡轮叶片故障检测领域内实体间相互作用和依赖关系的规则, 这些规则通过语义关系 (“发生关系” 和 “导致关系”) 来体现, 并构成了领域本体的重要组成部分; κ 是指语义关系的内容, 其中 κ_1 是指 “发生关系” 这一语义关系的内容: “涡轮叶片—发生—故障原因”, 它揭示了涡轮叶片上特定故障原因的显现, 定义了涡轮叶片与故障原因之间的关联, κ_2 是指 “导致关系” 这一语义关系的内容: “故障原因—导致—故障现象”, 它指出了故障原因如何触发具体的故障表现, 定义了涡轮叶片故障原因与涡轮叶片故障现象之间的因果关系^[15]。

1.3.2 知识图谱的存储与表示学习

将构建的航空发动机涡轮叶片故障检测知识图谱导入 Neo4j 图数据库中存储, 实现该知识图谱的可视化。应用 TransD 模型对构建的航空发动机涡轮叶片故障检测知识图谱实施表示学习, 具体公式如下:

$$F(\varphi, \gamma, \eta, \iota, \kappa) = n_h(\varphi_{\perp}, \gamma_{\perp}, \eta_{\perp}, \iota_{\perp}, \kappa_{\perp}) \cdot n_t(\varphi_{\perp}, \gamma_{\perp}, \eta_{\perp}, \iota_{\perp}, \kappa_{\perp}) \quad (19)$$

式中, φ_{\perp} 、 γ_{\perp} 、 η_{\perp} 、 ι_{\perp} 、 κ_{\perp} 是指航空发动机涡轮叶片故障检测中的一级概念 φ 、子概念 γ 、实体关键属性 η 、航空发动机涡轮叶片故障检测领域内实体间相互作用和依赖关系的规则 ι 以及语义关系内容 κ 的映射向量; n_h 、 n_t 是指 TransD 模型的映射矩阵^[16]。

1.3.3 涡轮叶片故障检测模型设计

此时航空发动机涡轮叶片故障检测知识图谱已经由离散化结构性数据被转化为深度学习模型能够学习使用的矢量连续化数据, 将所获得的实体向量作为涡轮叶片故障检测卷积神经网络模型的第一个输入。超分辨率重建图像作为涡轮叶片故障检测卷积神经网络模型的第二个输入。计算公式具体如下:

$$\zeta = \frac{1}{\text{context}[F(\varphi, \gamma, \eta, \iota, \kappa)]} J_{SR} \quad (20)$$

式中, $\text{context}[F(\varphi, \gamma, \eta, \iota, \kappa)]$ 是指该实体相连的全部上下文实体的个数^[17]。

构建基于特征嵌入的涡轮叶片故障检测卷积神经网络模型, 将实体向量与超分辨率重建图像输入特征 ζ 嵌

入模块, 经抽象语义特征提取通道 (4 个残差模块和空间注意力模块) 和缺陷形状先验提取通道 (HOG 特征提取) 处理输出 4 个结果, 全连接成 4 个 2 048 维向量再合并为两个 4 096 维向量, 经特征选择模块筛选得最终特征向量作特征嵌入, 用原型生成模块计算原型向量, 通过计算类别原型向量与查询集特征向量距离分类查询集样本, 得出航空发动机涡轮叶片故障检测结果。构建涡轮叶片故障检测卷积神经网络模型: 构建一个基于特征嵌入的涡轮叶片故障检测卷积神经网络模型, 其运行流程如下:

使第一个输入 (所获得的实体向量) 与第二个输入 (超分辨率重建图像) 经过特征嵌入模块, 获得对应的特征表达图 ξ_1 与 ξ_2 。其中特征嵌入模块的设计如下: 在抽象语义特征提取通道中, 两个输入经过 4 个残差模块后进入空间注意力模块, 获得涡轮叶片故障检测的两个深度语义特征。

所采用的残差模块由两个一致的卷积层构成, 每层均装备 64 个尺寸为 3×3 的卷积滤波器。利用 ReLU 函数, 执行一个将输入转变为输出的非线性映射步骤, 具体计算遵循如下公式:

$$\begin{cases} W(X) = \omega(R_1 \cdot X) \\ X = F(\varphi, \gamma, \eta, \iota, \kappa), \zeta \end{cases} \quad (21)$$

式中, X 是指涡轮叶片故障检测卷积神经网络模型的两个输入; R_1 是指第一个卷积层的参数; ω 是指非线性激活函数; $W(X)$ 是指第一个卷积层的输出^[18]:

$$X_{\text{out}} = X + \omega[R_2 \cdot W(X)] \quad (22)$$

式中, X_{out} 是指第二个卷积层的输出; R_2 是指第二个卷积层的参数。

空间注意力模块设计: 以第 4 个残差模块的两个输出为输入, 沿通道维度分别进行最大池化和平均池化, 得到两个新特征图。在通道维度合并它们, 形成两个新输出特征图, 经卷积层并通过激活函数非线性转换, 获得两个注意力模板。将注意力模板与初始输入实体向量逐元素相乘, 得到模块两个输出结果。此过程依据不同注意力权重对输入特征图不同部位加权, 实现空间注意力机制。该模块的具体操作如下式:

$$J_{\text{out}} = J_{\text{in}} X_{\text{out}} \otimes \varphi\{V_3([A(J_{\text{in}}); M(J_{\text{in}})])\} \quad (23)$$

式中, J_{in} 是指涡轮叶片故障检测中第 4 个残差模块的一个输出; A 是指平均池化操作; M 是指最大池化操作; J_{out} 是指空间注意力模块的输出, 也就是获得的一个涡轮叶片故障检测的深度语义特征^[19]。

在缺陷形状先验提取通道, 对两个输入实施形状先验以获取对应缺陷形状先验提取特征。具体操作是用方向梯度直方图 (HOG) 提取涡轮叶片故障检测深度语义特征: 先归一化两个输入, 计算梯度幅值与方向; 将输入分割成 “单元格”, 统计单元格内梯度方向信息构

建直方图；单元格组合成“块”，对块内单元格直方图再归一化；汇总所有块的特征向量生成最终 HOG 特征描述符，其中一个输入的 HOG 特征描述符如下式：

$$v = J_{\text{out}}[N(B_1), N(B_2), \dots, N(B_M)] \quad (24)$$

式中， $N(B_M)$ 是指一个输入的第 M 个块的归一化直方图特征向量。

对两个通道的 4 个输出分别进行全连接操作，得到 4 个 2 048 维向量。将各通道的两个 2 048 维向量合并，得两个 4 096 维向量。合并后的向量经特征选择模块，得到最终的涡轮叶片故障检测特征向量，作为最初图像的特征嵌入。特征选择模块受空间注意力模块启发，通过分配特征权重系数筛选高维特征信息，增强与故障相关特征作用。以 4 096 维向量为例，其流程为：将向量输入含 N （默认 40）个 1×1 卷积核的卷积层，输出 $4\,096 \times N$ 维特征图；对特征图按通道维度平均池化产生权重系数；用系数乘原始 4 096 维向量，得到筛选后的特征向量。该模块的具体操作如下式：

$$\tau_{\text{out}} = v\tau_{\text{in}} \otimes A[V_1(J_{\text{in}})] \quad (25)$$

式中， τ_{in} 是指两个 2 048 维的向量合并后获得的 4 096 维的特征向量； τ_{out} 是指特征选择模块的输出。

对于所获得的涡轮叶片故障检测特征表达图 ξ_1 与 ξ_2 ，通过下式的原型生成模块对其支持集中全部特征表达图的特征向量实施平均操作，计算获得一个涡轮叶片故障检测原型向量，表示该类别的中心：

$$D_k = \frac{1}{|z_k|} \sum_{(\xi_1, \xi_2) \in z_k} \vartheta(\xi_1) \tau_{\text{out}} \quad (26)$$

式中， D_k 是指第 k 类的涡轮叶片故障检测原型向量即第 k 类的涡轮叶片故障； z_k 是指第 k 类输入的涡轮叶片故障检测支持样本集； ϑ 是指四层卷积^[20]。

原型生成后，通过下式计算涡轮叶片故障检测中每个类别原型向量到查询集特征表达图的特征向量之间的距离，使涡轮叶片故障检测查询集样本被分类至距离最近的原型向量所表示的类别，获得航空发动机涡轮叶片故障检测结果：

$$\mu(\xi_2 = k | \xi_1) = \frac{\exp\{-\omega[\vartheta(\xi_1), D_k]\}}{\sum_k -\omega[\vartheta(\xi_1), D_k]} \quad (27)$$

式中， $\mu(\xi_2 = k | \xi_1)$ 是指航空发动机涡轮叶片故障分类结果； ω 是指欧几里得距离函数； μ 是指查询的航空发动机涡轮叶片故障样本标签为 k 的概率。就此完成航空发动机涡轮叶片故障检测。

2 实验测试

2.1 实验环境

对于设计的基于多尺度双阶段网络航空发动机涡轮叶片故障检测方法，利用其检测多个航空发动机涡轮叶片的故障，测试其实际检测性能表现。在测试中，首先搭建机器视觉模块，如图 3 所示。




图 3 搭建的机器视觉模块

根据上述所示机器视觉模块（MV-CE200-10GM 相机+环形 LED 光源），对涡轮叶片进行 360° 旋转拍摄。对 6 种典型故障类型（叶尖裂纹、气孔腐蚀、边缘变形、表面剥落、热障涂层脱落、榫头磨损）分别采集 50 组叶片样本，每组叶片通过中空旋转平台获取 72 个角度的图像（ 5° 间隔），共形成 $6 \times 50 \times 72 = 21\,600$ 张原始图像。原始分辨率： $4\,096 \times 3\,000$ 像素，存储为 16 位灰度 PNG 格式。利用基于多尺度双阶段网络的图像超分辨率重建算法实施采集的航空发动机涡轮叶片图像的超分辨率重建。在该步骤中，计算机配置如下：系统：Ubuntu 18.04；CPU：Inter Core i7-12700H；GPU：Nvidia Ge Force RTX 3060；深度学习框架：Pytorch1.8.1；编程语言：Python 3.。实验参数的设置情况如表 1 所示。

表 1 实验参数的设置情况

参数项目	参数设置
初始学习率	0.000 1
迭代次数	1 000
损失函数	交叉熵损失函数
学习率衰减率	0.95
epoch	120
优化器	AdamW
第一时刻梯度估计的衰减速度	0.5
第二时刻梯度估计的衰减速度	0.9
批大小	4

在故障检测模块中，特征嵌入层输出维度设置为 4 096 维，通过融合知识图谱向量与超分辨率图像特征实现高维语义表达。残差模块采用 64 个 3×3 卷积核的四层堆叠结构，配合 1×1 （ $N=40$ ）的空间注意力卷积核实现局部特征增强。HOG 特征提取器以 8×8 像素为单元格划分基准，捕获叶片表面的梯度方向分布特性。分类阶段采用原型学习策略，当测试样本与类别原型的欧氏距离超过 0.3 时触发故障判定。故障严重程度分级阈值设定为：概率值大于 0.2 标记为“需注意”状态，超过 0.5 判定为“异常”，达到 0.8 则归类为“严重故障”。超分辨率重建模块同步运行，其训练参数包括初

始学习率 0.000 1、120 个 epoch 的 Adam 优化 (动量衰减率为 0.5、0.9) 及批大小 4 的交叉熵损失优化。

2.2 实验指标

测试设计方法航空发动机涡轮叶片检测的准确性, 测试指标包括实际检测效果、FPR-MRCI (故障特征识别率与误报率综合指标)、噪声下的故障特征识别准确性指数。

1) 其中 FPR-MRCI 指标能够直观地反映方法在涡轮叶片故障检测中的综合性能。一个高的 FPR-MRCI 意味着方法具有较高的故障特征识别率, 同时误报率相对较低。这样的方法能够更准确地识别出涡轮叶片的故障特征, 同时减少不必要的误报。

2) 噪声下的故障特征识别准确性指数则直接反映了方法在复杂多变环境下的故障特征识别能力。通过加入噪声, 可以清晰地了解方法在实际应用中涡轮叶片故障检测准确性的表现。

在测试中, 将文献 [5] 基于深度学习的航空发动机涡轮叶片自动射线检测技术、文献 [6] 基于微焦点工业 CT 的高压涡轮叶片缺陷检测技术以及文献 [7] 航空发动机涡轮叶片表面裂纹的超声红外热成像检测技术作为对比技术进行测试分析。

2.3 测试结果分析

首先基于表 1、表 2 的实验参数的设置情况测试设计方法与 3 种对比技术的实际检测效果, 检测的故障包括晶界腐蚀、颗粒磨损、气动磨损, 均为检测难度较高的故障。对比测试结果如图 4 所示。




图 4 实际检测效果的对比测试

设计方法对于 3 种故障的检测结果是正确的, 基于深度学习的技术混淆了颗粒磨损与气动磨损故障, 基于微焦点工业 CT 的技术对于颗粒磨损故障的检测是错误的, 将该故障检测成了 High temperature gas corrosion

即高温燃气腐蚀故障。超声红外热成像检测技术对于气动磨损的检测是错误的, 将该故障检测成了 thermal fatigue damage 即热疲劳损伤故障。设计方法在航空发动机涡轮叶片故障检测中表现更好的原因可以总结如下: 知识图谱的构建使设计方法能够系统地整合涡轮叶片故障检测知识。同时该方法将航空发动机涡轮叶片故障检测知识图谱中的离散化结构性数据转化为深度学习模型能够学习的矢量连续化数据。这种转化使得数据更加适合深度学习模型的处理, 提高了数据的利用率和模型的泛化能力。

设计方法与 3 种对比技术的 FPR-MRCI 测试结果如图 5 所示。




图 5 FPR-MRCI 测试结果

由图 5 可以看出, 设计方法的 FPR-MRCI 整体高于 0.6, 在 4 种方法中表现最好。基于深度学习的航空发动机涡轮叶片自动射线检测技术的 FPR-MRCI 在 0.3~0.6 之间; 基于微焦点工业 CT 的高压涡轮叶片缺陷检测技术的 FPR-MRCI 在 0.25~0.75 之间; 航空发动机涡轮叶片表面裂纹的超声红外热成像检测技术的 FPR-MRCI 在 0.2~0.65 之间。由此结果说明设计方法具有较高的故障特征识别率, 同时误报率相对较低。这是由于设计方法在特征提取阶段, 设计方法利用残差模块和空间注意力模块, 有效地捕捉了涡轮叶片故障的深度语义特征。同时, 特征选择模块通过分配特征权重系数, 筛选出了与故障紧密相关的高维特征信息, 进一步增强了模型的故障识别能力。

加入不同强度的噪声后, 设计方法与 3 种对比技术的噪声下的故障特征识别准确性指数测试结果如图 6 所示。




图 6 故障特征识别准确性指数测试结果

从图中可以看出,随着噪声强度的增加,所有方法的故障特征识别准确性都有所下降,但设计方法的下降幅度相对较小,表现更加稳定。这是由于设计方法采用了高质量的工业相机、光学镜头和光源,确保了采集到的航空发动机涡轮叶片图像的高清晰度和高质量。夹持装置的设计考虑了涡轮叶片的形状和检测需求,有效避免了损伤和阴影干扰,提高了图像采集的准确性。设计方法还构建了涡轮叶片故障检测知识图谱,实现了系统性的涡轮叶片故障检测知识整合,提高了故障检测的准确性和效率。以及卷积神经网络模型的设计考虑了特征嵌入、空间注意力机制和形状先验提取等多个方面,能够充分提取和利用故障特征信息,提高了故障检测的准确性。

为进一步验证设计方法知识图谱构建的实用性,进行测试分析。进行实体关系定义如表 2 所示。

表 2 实体关系

头实体	关系类型	尾实体	权重
叶尖裂纹	caused_by	冷却孔应力集中	0.93
涂层脱落	requires	热障层厚度检测	0.88

根据此进行复合评价,在航空发动机故障检测场景中,单一指标(如准确率)无法全面反映系统性能。本复合指标由三类核心指标加权构成,准确率主导(60%);

召回率次重(30%); F_1 值补充(10%)。结果如表 3 所示。

表 3 测试结果

迭代次数/次	检测耗时/ms	复合得分
20	25	93.2
40	26	94.1
60	28	93.5
80	24	93.6
100	22	94.2

根据上述结果可以看出,多次迭代平均得分 93.72,始终高于行业安全阈值(90分)最优值在第 100 次迭代高达 94.2,证明该方法具有稳定性。

工业相机在图像采集过程中受到各种噪声的干扰,导致故障检测性能下降,为验证本文研究的监测性能,进行不同噪声环境下的检测准确性测试。设定 3 种噪声工况:模拟工况 1:高斯(0.02)+椒盐(3%),模拟老化相机常规工作;模拟工况 2:泊松(0=30)+散粒(增益 0.2),模拟高温环境快速拍摄;模拟工况 3:周期性(100 Hz, 10%)+高斯(0.04),模拟强电磁干扰现场。结果如图 7 所示。

根据图 7 可以看出,在不同工况下,研究方法的监测准确性均高于 94%,这充分说明了多尺度双阶段网




图 7 检测准确性结果

络在处理复杂噪声环境下的图像超分辨率重建和故障检测任务中的有效性。综上所述,本文研究的基于多尺度双阶段网络的航空发动机涡轮叶片故障检测方法在不同噪声工况下均表现出了较高的检测准确性。该方法通过多尺度卷积操作和上采样阶段的优化处理,有效地抑制了噪声的干扰,提高了图像的清晰度和质量,从而实现了准确的故障检测。

3 结束语

本研究致力于航空发动机涡轮叶片故障自动检测方法的设计与实现,通过机器视觉模块、图像超分辨率重建模块以及基于知识图谱的故障检测模块的结合,实现了对涡轮叶片故障的高效、准确检测。实验结果表明,该方法在多种故障类型的检测中均表现出色,相较于传统技术具有更高的准确性。

参考文献:

- [1] 刘丽玉,金向明,陈俊,等. 涡轴发动机燃气涡轮叶片断裂原因[J]. 机械工程材料, 2023, 47(12): 98-102.
- [2] 贾宜委,王鹤峰,王宇迪,等. 航空发动机涡轮叶片热障涂层研究现状[J]. 表面技术, 2023, 52(11): 139-154.
- [3] 姚尧,王占学,张晓博,等. 基于冷气预冷技术的高马赫数涡轮发动机建模与仿真研究[J]. 推进技术, 2023, 44(2): 16-31.
- [4] 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): 217-225.
- [5] DAVIS M, NAZARIO DEJESUE E, SHEKARAMIZ M, et al. Identification and localization of wind turbine blade faults using deep learning[J]. Applied Sciences (2076-3417), 2024, 14(14): 6319.
- [6] 李新越,杨龙,孙春贵,等. 基于微焦点工业 CT 的高压涡轮叶片缺陷检测技术[J]. 铸造, 2023, 72(7): 904-908.
- [7] 刘竞雄,崔旭东,马朝阳,等. 航空发动机涡轮叶片表面裂纹的超声红外热成像检测[J]. 无损检测, 2024, 46(3): 5-8.

(下转第 17 页)