

铸件 X 射线探伤图像质量评估与自适应增强

侯明君, 董昊, 李硕宏, 计效园, 段浩哲, 周文豪, 殷亚军, 周建新

(华中科技大学材料成形与模具技术全国重点实验室, 武汉 430074)

*通讯作者: 计效园, 男, 教授, 博士。E-mail: jixiaoyuan@hust.edu.cn

摘 要: 高端装备复杂铸件存在大壁厚差、异形曲面等结构, 极易形成孔松、夹杂等内部缺陷, 现有检测方式为 X 射线探伤成像与人工/机器评片。为保证成像精度, 探伤底片一般为高动态范围图像, 直接评片时缺陷不凸显易漏检误检、图像增强时缺少质量量化评估标准, 严重限制了人工评片效率和机器评片准度。为此, 本文开展铸件 X 射线探伤图像自适应增强算法与质量评估研究, 提出多特征融合驱动的 X 射线图像无参考质量评估模型、混合拓扑协同的粒子群-遗传算法驱动的图像增强算法。结果表明: 质量评估一致性达 97%; 图像增强的寻优算法相较于 PSO、ACO、GA 等, 平均提升了约 5.94%、17.82%、14.55%。相关研究可为人工评片和机器评片提供理论与技术支撑。

关键词: 铸件; 探伤图像; 自适应增强; 质量评估; 缺陷

Quality Assessment and Adaptive Enhancement of X-ray Radiographic Images for Castings

HOU Ming-jun, DONG Hao, LI Shuo-hong, JI Xiao-yuan, DUAN Hao-zhe, ZHOU Wen-hao, YIN Ya-jun, ZHOU Jian-xin

(State Key Laboratory of Materials Processing and Die & Mould Technology, Huazhong University of Science and Technology, Wuhan 430074, Hubei, China)

Abstract: Complex castings used in high-end equipment often have structures with large wall thickness differences and irregular curved surfaces, making them prone to internal defects such as porosity and inclusions. The current inspection method involves X-ray radiographic imaging combined with manual or automated evaluation. To ensure imaging accuracy, radiographic films are typically high dynamic range images. However, during direct evaluation, defects may not be clearly visible, leading to potential missed or incorrect detections. Additionally, image enhancement processes lack a quantitative quality assessment standard, which severely limits both the efficiency of manual evaluation and the accuracy of automated evaluation. To address these challenges, this paper investigates adaptive enhancement algorithms and quality assessment methods for X-ray radiographic images of castings. Specifically, we propose a multi-feature fusion-driven no-reference quality assessment model for X-ray images, as well as a hybrid topological cooperative particle swarm optimization-genetic algorithm (PSO-GA) driven image enhancement algorithm. Experimental results demonstrate that the quality assessment achieves a consistency rate of 97%. In terms of image enhancement, the proposed optimization algorithm improves performance by approximately 5.94%, 17.82%, and 14.55% on average compared to traditional methods such as Particle Swarm Optimization (PSO), Ant Colony Optimization (ACO), and Genetic Algorithm (GA), respectively. This research provides theoretical and technical support for both manual and automated radiographic evaluation of casting defects.

Keywords: Castings; Radiographic images; Adaptive enhancement; Quality assessment; Defects

1 前言

高端装备复杂铸件存在大壁厚差、异形曲面等结构,极易形成孔松、夹杂等内部缺陷。现有的检测方式主要采用 X 射线探伤二维成像+人工评片。近年来,随着图像处理^[1]、机器学习^[2]、深度学习^[3]等技术的快速发展,以及数字图像采集设备、图形处理器等硬件性能的不不断提升^[4],深度学习驱动^[5-10]的目标检测识别研究已经迅速成为交通^[11]、芯片^[12]、医学^[13]等各领域取得广泛应用。现有评片方式逐步转换为机器评片^[14],通过缺陷自动识别评价模型实现轻合金铸件缺陷^[15]探伤自动识别评价^[16]。

然而,高精度 X 射线探伤装备的探伤底片一般为高动态范围图像,直接评片时缺陷不凸显易漏检误检、图像增强时缺少质量量化评估标准,严重限制了人工评片效率和机器评片准度。国内外学者针对图像质量评估与图像增强也开展了相关研究。如质量评估方面,根据对参考信息的依赖程度,对图像质量评估开展了全参考质量评估^[17]、半参考质量评估^[18]和无参考质量评估^[19]。图像增强方面,有从图像本身的直方图分布出发来进行调窗处理^[20];有开展空间域增强算法^[21]研究,直接对图像像素的灰度值进行操作,通过建立输入像素和输出像素的映射关系或邻域运算实现图像增强;也有开展频域增强算法^[22]研究,通过傅里叶变换方法图像由空间域转换至频率域,然后通过滤波器修改频谱分量来实现特征增强。但是,现有质量评估研究难以全面反映图像质量、图像增强研究难以适应实际成像环境的多样性。因此,如何构建多特征融合驱动的无参考质量评估模型,并设计兼顾增强效果与计算效率的优化算法,成为当前研究的难点与重点。

本研究围绕铸件 X 射线探伤图像的增强与质量评估问题展开,构建多特征融合的无参考质量评估模型,并提出一种混合拓扑协同的粒子群-遗传算法驱动的图像增强方法。通过引入动态参数调整机制与多尺度特征提取策略,增强算法可适应不同成像条件下的缺陷特征提取需求;质量评估模型则结合局部纹理、边缘信息及全局对比度等多维度指标,实现对增强图像质量的量化评价。

2 X 射线图像无参考质量评估

2.1 X 射线图像视觉感知颜色迁移

颜色迁移目的是将铸件 X 射线图像的纹理特征等迁移至自然灰度图像,通过对迁移后的自然图像

进行质量评估,来反应原始 X 射线探伤图像的相关特性。为选择最佳自然灰度图像进行迁移,提出了一种灰度共生矩阵(Gray-level co-occurrence matrix, GLCM)驱动的自然图像选择策略。

由于 X 射线图像的灰度范围为 0~255,为减少计算复杂度,将灰度值归一化为 0-8,构建 $L \times L$ 矩阵。遍历图像中每一个像素,计算其与在 0° 、 $\pi/4$ 、 $\pi/2$ 、 $3\pi/4$ 方向上距离为 1 和 2 的像素的灰度组合。对每个灰度对 (i, j) ,并记录其在图像中出现的次数,填入对应矩阵的对应位置 $M(i, j)$ 。如图 1 所示为某图像在距离为 1、方向为 0° 的对应 GLCM。最后按照式(1)对得到的 GLCM 进行归一化。然后,提取对比度(式(2))、能量(式(3))、熵(式(4))、相关性(式(5))等关键纹理特征参数。采用欧几里得距离进行特征相似性度量,如式(6)所示, Sim 越小,表明两张图像的纹理特征越相似。




图 1 在距离为 1、方向为 0° 的对应共生矩阵

Fig. 1. Gray-level co-occurrence matrix (GLCM) at distance 1 and orientation 0°

$$P(i, j) = \frac{M(i, j)}{\sum_{i, j} M(i, j)} \quad (1)$$

式中, i 和 j 表示灰度级, $M(i, j)$ 表示灰度级 i 和 j 在特定方向、距离下共同出现的频次, $P(i, j)$ 表示灰度对 (i, j) 出现的概率。

$$con = \sum_{i, j} P(i, j) * (i - j)^2 \quad (2)$$

$$Asm = \sum_{i, j} P(i, j)^2 \quad (3)$$

$$Ent = - \sum_i \sum_j P(i, j) \log P(i, j) \quad (4)$$

$$corr = \frac{\sum_{i, j} (i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j} \quad (5)$$

式中, σ_i 、 σ_j 表示灰度级 i 和 j 的标准差。

$$Sim = \sqrt{(SD_A - SD_B)^2} \quad (6)$$

式中, SD_A 和 SD_B 分别为 X 射线图像和自然图像通过上述方法计算得到的纹理特征向量。

选取自然图像后,进行灰度颜色迁移,流程如图 2 所示。按照式(7)、式(8)计算铸件 X 射线图像、

自然灰度图像均值与标准差。其中，均值和标准差分别代表了图像整体细节特写和对比度。按照式(9)改变自然图像的每个像素灰度值，完成 X 射线图像对自然灰度图像的颜色迁移，生成待评估图像。




图 2 颜色迁移驱动的评估图像构建

Fig. 2. Assessment image construction driven by color transfer

$$\mu = \frac{1}{M * N} \sum_{i=1}^M \sum_{j=1}^N I(i, j) \quad (7)$$

$$\sigma = 2 * \sqrt{\frac{1}{M * N} \sum_{i=1}^M \sum_{j=1}^N (I(i, j) - \mu)^2} \quad (8)$$

式中， M 和 N 表示图像的长与宽， i 和 j 表示某像素点在图像上的位置， μ 和 σ 分别表示为图像的均值与方差。

$$I = \frac{\sigma^T}{\sigma^S} \cdot (S - \text{mean}(S)) + \text{mean}(T) \quad (9)$$

式中， S 表示灰度自然图像， T 表示 X 射线图像， I 表示输出图像， σ^T 表示 X 射线图像的标准差， σ^S 表示自然图像的标准差， $\text{mean}(S)$ 表示自然图像的均值， $\text{mean}(T)$ 表示 X 射线图像的均值。

2.2 多特征提取与质量评估

本文设计专用于 X 射线图像的人眼感知视觉特征 (Retinex-based Visual Perception, R-Visual)，并融合局部结构、全局视觉、灰度、纹理等特征综合量化表征图像质量。

人眼感知视觉特征是将颜色迁移后自然图像和原始自然图像分解为反射成分与光照成分。按照式(10)计算迁移前后图像在反射成分和光照成分的整体匹配度，确保迁移后不会出现伪影、不过度改变原始图像信息，且两张图像信息合理。按照式(11)衡量迁移前后图像的反射成分差异，确保迁移后图像能保持原始结构信息。按照式(12)计算迁移前后图像光照梯度合理性，在反射成分变化较大时光照信息影响减少，保证图像能有较好的人眼感知效果。最后，计算人眼感知视觉特征值，如式(13)所示。

$$L_{re} = \lambda_4 \sum_{i=1}^N \|R_n \circ I_l - S_l\|_1 + \quad (10)$$

$$\lambda_5 \sum_{i=1}^N \|R_l \circ I_n - S_n\|_1 + \sum_{i=1}^N \|R_l \circ I_l - S_l\|_1 + \sum_{i=1}^N \|R_n \circ I_n - S_n\|_1$$

式中， L_{re} 为整体匹配度， R_n 、 I_n 、 S_n 表示颜色迁移后图像的反射成分、光照成分和像素值， R_l 、 I_l 、 S_l 表示原始自然灰度图像的反射成分、光照成分和像素值， N 表示整个图像的像素总值， λ_4 、 λ_5 为权重参数。

$$L_r = \|R_l - R_n\|_1 \quad (11)$$

$$L_i = \sum_{i=1}^N \|\nabla I_n \circ \exp(-\lambda_6 \nabla R_n)\|_1 \quad (12)$$

式中， L_i 用于衡量其中， ∇I_n 表示迁移后图像中光照成分 I_n 的梯度，即光照信息的变化速率，用于检测光照变化的平滑性， $\exp(-\lambda_6 \nabla R_n)$ 是加权因子，由反射成分梯度控制，确保光照成分的变化不会被过度抑制，仍受到反射成分的调节。 λ_6 为权重参数，设置为 1。

$$L = \lambda_1 L_{re} + \lambda_2 L_r + \lambda_3 L_i \quad (13)$$

式中， L_{re} 表示综合匹配度， L_r 表示反射成分评估， L_i 表示光照成分评估， λ_1 、 λ_2 、 λ_3 为权重参数。

在实际探伤检测场景中，图像质量的退化呈现多维特性。人眼视觉系统对缺陷的感知具有显著的区域选择性，注意力通常集中于局部对比度突变、纹理异常或结构连续性中断等关键区域，为此，引入局部特征相似性的图像质量评估方法 (Feature Similarity Index Method, FSIM) 和自然场景统计的图像质量评估方法 (Natural Image Quality Evaluator, NIQE)，模拟人类视觉系统对图像自然度的潜意识判断过程。

在 X 射线探伤图像的典型缺陷检测与识别中，灰度特征可以直接反映缺陷与背景区域的密度差异，如亮斑、暗区等；纹理特征能够刻画缺陷的形态细节，如形貌、边缘粗糙度、方向性等，都属于关键物理特性特征，在缺陷的检测与识别中起到关键作用。为此，引入信息熵 (Information Entropy, IE)、局部对比度 (Local contrast, LC) 和边缘清晰度 (Edge clarity, EC)，共同表征图像的灰度和纹理特征。

为了将上述指标综合起来进行 X 射线图像质量评估，本文提出一种基于稳健统计的多特征融合质量评估方法。统计铸件 X 射线探伤图像数据集中所

有图像的六个特征值，按照式(14)计算每个特征值的四分位数。并设定阈值 k 来计算数据的合理下限和上限，确保不受极端值影响的稳健统计量，如式(15)和(16)所示。处于合理上下限的数据，进行标准化处理，将各特征值映射至 $[0,1]$ 区间。超出界限的值分别按照 0 和 1 处理。为每个特征值分配一个权重，并构建一个决策矩阵，实现多特征融合质量评估，如式(17)所示。将最后得到的百分制特征值作为图像的质量分数。

$$IQR = Q3 - Q1 \quad (14)$$

式中， IQR 代表数据中间 50%范围， $Q1$ 为第 25%分位数， $Q3$ 为第 75%分位数。

$$Lower = Q1 - k * IQR \quad (15)$$

$$Upperer = Q3 + k * IQR \quad (16)$$

$$NS = 100 * (K_{R-V} * NS_{R-V} + K_{FSIM} * NS_{FSIM} + K_{NIQE} * NS_{NIQE} + K_{IE} * NS_{IE} + K_{LC} * NS_{LC} + K_{Ec} * NS_{Ec}) \quad (17)$$

式中， NS_{R-V} 、 NS_{FSIM} 、 NS_{NIQE} 、 NS_{IE} 、 NS_{LC} 、 NS_{Ec} 分别为在 R-Visual、FSIM、NIQE、IE、LC、EC 特征下得到的归一化分数， K_{R-V} 、 K_{FSIM} 、 K_{NIQE} 、 K_{IE} 、 K_{LC} 、 K_{Ec} 为六个特征值的权重系数。

3. 高动态范围图像自适应增强

3.1 图像增强算法与寻优参数设计

高动态范围铸件 X 射线探伤图像增强算法包括窗宽窗位调整、伽马校正（Gamma Correction, GC）、自适应直方图均衡处理（Contrast Limited Adaptive Histogram Equalization, CLAHE）、边缘增

强等。

窗宽窗位调整中，设计三种策略进行调节。一是以窗宽、窗位分别为寻优参数，按照(18)、(19)、(20)将高动态范围图像转化为 8 位灰度图像；二是设定一个合理的灰度步长，将整张图像按照灰度值划分成不同的灰度区间，对每个灰度区间进行窗宽窗位调整，寻优参数为步长和每个区间内窗宽、窗位；三是将整张图像分割成相同大小子图，逐一进行窗宽窗位调整，为适应后期缺陷检测相关工作，将子图尺寸设置为 416×416，寻优参数为每个子图的窗宽、窗位。

$$\min(C) = C - \frac{W}{2} \quad (18)$$

$$\max(C) = C + \frac{W}{2} \quad (19)$$

$$I_t(x,y) = \text{clip}\left(\frac{I(x,y) - \min(C)}{\max(C) - \min(C)} \times 255\right) \quad (20)$$

式中， C 表示图像的窗位； W 表示图像的窗宽； $\max(C)$ 、 $\min(C)$ 分别表示图像窗口的上下界； clip 表示将图像像素值超出 $[0,255]$ 范围的部分截断，调窗窗口内对比度，抑制窗口外噪声； $I(x,y)$ 表示图像在 (x,y) 位置上的灰度值。

伽马校正、自适应直方图均衡处理、边缘增强等算法针对性地去噪、提升局部对比度，并突出微小缺陷或细节。伽马校正以校正参数 γ 作为寻优参数，自适应直方图均衡处理以网格大小和剪切限制作为寻优参数，边缘增强以高斯核大小、高斯标准差、锐化增强系数作为寻优参数。高动态范围铸件 X 射线探伤图像增强算法与寻优参数如图 3 所示。




图 3 图像增强策略及具体寻优参数

Fig. 3. Image enhancement strategy and specific optimization parameters

3.2 粒子群改进策略

在 PSO 算法中, 粒子通过相互之间的信息交流来更新自己的位置和速度, 而粒子群的拓扑结构决定了粒子间的信息传播方式, 从而影响粒子间的信息交换效率。因此, 拓扑结构在提高粒子群性能方面有重要作用。

典型的粒子拓扑结构包括星形拓扑、环形拓扑、冯诺依曼拓扑等。星形拓扑结构是经典 PSO 算法中常用的一种, 其所有粒子相互连接, 相互传递位置信息和速度信息, 所有粒子都会向全局最优方向飞行, 因此信息传播速率非常快, 可以迅速找到全局最优解, 但也容易过早收敛, 失去多样性。在环形拓扑中, 粒子按照编号与最相邻的 k 个粒子直接相连。当 $k=2$ 时, 粒子只与首尾相连的两个粒子进行信息交换, 全局最优信息传递速度较慢, 各个粒子有机会探索其他区域, 保留了群中粒子的多样性, 但也限制了全局搜索能力。在冯诺依曼拓扑中, 粒子呈现网格状, 每个粒子与周围四个粒子相互连接, 因此相较于之前的星形拓扑和环形拓扑, 全局最优信息传递速度相对较慢, 但多样性相对较高。

因此, 本算法采用混合拓扑结构, 设计星形、环形、冯诺依曼三种粒子群并行协作优化并使用混合更新策略, 每个种群内部先独立优化, 维持自己种群的全局最优位置 $gbest$, 保持不同拓扑结构带来的多样性。然后每隔一定代数, 定期比较三个种群的 $gbest$, 选出全局最优的粒子位置 $Gbest$ 。在保留各拓扑的独立搜索特性的同时, 将所有子种群的 $gbest$ 逐步收敛到 $Gbest$, 从而帮助粒子群快速朝着全局最优解的方向收敛, 避免单一群体的过早收敛。

4. 结果与讨论

4.1 评估效果验证

本文选取航天领域高动态铸件 X 射线探伤图像, 样本容量为 3500 张。如图 4 所示为 R-Visual、FSIM、NIQE、IE、LC 和 EC 六个特征值的箱型图数据分析, 经过异常值剔除后的特征值统计数据与合理范围如表 1 所示。









图 4 特征异常值分析

Fig. 4. Analysis of feature outliers

表 1 六个图像特征信息与合理范围

Tab.1 Six image features and their corresponding reasonable

特征	中位数	均值	下限	上限
R-Visual	257.1985	260.6523	166.6447	347.7134
FSIM	0.9990	0.9988	0.9959	1.0000
NIQE	8.4613	8.6706	1.9961	16.2454
IE	6.5842	6.6313	4.7527	7.9405
LC	2.8154	5.4169	0.9195	14.0790
EC	44.3803	48.7449	2.876	111.0053




图 5 六种单特征和多特征评估结果

Fig. 5. Evaluation results of six single-feature and multi-feature approaches

随机选取 200 张探伤图像，每张原始图像使用 3.1 节中三种窗宽窗位调整方式生成五张增强后图像。其中全局调整策略生成两张增强图像，一张为选取标准差和均值为窗宽窗位，一张根据灰度极值确定窗宽窗位；灰度分区策略生成一张增强图像，每个灰度分区以标准差和均值为窗宽窗位；子图分区策略生成两张增强图像，与全局调整策略相同。处理后获得 1000 张不同调窗效果的 X 射线图像。为验证质量评估模型的可靠性，选取了 10 名有经验的缺陷检测工程师分别对这 1000 张图像进行质量评估，选取调窗效果最好、缺陷最明显的 200 张图像，将其调窗算法作为真实类别。与上述多特征融合无参考质量评估算法计算得到的最优图像进行比对，验证效果如图 5 所示。

可以看出，尽管 R-Visual、FSIM、NIQE、IE、LC 和 EC 等特征已经各个角度对 X 射线图像进行量化表征，但质量评估得到的结果仍与专业检测人员的判断结果有较大差距，效果表现最好的 R-Visual 特征评估准确率仅达 76%，而多特征融合驱动的 X 射线质量评估算法在本验证集上与人工综合评判一致性达 97%，说明从 X 射线图像缺陷显著性的角度出发，本算法显著优于六个特征单独进行质量评估。

4.2 参数寻优后图像增强效果验证

使用多特征融合驱动的 X 射线图像无参考质量评估算法提取图像质量分数，并以上述多特征融合质量分数最大为优化目标，采用 PSO、遗传 (Genetic Algorithm, GA)、蚁群 (Ant Colony Optimization, ACO)、HTCPSO-GA 算法对图像增强算法中的多个参数进行寻优。




图 6 部分测试图像增强结果

Fig. 7. Enhanced results of selected test DICOM images




图 7 灰度分区策略在不同算法下评估分数

Fig. 6. Evaluation scores of gray-scale partitioning strategies under different algorithms

表 2 不同算法评估结果

Table 2. Evaluation outcomes for different algorithm approaches

编号	指标	HTCPSO-GA	PSO	ACO	GA
1	初始值	85.724	82.963	71.397	76.020
	迭代值	92.992	88.697	78.848	80.234
	代数	35	45	9	20
2	初始值	85.332	76.464	76.567	73.675
	迭代值	91.617	85.815	78.427	78.226
	代数	35	50	4	25
3	初始值	85.683	88.295	78.422	72.260
	迭代值	95.010	90.662	80.712	81.326
	代数	35	50	30	40

	初始值	85.216	77.427	77.232	71.870
4	迭代值	92.561	86.214	77.919	80.604
	代数	50	35	9	25

如图 6 所示, (c)、(f)、(i)、(l)分别为本文算法增强后的片状疏松、线状疏松、一般疏松和高密夹杂缺陷, 四类缺陷区域与背景区域之间均呈现显著差异, 边界轮廓清晰可见, 这种强特征差异使得缺陷的自动检测与分类具有较高可行性。如图 7、表 2 所示为在不同群智能优化算法下, 使用包含灰度分区调窗增强模型进行增强参数寻优的迭代过程与详细结果实例。根据寻优步长的不同, 寻优参数为 10~206 个。因此各个算法在相同图像上寻优得到的步长不同, 收敛速度难以进行比较。结果表明, 对于高动态范围图像使用灰度分区寻优时, HTCPSO-GA 算法效果优于 PSO、ACO、GA 三个算法。HTCPSO-GA 算法在测试图像上的迭代最优值都优于其他算法, 相较于 PSO、ACO、GA 算法, 平均提升了约 5.94%、17.82%、14.55%。

5 结论

本文提出的多特征融合驱动的 X 射线质量评估算法与人工综合评判一致性达 97%; HTCPSO-GA 算法在测试图像上的迭代最优值都优于其他算法, 相较于 PSO、ACO、GA 算法, 平均提升了约 5.94%、17.82%、14.55%。相关研究可为高动态范围铸件 X 射线探伤图像缺陷自动检测与人工评片研究提供理论与技术支撑, 提高缺陷自动识别的准确度、人工评片的效率。

参考文献:

- [1] Fu W L, Jiang X H, Li B L, et al. Rolling bearing fault diagnosis based on 2D time-frequency images and data augmentation technique[J]. Measurement Science and Technology, 2023, 34(4): 045005.
- [2] Wei H Y, Wu C T, Hu W, et al. LS-DYNA Machine Learning-Based Multiscale Method for Nonlinear Modeling of Short Fiber-Reinforced Composites[J]. Journal of Engineering Mechanics, 2023, 149(3): 04023003.
- [3] Lian G H, Sun Q H, Liu X M, et al. Automatic recognition and intelligent analysis of central shrinkage defects of continuous casting billets based on deep learning[J]. Journal of Iron and Steel Research International, 2023, 30: 937-948.
- [4] Goodfellow I, Bengio Y, Courville A. Deep Learning[M]. The MIT Press, 2016.
- [5] Wang L, Dong X, Guo S. Sand-bed defect recognition for 3D sand printing based on deep residual network[J]. China Foundry, 2021, 18(04): 344-350.
- [6] Han Y, Li X J, Song K C, et al. Adaptive depth and receptive field selection network for defect semantic segmentation on castings X-rays[J]. NDT & E International, 2020, 116(6): 102345.
- [7] Yang K, Sun Z Y, Wang A H, et al. Deep hashing network for material defect image classification[J]. IET Computer Vision, 2018, 12(8): 1112-1120.
- [8] Jing R, Rui R, Mark G, et al. Defect detection from X-Ray images using a three-stage deep learning algorithm[C]. 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE). IEEE, 2019: 1-4.
- [9] Hu C F, Wang Y X, Chen K, et al. A CNN model based on spatial attention modules for casting type classification on pseudo-color digital radiography images[C]. 2019 Chinese Automation Congress (CAC2019). 2019: 4585-4589.
- [10] Hu C F, Wang Y X. An efficient convolutional neural network model based on object-level attention mechanism for casting defect detection on radiography images[J]. IEEE Transactions on Industrial Electronics, 2020, 67(12): 10922-10930.
- [11] Kuutti S, Bowden R, Jin Y C, et al. A Survey of Deep Learning Applications to Autonomous Vehicle Control[J]. IEEE transactions on intelligent transportation systems, 2021, 22(2): 712-733.
- [12] Irhoseini A, Goldie A, Yazgan M, et al. A graph placement methodology for fast chip design. Nature, 2021, 594(7862): 207 - 212.
- [13] Richard J C, Ming Y L, Wang J W, et al. Pathomic fusion: An integrated framework for fusing histopathology and genomic features for cancer diagnosis and prognosis. IEEE Trans. Med. Imag. 2020, 41(4): 757 - 770.
- [14] Ji X Y, Yan Q Y, Huang D, et al. Filtered Selective Search and Evenly Distributed Convolutional Neural Networks for Casting Defects Recognition[J]. Journal of Materials Processing Technology, 2021, 292(2): 117064.
- [15] Wu B, Zhou J X, Ji X Y, Yin Y J, et al. An ameliorated



- teaching-learning-based optimization algorithm based study of image segmentation for multilevel thresholding using Kapur's entropy and Otsu's between class variance[J]. Information Sciences, 2020, 533(9): 72-107.
- [16] Wu B, Zhou J X, Yang H Q, et al. An ameliorated deep dense convolutional neural network for accurate recognition of casting defects[J]. Knowledge-Based Systems, 2021, 226(8): 107096.
- [17] 李国庆, 赵洋, 刘青萌, 殷翔宇, 王业南. 多层感知分解的全参考图像质量评估. 中国图象图形学报, 2019, 24(1): 149-158.
- [18] B. Zhang, L. Wang, C. Zhang, R. Zhao, J. Sun. No-reference image quality assessment based on improved vision transformer and transfer learning. Signal Processing: Image Communication, 2025: 117282.
- [19] W. Tian, A. S. Azofeifa, Z. Kan, Q. Z. Zhao, G. S. Zhang, Y. Z. Wu, et al. NR-IQA for UAV hyperspectral image based on distortion constructing, feature screening, and machine learning. International Journal of Applied Earth Observation and Geoinformation, 2024, 133: 104130.
- [20] 沈琴, 蒋谟文, 骆建华. 一种改进的磁共振图像自动调窗算法. 中国医疗器械杂志, 2011, 35(4): 253-255.
- [21] 王鹏, 齐洁, 张鑫, 邓守京, 孙莉莉. 基于空域分解的雾天图像增强方法. 无线电工程, 2021, 51(11): 1261-1269.
- [22] J. Liang, H. Ju, L. Ren, L. Yang, R. Liang. Generalized polarimetric dehazing method based on low-pass filtering in frequency domain. Sensors, 2020, 20(6): 1729.