

基于 MODE 算法的智能检修图像模型分析

马志强, 曹玉平, 刘建波, 胡伟, 张立杰, 王长周

(国能国华(北京)燃气热电有限公司, 北京 100018)

摘要: 针对工业智能检修中复杂工况下图像噪声污染、缺陷特征弱区分度等问题, 该研究提出基于多目标差分进化算法的智能检修图像模型; 通过灰度共生矩阵与局部二值模式的多特征融合提取宏观至微观缺陷表征, 利用多目标差分进化算法协同优化卷积神经网络参数以平衡模型精度与复杂度, 并结合多尺度特征网络和物理模型驱动的噪声抑制策略提升工业场景适应性; 实验表明, 该模型在裂纹分类准确率达 91.7%, 抗高斯噪声、运动模糊等干扰能力较传统方法提升 16.6%~22.9%, 端到端检测延迟 153.3 毫秒, 为工业设备实时智能检修提供了高效解决方案。

关键词: 智能检修; 多目标差分进化算法; 特征融合; CNN 优化; 鲁棒性设计

Analysis of Intelligent Maintenance Image Models Based on MODE Algorithm

MA Zhiqiang, CAO Yuping, LIU Jianbo, HU Wei, ZHANG Lijie, WANG Changzhou

(Guoneng Guohua (Beijing) Gas Thermal Power Co., Ltd., Beijing 100018, China)

Abstract: To address issues such as image noise pollution and weak distinguishability of defect features under complex working conditions in industrial intelligent maintenance, this paper proposes an intelligent maintenance image model based on the multi-objective differential evolution algorithm (MODE). Macro to micro defect representations are extracted through multi-feature fusion of gray-level co-occurrence matrix and local binary pattern. The multi-objective differential evolution algorithm is used to collaboratively optimize convolutional neural network (CNN) parameters to balance model accuracy and complexity. Additionally, multi-scale feature networks are integrated with physical model-driven noise suppression strategies to enhance their adaptability to industrial scenarios. Experimental results show that the model achieves a crack classification accuracy of 91.7%, and improves the anti-interference capabilities against Gaussian noise, motion blur, etc. by 16.6%~22.9% compared with traditional methods, with an end-to-end detection delay of 153.3 ms, providing an efficient solution for real-time intelligent maintenance of industrial equipment.

Keywords: intelligent maintenance; MODE; feature fusion; CNN optimization; robust design

0 引言

在热能与动力工程、电气工程领域, 设备的安全稳定运行直接影响能源系统可靠性。传统人工检修依赖经验判断, 存在效率低、主观性强等问题; 基于机器视觉的智能检修技术虽已初步应用, 但复杂工况下(如高温、强电磁干扰环境)的图像噪声污染、缺陷特征与背景信息的弱区分度等问题, 导致现有模型的检测精度难以满足工程需求。

针对上述问题, 国内外学者开展了相关研究。国外文献[1]设计了时空联合学习的大坝空洞检测模型,

通过红外图像时序特征分析增强小目标识别能力, 但缺乏对工业设备动态运行过程中噪声时变特性的建模。国外学者 Shao 等提出基于迁移卷积神经网络的转子轴承系统故障诊断方法, 通过热图像特征迁移提升变工况下的检测鲁棒性, 但未涉及多目标优化策略^[2]。国内文献[3]构建了基于 ROV 的水下检修缺陷数据智能处理系统, 通过多传感器数据融合提升检测效率, 但该系统聚焦水下场景, 未解决工业设备表面缺陷的多尺度特征协同提取问题。学者 Ojala 等提出局部二值模式(LBP)的扩展算法, 通过旋转不变性与均匀模式增强纹理特征的抗干扰能力, 为本文局部结构特征提取提供了方法参

收稿日期:2025-06-19; 修回日期:2025-09-08。

作者简介:马志强(1976-),男,大学本科,高级工程师。

引用格式:马志强,曹玉平,刘建波,等. 基于 MODE 算法的智能检修图像模型分析[J]. 计算机测量与控制, 2026, 34(7):164-170, 189.

考^[4]。文献 [5] 将 MODE 算法应用于光伏逆变器参数辨识, 验证了多目标优化在工业场景的有效性, 但其未将该算法与深度学习模型结合, 无法实现图像检测参数的端到端优化。国外学者 Redmon 等提出的 YOLO 系列目标检测算法, 通过单阶段检测架构提升实时性, 但其在小尺度缺陷检测中精度不足^[6]。现有研究在工业图像的多尺度特征融合、复杂噪声抑制及算法优化效率等方面仍存在改进空间。

多目标差分进化算法 (MODE, multi-objective differential evolution algorithm) 作为一种高效的全局优化算法, 通过模拟生物进化过程中的变异、交叉和选择操作, 能够在高维空间中快速搜索最优解。本文将 MODE 算法引入智能检修图像模型, 针对设备缺陷检测的多目标优化需求, 构建“特征提取—参数优化—模型训练”的闭环架构, 实现复杂工业场景下的精准缺陷识别。

1 多特征融合模块的构建

在工业智能检修领域, 单一图像特征难以全面表征复杂缺陷的多尺度特性, 针对这一问题, 本研究提出基于灰度共生矩阵与局部二值模式的多特征融合方案, 通过全局纹理统计与局部结构编码的优势互补, 结合主成分分析实现特征降维, 为后续 CNN 模型提供高效输入。具体流程如图 1 所示。

首先采用灰度共生矩阵提取全局纹理特征, 其核心是通过计算图像中特定方向和距离 ($d=1、3、5$ 像素) 的像素对联合概率分布刻画纹理结构。概率分布通过式 (1) 定义:

$$P(i, j | d, \theta) = \frac{|\{(x_1, y_1), (x_2, y_2) \in I \times I \mid I(x_1, y_1) = i, I(x_2, y_2) = j, \text{dist} = d, \text{angle} = \theta\}|}{\text{总像素对数}} \quad (1)$$

式中, $I(x, y)$ 表示图像在 (x, y) 处的灰度值, $\text{dist}(\cdot)$ 为欧氏距离, θ 为像素对连线与水平轴的夹角。

基于该矩阵衍生出四项关键特征: 通过对比度衡量局部灰度变化程度, 反映缺陷边缘清晰度, 计算公式如式 (2):

$$\text{Contrast} = \sum_{i,j=0}^{L-1} P(i, j) \cdot (i - j)^2 \quad (2)$$

通过能量评估灰度分布均匀性, 缺陷区域通常能量较低, 如式 (3):

$$\text{Energy} = \sum_{i,j=0}^{L-1} P(i, j)^2 \quad (3)$$

通过同质性量化局部灰度相似性, 缺陷区域同质性往往较低, 如式 (4):

$$\text{Homogeneity} = \sum_{i,j=0}^{L-1} \frac{P(i, j)}{1 + |i - j|} \quad (4)$$

通过相关性描述灰度线性依赖性, 结构形变会导致




图 1 多特征融合模块流程图

相关性下降, 如式 (5):

$$\text{Correlation} = \sum_{i,j=0}^{L-1} \frac{(i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j} \quad (5)$$

式中, μ_i, μ_j 为灰度值 i, j 的均值, σ_i, σ_j 为标准差。通过多方向、多距离组合及滑动窗口策略, 实现对各向异性纹理和微小缺陷的捕捉。该方法与 Maenpaa 等提出的自适应纹理特征提取框架思路一致, 均通过多参数组合增强纹理表征的鲁棒性。

其次利用局部二值模式提取局部结构特征, 基本算子通过中心像素 g_c 与邻域像素 g_p 的灰度差异进行二进制编码, 如式 (6):

$$[LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p \quad (6)$$

式中, $s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$, P 为邻域像素数, R 为邻域半径。为增强抗干扰能力, 引入旋转不变 LBP, 通过循环移位取最小值消除旋转影响, 如式 (7):

$$LBP_{P,R}^{\text{rot}} = \min \{ROR(LBP_{P,R}, k) \mid k = 0, 1, \dots, P-1\} \quad (7)$$

式中, $ROR(\cdot)$ 表示循环右移操作。同时采用均匀模式 LBP, 仅保留跳变次数 ≤ 2 的模式以减少噪声, 如式 (8):

$$LBP_{P,R}^{w2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & \text{跳变次数} \leq 2 \\ P+1, & \text{跳变次数} > 2 \end{cases} \quad (8)$$

式中,通过调整邻域半径 R 和像素数 P 实现多尺度分析,并对图像分块统计 LBP 直方图,保留缺陷空间分布信息。

在特征融合与降维阶段,首先将 GLCM 特征与 LBP 特征串联为融合特征向量,特征权重通过互信息最大化策略动态确定:计算 GLCM 与 LBP 特征对缺陷分类任务的互信息值 MI_{GLCM} 和 MI_{LBP} ,权重系数分别为 $w_{GLCM} = MI_{GLCM} / (MI_{GLCM} + MI_{LBP})$ 和 $w_{LBP} = MI_{LBP} / (MI_{GLCM} + MI_{LBP})$,融合特征向量如式 (9):

$$\mathbf{F}_{\text{fused}} = [w_{GLCM} \cdot \mathbf{F}_{GLCM}; w_{LBP} \cdot \mathbf{F}_{LBP}] \in \mathbb{R}^{D_{GLCM} + D_{LBP}} \quad (9)$$

式中, w_{GLCM} 为 GLCM 特征的权重系数,通过互信息最大化策略计算得出 $w_{GLCM} = MI_{GLCM} / (MI_{GLCM} + MI_{LBP})$; w_{LBP} 为 LBP 特征的权重系数 $w_{LBP} = MI_{LBP} / (MI_{GLCM} + MI_{LBP})$; $\mathbf{F}_{GLCM}$ 为灰度共生矩阵提取的全局纹理特征向量; $\mathbf{F}_{LBP}$ 为局部二值模式提取的局部结构特征向量; $\mathbb{R}^{D_{GLCM} + D_{LBP}}$ 表示融合特征向量的维度空间, D_{GLCM} 为 GLCM 特征维度, D_{LBP} 为 LBP 特征维度; MI_{GLCM} 和 MI_{LBP} 分别为 GLCM、LBP 特征与缺陷分类任务的互信息值,衡量特征对分类的贡献度。通过互信息动态加权融合全局纹理与局部结构特征,实现对有效信息的最大化保留和特征冗余的减少,为后续 PCA 降维提供高分度输入。该融合策略借鉴了 Ren 等提出的特征加权机制,通过任务相关性动态调整特征权重。

随后通过 PCA 降低维度:计算协方差矩阵如式 (10):

$$\mathbf{C} = \frac{1}{N} \sum_{i=1}^N (\mathbf{F}_i - \mu)(\mathbf{F}_i - \mu)^T \quad (10)$$

式中, μ 为均值向量, N 为样本数。对协方差矩阵进行特征值分解,选取前 k 个最大特征值对应的特征向量构成变换矩阵 $\mathbf{W}$,最终得到降维特征如式 (11):

$$\mathbf{F}_{PCA} = \mathbf{W}^T \mathbf{F}_{\text{fused}} \quad (11)$$

该过程通过 GLCM 的全局纹理描述与 LBP 的局部结构编码实现信息互补,同时避免高维特征导致的模型过拟合与计算冗余。

本模块通过多特征融合构建了覆盖宏观(如裂纹、锈蚀)与微观(如划痕、形变)的缺陷表征体系,结合 PCA 降维为后续 MODE 算法优化 CNN 提供了低冗余、高分度的输入特征,奠定了模型对工业场景中复杂缺陷的多层次感知基础,提升了智能检修图像分析的准确性与效率。

2 MODE 算法协同优化 CNN

在工业智能检修领域, CNN 模型面临参数优化效

率低、高维空间收敛慢及多目标冲突等挑战。针对这些问题,本研究提出基于多目标差分进化算法(MODE)的 CNN 参数协同优化方案,通过种群进化机制同步优化权重与池化超参数,在 Pareto 前沿框架下平衡模型性能与复杂度。整体流程如图 2 所示。




图 2 MODE-CNN 协同优化流程图

MODE 的核心在于通过模拟生物进化实现多目标优化。首先随机生成包含 N 个个体的初始种群,每个个体以向量 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$ 表示 CNN 参数。变异操作采用 $DE/rand/1$ 策略生成变异向量,如式 (12):

$$\mathbf{v}_i = \mathbf{x}_{r1} + F(\mathbf{x}_{r2} - \mathbf{x}_{r3}) \quad (12)$$

式中, r_1, r_2, r_3 为从种群中随机选取的互异个体索引, $F \in [0, 2]$ 为缩放因子,该式通过线性组合父代个体的参数差异生成候选解,增强种群多样性。该变异策略与 Liu 等提出的差分进化改进算法一致,均通过增强种群多样性提升全局搜索能力。

交叉操作通过二项交叉生成试验向量,如式 (13):

$$u_{ij} = \begin{cases} v_{ij}, & \text{if rand}() \leq CR \text{ 或 } j = j_{\text{rand}} \\ x_{ij}, & \text{otherwise} \end{cases} \quad (13)$$

式中, $CR \in [0, 1]$ 为交叉概率, 控制变异向量与原个体的混合比例; j_{rand} 为随机选择的维度索引, 确保每个试验向量至少包含一个变异维度。该操作通过概率选择机制融合原个体与变异向量的特征, 避免进化停滞。

针对高相似度背景与缺陷特征场景, 引入自适应权重因子 α 动态调整目标权衡: 计算缺陷与背景的结构相似度指数 (SSIM), 当 $SSIM > 0.85$, 即高相似度时, $\alpha = 0.7$, 否则 $\alpha = 0.5$, 目标函数如式 (14):

$$\begin{cases} f_1(x) = \alpha \cdot \text{交叉熵损失} + (1 - \alpha) \cdot F_1 \text{ 分数} \\ f_2(x) = \|x\|_1 \text{ (权重稀疏性)} \end{cases} \quad (14)$$

式中, $f_1(x)$ 是衡量模型分类性能的第一个目标函数, $f_2(x)$ 是衡量模型复杂度的第二个目标函数, α 为自适应权重因子。该公式通过计算缺陷与背景的结构相似度指数动态调整 α 值, 当 $SSIM > 0.85$, 即高相似度场景时, $\alpha = 0.7$ 以侧重分类精度; 其他场景下 $\alpha = 0.5$ 以均衡精度与复杂度, 同时借助 L1 范数约束权重稀疏性, 有效实现了算法在复杂场景下对目标权衡的动态调整, 体现了其适用性和灵活性。该目标函数设计参考了 Ronneberger 等提出的多任务损失机制, 通过动态权重平衡多目标冲突。

在 CNN 参数优化设计中, 权重参数 (全连接层 $W \in \mathbb{R}^{m \times n}$ 、卷积核 $K \in \mathbb{R}^{k \times k \times c}$) 经展平后纳入优化向量; 池化超参数通过离散映射规则适配。为加速收敛, 嵌入梯度下降步骤, 如式 (15):

$$\mathbf{x}_{\text{new}} = \mathbf{x}_{\text{old}} - \alpha \cdot \nabla f_1(\mathbf{x}_{\text{old}}) \quad (15)$$

其中: α 为学习率, $\nabla f_1(\mathbf{x}_{\text{old}})$ 为损失函数梯度。该式通过梯度信息引导参数向局部最优方向更新, 弥补进化算法局部搜索能力的不足。该混合优化策略与 Fan 等提出的强化学习-进化算法融合框架思路相似, 均通过局部与全局搜索结合提升优化效率。

协同优化流程始于预训练阶段, 以初始训练参数作为 MODE 种群起点, 随后进入迭代循环: 首先 MODE 生成新一代参数, 然后载入 CNN 验证集计算目标函数, 最后基于 Pareto 前沿更新种群。最终从 Pareto 前沿选取“拐点解”作为优化结果。针对工业场景挑战, 采用分层优化、k-means 聚类压缩解集、交叉验证抵抗噪声等策略。

本模块通过 MODE 与 CNN 的深度协同, 实现了从权重到超参数的全维度自动调优, 在平衡模型精度与复杂度的同时, 显著提升了对工业噪声和小样本缺陷的鲁棒性, 为后续面向工业场景的鲁棒性设计提供了优化后的模型基础, 有效解决了传统 CNN 人工调参效率低、

泛化能力弱的核心问题, 奠定了智能检修图像分析的算法性能基石。

3 面向工业场景的鲁棒性设计

在工业智能检修领域, 设备缺陷的多尺度特性 (如 1 mm 级微裂纹至 10 cm 级大范围形变) 与复杂检测环境中的热噪声、光照不均等干扰, 导致传统单尺度模型难以兼顾检测精度与环境适应性。针对这一问题, 本研究提出融合多尺度特征网络、物理模型驱动的噪声抑制及场景定制化优化的鲁棒性设计方案, 通过跨尺度特征协同、噪声物理建模与设备特性适配, 实现复杂工业环境下的稳定检测。

为解决工业缺陷多尺度检测难题, 采用特征金字塔网络 (FPN) 与空洞空间金字塔池化 (ASPP) 的融合架构。融合后的整体架构图如图 3 所示。




图 3 FPN 与 ASPP 融合框架图

FPN 通过自上而下的通路实现语义信息与空间细节的结合, 如式 (16) 所示:

$$P_l = \text{Conv}_{1 \times 1} C_l + \text{Upsample}(P_{l+1}) \quad (16)$$

式中, C_l 为第 l 层 CNN 特征图, P_l 为融合后的特征图, 上采样操作采用双线性插值。通过该式, 浅层高分辨率特征与深层强语义特征实现叠加, 覆盖 1 mm~10 cm 的缺陷检测范围。ASPP 并行使用不同扩张率的空洞卷积, 如式 (17):

$$y = \text{Concat}[\text{Conv}_{d=1}(x), \text{Conv}_{d=3}(x), \text{Conv}_{d=6}(x), \text{Conv}_{d=9}(x)] \quad (17)$$

其中: 扩张率 d 对应的有效 ϵ 感受野通过式 (18) 计算:

$$\epsilon = 2r + 1 \quad (18)$$

式中, r 为扩张率。通过 $d=1, 3, 6, 9$ 的组合, 该式实现对不同尺度缺陷空间的覆盖。为避免多尺度特征冲突, 通过多层感知机 (MLP) 计算高低层特征的融合权重, 如式 (19):

$$\alpha = \text{softmax}\{\text{MLP}[(F_{\text{low}}; F_{\text{high}})]\} \quad (19)$$

式中, F_{low} 和 F_{high} 分别为低层和高层特征向量。该式通

过 softmax 函数生成通道级权重, 实现特征的动态加权融合。

针对工业环境中的热噪声与传感器干扰, 采用物理模型驱动的预处理方案。热红外图像降噪通过温度-灰度归一化实现, 如式 (20):

$$I_{\text{norm}} = \frac{I - \mu_{\text{bg}}}{\sigma_{\text{bg}}} \quad (20)$$

式中, I 为原始热红外图像, μ_{bg} 和 σ_{bg} 分别为背景区域的灰度均值与标准差。通过该式消除环境温度波动对图像的影响。热辐射补偿通过式 (21) 实现:

$$I_{\text{comp}} = I \cdot e^{-\beta d} \quad (21)$$

式中, β 为介质吸收系数, d 为检测距离。该式补偿因距离导致的热辐射衰减, 确保不同距离下的图像一致性。

边缘增强采用改进 Canny 算子, 通过式 (22) 计算梯度幅值:

$$G = \sqrt{(I * S_x)^2 + (I * S_y)^2} \quad (22)$$

其中: 方向模板 S_x 定义为:

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -k & 0 & k \\ -1 & 0 & 1 \end{bmatrix}, k = \frac{\sigma_{\text{local}}}{\sigma_{\text{global}}} \quad (23)$$

式中, k 为局部标准差与全局标准差的比值, S_y 为与 S_x 垂直的方向模板。该式通过自适应模板权重增强缺陷边缘, 抑制噪声干扰。

热红外图像降噪通过温度-灰度归一化实现, 其中背景区域灰度均值 μ_{bg} 与标准差 σ_{bg} 通过滑动窗口统计法确定: 采用 5×5 滑动窗口遍历图像非缺陷区域, 计算窗口内像素均值与标准差的中位数作为最终值; 热辐射补偿中的介质吸收系数 “ β ” 根据设备材质手册选取, 如汽轮机叶片 $\beta = 0.02/\text{m}$, 变压器绕组 $\beta = 0.015/\text{m}$, 检测距离 d 通过激光位移传感器实时测量; 边缘增强中局部标准差 σ_{local} 与全局标准差 σ_{global} 通过图像分块统计法获取, k 值由两者比值动态计算。

数据增强时注入物理模型驱动的噪声, 如式 (24):

$$I_{\text{noisy}} = I + N(0, \sigma^2) + P(\lambda) \quad (24)$$

式中, $N(0, \sigma^2)$ 为高斯噪声, $P(\lambda)$ 为泊松噪声, 用于模拟工业相机的光子计数噪声, 提升模型抗噪能力。

针对不同工业设备特性, 设计定制化适配方案。汽轮机叶片检测中, 通过式 (25) 抑制高温氧化层干扰:

$$I_{\text{enhanced}} = I - \alpha \cdot \text{Filter}(I) \quad (25)$$

式中, α 为抑制系数, $\text{GuidedFilter}(I)$ 为引导滤波提取的氧化层低频成分。该式通过减去氧化层低频信息, 突出裂纹等缺陷特征。

裂纹增强因子通过式 (26) 计算:

$$\gamma = 1 + \frac{\text{Var}_{\text{local}}}{\text{Var}_{\text{global}}} \quad (26)$$

式中, $\text{Var}_{\text{local}}$ 和 $\text{Var}_{\text{global}}$ 分别为局部区域和全局区域的方差。该式通过增强局部方差与全局方差的比值, 提升裂纹区域的对比值。变压器绕组检测中, 通过式 (27) 进行三维形变投影校正:

$$\begin{bmatrix} u' \\ v' \end{bmatrix} = \mathbf{H} \begin{bmatrix} u \\ v \end{bmatrix}, \mathbf{H} = \arg \min \sum \|p_i - Hq_i\|^2 \quad (27)$$

式中, (u, v) 为原始图像坐标, (u', v') 为校正后坐标, $\mathbf{H}$ 为单应性矩阵, p_i 和 q_i 分别为参考图像和当前图像的对应点。该式通过最小化对应点误差, 实现三维形变的投影校正。

绕组形变度量通过式 (28) 完成:

$$\Delta = \frac{1}{N} \sum_{i=1}^N \|f_i - f_{\text{ref}}\|^2 \quad (28)$$

式中, f_i 为当前绕组的特征向量, f_{ref} 为参考特征向量, N 为特征点数量。该式通过计算欧氏距离的平均值, 量化绕组的形变程度。

本模块通过多尺度特征融合实现缺陷的全尺寸覆盖, 结合热物理模型与自适应算法抑制工业噪声, 针对汽轮机叶片、变压器绕组等典型设备设计定制化增强策略, 使模型在极端温度梯度、小样本缺陷等复杂场景下的 PSNR 提升 15 dB 以上, 显著增强了智能检修系统对工业环境的适应性, 为后续模型在实际生产中的稳定应用提供了关键支撑, 奠定了整个智能检修图像模型在工业场景中鲁棒性检测的技术基础。

4 试验结果与分析

本研究采用 FLIR A655sc 红外热像仪与 Olympus IPLEX NX 内窥镜构建多模态数据采集系统, 搭配 25 μm 标准裂纹试块与 Keyence LK-G5000 激光位移传感器完成标定。

同时, 数据集覆盖多样化场景: 300 组汽轮机叶片热图像包含冷态启动 25~80 $^{\circ}\text{C}$ 、稳态运行 300~500 $^{\circ}\text{C}$ 、停机降温 500~30 $^{\circ}\text{C}$ 三种状态, 涵盖高温氧化 >400 $^{\circ}\text{C}$ 、潮湿结露湿度 >85% 等环境; 200 组变压器绕组可见光图像包含正常运行室温、过载 40~60 $^{\circ}\text{C}$ 、淋雨湿度 >90% 工况, 形变幅度 0.5~10 mm; 通过 Gaussian-Poisson 模型生成 100 组含噪声干扰样本, 噪声强度 $\sigma = 0.05 - 0.2$ 。

通过对比仅 GLCM、仅 LBP 及 GLCM + LBP + PCA 三种特征方案, 验证多尺度表征优势。实验结果可知融合方案将裂纹分类准确率提升至 91.7%, 形变检测误差降至 0.8 mm, 特征维度经 PCA 降维后从 107 维压缩至 28 维, Fisher Score 特征区分度指标从 9.3 提升至 15.6。

基于 NVIDIA A100 GPU 与 Ray 分布式框架, 设置

种群大小 10，分别迭代 50、100、150、200 代，采用 $F=0.6$ 变异因子与 $CR=0.9$ 交叉概率，在卷积核尺寸、池化窗口等参数空间中搜索最优解。实验结果如图 4 所示。




图 4 实测数据与 MODE 仿真结果对比

从图 4 对比实验可知，MODE 算法将分类准确率提升至 93.5%，模型大小压缩至 32.6 MB，仅用 22 代即收敛（遗传算法需 35 代），Pareto 前沿在第 20 代已呈现稳定平衡解。对比数据如表 1 所示。

表 1 不同算法准确率对比

优化方法	分类准确率	模型大小/MB	迭代收敛代数
网格搜索	88.2%	45.7	—
遗传算法	90.1%	38.2	35
MODE(本文)	93.5%	32.6	22

在高斯噪声 ($\sigma=0.1$)、15 px 运动模糊、50 lux 低光照等干扰下，分别对传统 CNN 模型和本文方法进行测试对比可知，本文方法较传统 CNN 实现显著提升：噪声环境 mAP 达 89.2%，运动模糊场景 mAP 提升至 83.7%，低光照条件下 mAP 达 87.5%。热图像处理中，温度梯度干扰导致的 $PSNR$ 从 28.5 dB 提升至 35.2 dB。

为进一步验证所提模型的先进性，补充与当前主流基于 Transformer 的工业图像检测模型的对比。选取 ViT (Vision Transformer) 和 DETR (Detection Transformer) 两种典型模型进行实验，结果显示：ViT 模型分类准确率为 90.8%，但模型大小达 89.3 MB，在噪声干扰场景下 mAP 较本文方法低 4.3 个百分点；DETR 模型分类准确率为 92.1%，模型大小 102.5 MB，虽精度接近本文方法，但计算复杂度更高，端到端检测

延迟达 286 ms，远超本文模型的 153.3 ms。这表明本文模型在平衡检测精度、模型轻量化与实时性方面更具优势，尤其适用于工业边缘计算场景。

表 2 与主流模型准确率对比

优化方法	分类准确率/%	模型大小 /MB	迭代收敛代数
ViT(Transformer)	90.8	89.3	31
DETR(Transformer)	92.1	102.5	26

为量化各鲁棒性策略对模型性能的单独贡献，采用控制变量法开展对比实验：在相同测试集上分别禁用单一策略并评估性能变化，得到实验结果如表 3 所示。

表 3 鲁棒性策略贡献评估数据

样本 ID	基础模型准确率 /%	多尺度特征网络准确率 /%	噪声抑制策略 mAP /%	定制化方案检出率 /%	综合策略 $PSNR$ /dB
1	78.2	83.5	79.6	82.1	30.2
5	79.4	84.7	80.5	83.6	31.1
10	80.5	85.7	81.5	84.7	31.8
15	81.0	86.2	82.0	85.1	31.9
20	75.9	81.2	77.0	79.9	29.5
25	76.7	82.0	77.6	80.7	29.6
30	79.8	85.0	80.7	83.8	31.3
35	79.7	84.9	80.6	83.7	31.1
40	75.5	80.9	76.3	79.2	29.3
45	80.2	85.5	81.1	84.2	31.4
50	79.1	84.3	80.1	83.2	31.0

实验结果显示，多尺度特征网络单独作用时，模型准确率提升 5.2%、召回率提升 4.8%；物理模型驱动的噪声抑制策略单独使用时， mAP 提升 6.7%、峰值信噪比 $PSNR$ 提升 4.3 dB；定制化适配方案单独应用时，特定设备缺陷检出率提升 8.3%、误报率降低 2.1 次/24 h，进一步绘制完整数据如图 5 进行深入分析。




图 5 鲁棒性策略贡献评估

从图 5 中可知，基础模型准确率因未引入鲁棒性策略，在样本 ID 变化中波动明显，受噪声、尺度差异影

响, 准确率在 75%~82% 区间震荡; 多尺度特征网络准确率整体呈稳定上升趋势, 均值较基础模型提升约 5.2%, 尤其在样本 ID20-40 段, 有效缓解了因尺度差异导致的精度波动; 噪声抑制策略 *mAP* 曲线平滑度显著优于基础模型, 均值提升 6.7%, 表明其对工业场景噪声干扰的抑制作用; 定制化方案检出率虽绝对数值低于准确率指标, 但在样本 ID10-30 等复杂缺陷场景, 较基础模型检出率提升 8.3% 以上; 综合策略 *PSNR* 始终维持在 29~32 dB 区间, 且与各单项策略曲线趋势正相关, 验证了多策略协同对模型鲁棒性与图像质量的叠加优化效果, 直观展现了各鲁棒性策略在工业图像检测中对精度、抗干扰能力的提升价值。

在线检测系统部署于 Jetson Orin 边缘计算平台, 全流程延迟 153.3 ms, 满足工业实时性要求。为验证本研究的工业实操性, 选取某火工厂进行试点实验, 设置 720 小时连续运行, 测试结果如表 4 所示。

表 4 试点实验结果

处理阶段	耗时/ms
图像采集	33.2
特征提取	45.7
MODE 优化推理	62.3
结果输出	12.1
总延迟	153.3

从表 4 可知, 火电厂 720 小时连续运行裂纹检出率 98.7%, 24 小时误报率 0.8 次, 平均响应延迟<200 ms。综合性能方面, 最小可检测裂纹宽度 0.08 mm, 形变测量重复精度±0.05 mm, 已在 3 个电厂部署并减少年停机时间 1 200 小时。

本实验通过多维度验证证实: 多特征融合模块将微小缺陷检出率提升 42.7%, MODE 优化算法较传统搜索策略收敛速度提升 1.6 倍, 鲁棒性设计使复杂场景下 *mAP* 平均提升 20.7%。端到端系统实现了 98.7% 的裂纹检出率与 153.3 ms 的处理延迟, 在最小检测精度、形变测量重复性等指标上显著优于传统方案。该成果已在工业现场验证其工程价值, 为智能检修领域提供了兼具算法先进性与场景适配性的技术范式。

5 结束语

本文聚焦工业智能检修图像技术, 在先进性与实用性维度展开深入探索, 为工业设备智能检测与维护提供了创新方案。在技术先进性上, 构建多维度创新体系。通过面向工业场景的鲁棒性设计, 以多尺度特征网络、物理模型驱动的噪声抑制等策略, 突破传统模型局限。多尺度特征网络可灵活适配工业场景中设备缺陷的复杂尺度, 精准捕捉细微特征; 物理模型驱动的噪声抑制, 基于工业环境物理特性, 有效净化图像干扰, 为精准检

测筑牢基础。同时, 对各策略进行量化评估, 明晰其对模型性能的提升贡献, 这种精准把控策略价值的方式, 展现技术研发的深度与严谨, 使模型在复杂工业场景下的检测能力显著增强, 契合工业智能化对高精度检测的需求。实用性层面, 紧密贴合工业现场需求。针对不同工业设备, 定制化适配方案充分考量设备差异, 让模型能在多样设备检测中高效运行, 覆盖汽轮机叶片、变压器绕组等典型设备, 拓展应用广度。在智能检修流程中, 从图像采集到缺陷识别、预警, 形成完整闭环, 与工业现场运维流程深度融合。物理参数设定结合实际, 通过实验标定与理论计算, 保障方法可重复性, 便于工业场景快速落地应用, 降低技术迁移成本, 助力企业提升设备检修效率、减少故障损失, 真正将技术创新转化为工业生产提质增效的动力, 为工业智能化升级提供切实可行的技术路径, 推动工业检测向更智能、更高效、更可靠方向发展, 有望在工业领域广泛推广, 释放技术赋能产业的巨大潜力^[7-15]。

参考文献:

[1] ZHANG L, JIN Z, WANG Y, et al. Novel spatio-temporal joint learning-based intelligent hollowing detection in dams for low-data infrared images [J]. *Sensors*, 2025, 25 (10): 3199–3199.

[2] SHAO H, XIA M, HAN G, et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1–12.

[3] 许家铭, 李新宇, 张 径, 等. 基于 ROV 的水下检修缺陷数据智能处理与管理系统应用研究 [J]. *湖南水利水电*, 2025 (2): 94–96.

[4] OJALA T, PIETIÄÄINEN M, HARWOOD D. A comparative study of texture measures with classification based on feature distributions [J]. *Pattern Recognition*, 1996, 29 (1): 51–59.

[5] 徐恒山, 王思维, 张旭军, 等. 基于 MODE 算法的光伏逆变器机电暂态模型 LVRT 控制方式与控制参数辨识研究 [J/OL]. *太阳能学报*, 1–9 [2025-06-16]. <https://doi.org/10.19912/j.0254-0096.tynxb.2024-1242>.

[6] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 6517–6525.

[7] A A Z, XINYI X, YUE D, et al. Intelligent detection of sealed crack with 2D asphalt pavement images [J]. *Journal of Transportation Engineering, Part B: Pavements*, 2025, 151 (1):

(下转第 189 页)