

基于图像处理的 SLM 铺粉缺陷检测识别与分类研究

伍缘杰¹ 徐晓静¹ 计效园¹ 杨欢庆² 彭东剑² 武 博¹ 周建新¹ 殷亚军¹ 沈 旭¹
(1.华中科技大学材料成形与模具技术国家重点实验室; 2.西安航天发动机有限公司)

摘 要 SLM 生产过程铺粉缺陷多采用人工间断性离线检测的方法,存在容易漏检、误检、效率较低和响应时间较长等问题,极大地影响了生产效率和生产品质。因此,搭建了一种基于图像处理的 SLM 铺粉缺陷检测识别与分类系统。该系统包括图像采集及缺陷提取、缺陷定量表征与分类识别两部分。在图像采集及缺陷提取部分,搭建了铺粉缺陷检测硬件系统,提出了基于概率快速自动选取阈值、滞后阈值分割等方法用于分割缺陷;在缺陷定量表征与分类识别部分,提出了缺陷定量表征与 CART 决策树方法进行缺陷种类的细分。结果表明,本系统对铺粉缺陷的检测识别与分类精度可达到 96.67%,响应时间在 400 ms 左右,具有较高的识别精度与检测效率,显著提升了生产效率和生产品质。

关键词 SLM;铺粉过程;缺陷检测;缺陷分类;图像处理

中图分类号 TG249.5;TP311 **文献标志码** A

DOI:10.15980/j.tzzz.2023.01.005

开放科学(资源服务)标识码(OSID):



Defect Recognition and Classification of SLM Powder Spreading Based on Image Processing

Wu Yuanjie¹, Xu Xiaojing¹, Ji Xiaoyuan¹, Yang Huanqing², Peng Dongjian², Wu Bo¹,
Zhou Jianxin¹, Yin Yajun¹, Shen Xu¹

(1.State Key Laboratory of Material Processing and Die & Mould Technology, Huazhong University of Science and Technology; 2.Xi'an Aerospace Engine Co., Ltd.)

Abstract: Artificial intermittent offline method is commonly used during SLM powder spreading process, which exists in problems such as missing, false detection, low efficiency, long response time, greatly affecting the production efficiency and quality. On this basis, a defect recognition and classification system of SLM powder spreading was established based on the image processing, which included image acquisition and defect extraction as well as defect quantitative characterization and classification recognition. For the former one, a hardware detection system of powder spreading defect was built up, and methods for defect segmentation such as fast automatic threshold selection and lag threshold segmentation based on probability were proposed. For the latter one, defect quantitative characterization and CART decision tree method were proposed to subdivide defect types. The results indicate that the detection, identification and classification accuracy of the system can reach 96.67%, and the response time is about 400 ms, which exhibits high identification accuracy and detection efficiency, greatly improving the production efficiency and quality.

Key Words: SLM, Powder Spreading, Defect Detection, Defect Classification, Image Processing

激光选区熔化(Selective laser melting, SLM)技术是增材制造技术中的重要组成部分,也是目前应用最为广泛的粉末床增材制造技术^[1]。相比于其他传统制造方法,激光选区熔化技术具有以下特点:制作过程不受零件复杂外形限制^[2],简化零部件的生产流程,快速高效^[3],制造成本低、速度快、无污染、成形件整体品质优

良^[4]等。因此,激光选区熔化技术在制造复杂结构的金属零部件方面具有传统生产加工工艺无法替代的优势,在制造航天轻质合金相关零部件制造领域有着十分重要的地位^[5]。

SLM 成形原理为通过激光扫描特定区域内的金属粉末,使之熔化后再通过层层叠加堆积成形^[6],SLM 在

收稿日期:2022-03-03;修改稿收到日期:2022-04-20
基金项目:国家自然科学基金资助项目(51905188,52090042,52275337);KGW 资助项目(2019XXX.XX4007Tm)
第一作者简介:伍缘杰,男,1997 年出生,硕士研究生,武汉(430074),E-mail:1294335005@qq.com
通信作者:计效园,男,1986 年出生,副教授,武汉(430074),E-mail:linnjxy@foxmail.com
引用格式:伍缘杰,徐晓静,计效园,等. 基于图像处理的 SLM 铺粉缺陷检测识别与分类研究[J]. 特种铸造及有色合金,2023,43(1):23-28.
WU Y J, XU X J, JI X Y, et al. Defect recognition and classification of SLM powder spreading based on image processing[J]. Special Casting & Nonferrous Alloys, 2023, 43(1):23-28.

铺粉过程中存在的缺陷对成形件的品质和性能有较大影响。因此,结合数字化、智能化方法对 SLM 成形中粉床铺粉缺陷进行在线监测与识别^[7],对于实现 SLM 成形件品质的准确控制、解决航空航天复杂构件具有积极意义。

针对 SLM 铺粉缺陷的智能监测,CRAEGHS T 等^[8]提出了用于检测粉床铺粉情况的可视化监测系统,可通过简单的图像处理技术检出水平方向线状铺粉缺陷,但能够分割的缺陷种类有限。ZHANG B 等^[9]开发了一种用于激光粉末床融合的原位条纹投影技术,通过三维重建技术以实现对粉末层表面形貌的详细测量,但缺乏对铺粉面缺陷的进一步检测识别。基于铺粉过程已采集的图像,SONKA M 等^[10]使用“滚动球”算法来对图像进行平滑处理,去除部分噪声;EL-ZAART A^[11]对图像进行阈值分割来提取缺陷部分,利用形态学腐蚀操作去除由于噪声引起的孤立区域和较小的连通分量,从而识别铺粉划痕缺陷。但上述研究都仅针对铺粉图像处理进行了局部性研究,缺乏从铺粉图像采集到缺陷检测识别的整体自动化流程及系统研究。张鹏^[12]搭建了机器视觉硬件系统,通过 Hough 变换与 CART 构造决策树等方法对缺陷进行检测识别,并结合到 SLM 加工软件中,一定程度上实现了铺粉质量的在线监控,但也存在部分缺陷种类识别精度不高的问题。

为解决 SLM 生产过程中铺粉质量采用人工间断性离线检测导致容易漏检、误检、效率较低和响应时间较长的问题^[12],针对当前激光选区熔化成形铺粉过程监测研究缺乏整体自动化系统、分割缺陷种类有限、部分缺陷种类识别精度低的现状,本课题搭建了一种基于图像处理的 SLM 铺粉缺陷检测识别与分类系统,并对此系统进行了分析和研究,旨在为其应用提供参考。

1 系统技术路线、图像采集及缺陷提取

该系统包括图像采集及缺陷提取、缺陷定量表征与分类识别两部分,具体技术路线方案见图 1。




图 1 技术路线方案示意图

Fig.1 Schematic diagram of technological route

1.1 铺粉缺陷检测硬件系统的搭建

待检出的铺粉缺陷种类有粉堆、划痕、铺粉不足、熔覆层偏高、飞溅等,对图像精度要求为 0.1 mm,因此,选用 BALSER 2000 万像素工业相机 acA5472-5gm-Basler

ace,AZURE 型号为 BW0620M-S 的镜头作为硬件检测系统的图像采集关键部件,相机采用旁轴方式安装。

采用标定法对相机进行标定^[13],并采用透视变换与双线性内插法进行相机畸变的校正。


1.2 图像预处理

在收集 SLM 粉床铺粉图像的过程中,可以发现图片受到噪音、光照、设备本身等因素的影响,导致出现亮度不均匀、对比度低等问题,严重影响铺粉图像中缺陷的检测识别。

因此提出了一种基于邻域均值与全局均值的灰度矫正法用于校正图像的亮度不均匀问题,具体步骤为:①矫正之前,求取灰度图像的灰度均值 μ_0 作为参考,并设置邻域范围;②遍历图像的每个像素点,计算当前像素点邻域内的均值 μ ,比较 μ 与 μ_0 的大小;③如果 $\mu < \mu_0$,则证明当前区域灰度值偏低,需要对当前像素的灰度值进行如下处理:

$$g = g_0 + \mu_0 - \mu \quad (1)$$

式中, g_0 为当前像素原本的灰度值; g 为更改后的灰度值;否则,证明当前区域灰度值正常或偏高,因此不采取措施,保持当前像素灰度值不变;④循环步骤②直至所有的点遍历完毕,获得处理后的图像见图 2。经过本算法矫正后,图片四周暗角情况得到有效改善,整体背景部分由于光源而出现的亮度不均匀引起的阴影也得到优化,但缺陷部分保留良好。



(a) 灰度化后图像 (b) 亮度不均匀矫正后图像

图 2 亮度不均匀矫正后图像对比

Fig.2 Image comparison after correction of uneven brightness

此外,采用对比度拉伸方法^[14]凸显图像区域细节,处理后图片整体对比度有所提升,增强了对缺陷信息的辨别能力,便于缺陷的后续检测识别。

1.3 低灰度块状缺陷提取与识别

1.3.1 阈值分割

对于粉床铺粉面的图像,铺粉正常且完好的区域作为背景部分,其面积占比较大,且灰度值为中等大小,而出现铺粉缺陷的待识别区域,面积占比较小,灰度值一般较低或较高。因而可以分别用低阈值或高阈值来实现低灰度与高灰度缺陷的分割。

图 3 为预处理后灰度直方图。可以看出,由于缺陷

的面积较小,因此图像的像素点灰度值位于中等大小的比例最高,而灰度过高或过低的比例则相对低很多,符合正态分布的。因而可以利用正态分布的性质,快速确定目标阈值的范围,进而确定最终的阈值。





图3 预处理后灰度直方图

Fig.3 Gray histogram after pretreatment

基于此,提出了一种基于概率快速自动选取阈值的阈值分割法。具体的算法步骤如下:①获取图像的灰度值的均值与标准差,即确定 μ 、 σ ,从而计算出 dt 、 T_L 与 T_H ;②确定 $T=T_L$ 为该算法的起始值,进行第一次阈值分割,并获取当前阈值所提取出的缺陷面积 S_i 及缺陷数量 N_i ;③对 T 每次递增 dt ,每次都计算出 S_i 、 N_i 及相应的 dS 和 dN ;④若 dS 、 dN 超出当前的取值范围,或 $T=T_H$,则程序结束。否则,跳转到步骤③,依次循环上述步骤。 T 为最终确定的分割阈值; σ 为该图像灰度值的标准差; T_L 与 T_H 分别为最终所取得阈值的取值范围区间的下限值和上限值,灰度介于 T_L 与 T_H 之间的点视为潜在的缺陷点; dt 为每次所增加的步长, $dt=\sigma/3$; S_i 为当前阈值提取出的缺陷面积, $dS=\frac{S_i}{S_{i-1}}$, S 为 dS 的阈值; N_i 为当前阈值提取出的缺陷个数, $dN=N_i-N_{i-1}$, N 为 dN 的阈值;对图像进行分割后结果见图4。可见,除包含少数噪声外,能较准确地将低灰度块状缺陷分割出来。



(a) 预处理后灰度图像 (b) 分割后二值化图像

图4 图像分割处理结果对比


Fig.4 Comparison of image segmentation results

1.3.2 噪声去除

图像在生成和传输过程中很容易受到周围环境及其他各种因素的干扰,从而影响后期的图像处理工作。因此提出了一种基于形态学和连通域方法的噪声去除

的方法,具体步骤如下:①对二值化后的图像进行连通域滤波,将面积较小的连通域视为非缺陷区域,将其去除;②对连通域滤波后的图像进行膨胀处理,使得被粉末噪声分隔开或由于边界不明显导致识别出来的孤立缺陷区域连通在一起;③对于每一块连通域,判断其是否为缺陷区域:第一步,该连通域的面积是否高于阈值,若是,将其视为缺陷区域,进入下一块连通域的判断;若否,进入第二步:第二步,该连通域的边界点到离其最近的连通域内点的距离是否低于阈值。若是,则将其视为缺陷区域,进入下一块连通域的判断;若否,将其视为非缺陷区域,灰度值改为255,纳入到背景区域中;④对所获得的图像进行腐蚀处理,再次去掉可能导致误识别的噪声。

对图4中阈值分割后的图像进行噪声去除,结果见图5。经过前期的图像预处理以及图像分割,可能会导致线缺陷所呈现出来的线条的断裂,通过此种方法,可避免由于线条呈现出来的破碎化导致漏检。



(a) 阈值分割后结果 (b) 噪声去除后结果

图5 噪声去除前后结果对比

Fig.5 Comparison before and after noise removal

1.4 高灰度类缺陷提取与识别

1.4.1 阈值分割

高灰度缺陷在成像时,对光线会有很强的反射能力,导致该部分缺陷灰度值集中在一个很高的小范围。因此,针对高灰度缺陷分割的阈值的设置范围为 $(\mu+2\sigma, 254)$,同样采用基于概率快速自动选取阈值的阈值分割法。

1.4.2 噪声去除

由于熔覆层过高的缺陷,其单个连通域的面积过小,若采用针对低灰度块状缺陷所使用的基于形态学和连通域方法的噪声去除方法,在过滤掉噪声的同时,也容易去除掉这些较为细碎的缺陷区域,无法做到熔覆层较高缺陷的完整提取。

针对上述问题,结合熔覆层缺陷分布集中、噪声分布离散的特点,提出了一种基于滞后阈值的图像分割及去噪算法,在二次分割图像的同时去除高灰度缺陷图像中噪声的干扰。其具体步骤如下:①首先,获取图像的灰度值的均值与标准差,即确定 μ 、 σ ,从而计算出 dt 、

T_L 与 T_H ;②确定 $T=T_H$ 为该算法的起始值,进行第一次阈值分割,将获得的二值图像作为基准图像;③对 T 每次递减 dt ,获取阈值分割后的结果,并与基准图像进行比较,并及时更新基准图像。更新方法:对于所得到的新的缺陷点,逐点进行判断,计算其到已确定的点(即上一次阈值分割后所获得的灰度值为 255 的点)的距离最小值 D_i ,若 D_i 小于阈值 D ,则将其视为缺陷点,纳入到阈值分割的结果中,将基准图像中该点的灰度值置为 255;否则,将该点视为噪声干扰,跳过,进行下一点的判断。依次循环上述步骤;④当 $T<T_L$,跳出循环,此时判断所获得的基准图像其缺陷的面积 S_0 是否大于临界值 S ,缺陷个数 N_0 是否小于临界值 N ,若是,则输出此基准图像作为阈值分割后最终所获得的二值图像,否则,输出一张灰度为 0 的二值图像,程序结束。 $T_L=\mu+3\sigma$, $T_H=T_{\max}-1$,灰度介于 T_L 与 T_H 之间的点视为潜在的缺陷点。

经过试验,以最大类间方差法(OTSU 法)作为对照,识别结果见图 6,当存在高灰度类缺陷时,本算法识别出的缺陷图像与 OTSU 法一致;当出现非高灰度缺陷(如线缺陷中的划痕)时,见图 6g,本算法相比于 OTSU 法,得到的结果更好,不会出现误识别^[14]。




图 6 OTSU 算法与本算法处理不同缺陷结果对比
Fig.6 Comparison of varied defects between OTSU algorithm and the presented algorithm

1.5 线缺陷提取与识别

由于 SLM 粉床铺粉的特殊性,其铺粉面图像的线

缺陷只有水平和垂直两大方向,采用 Hough 变换^[14]进行线缺陷的提取识别。为提高识别效率,将筛选的直线角度定为 $-2^{\circ}\sim 2^{\circ}$ 以及 $88^{\circ}\sim 92^{\circ}$ 。

最终识别结果见图 7,在原始图像中,即便是相对较浅,肉眼识别都较为困难的划痕,也可以被本算法识别。




图 7 线缺陷识别结果对比
Fig.7 Identification comparison of line defects


2 缺陷定量表征与分类识别

2.1 缺陷定量表征

按照每一类缺陷的成因和标识方法,相应的表征指标见表 1。基于以上分析,针对每类缺陷,选取缺陷面积、中心点位置坐标、长度、宽度作为同等统一定量表征指标,基本可以满足后续操作及模型建立的需求。对形状不规则缺陷,以该处缺陷的外接矩形的相应指标来替代;对于线状缺陷,只求其长度和坐标即可;而熔覆层偏高类缺陷,则只关心这类缺陷是否存在,并不关心其具体表现,其表征指标对于后续操作也并无影响,因此,不对该类缺陷进行定量表征。对缺陷的定量表征见图 8。

表 1 各类缺陷及其表征指标

Tab.1 All kinds of defects and characterization indexes				
缺陷种类	缺陷表征指标			
熔覆层偏高(属于高灰度缺陷类)	无			
线状缺陷(属于线缺陷类)	长度	起点坐标		
其他缺陷(属于高、低灰度缺陷类)	面积	中心点位置坐标	长度	宽度



(a) 块状粉堆缺陷识别结果 (b) 划痕缺陷定量表征
图 8 缺陷定量表征指标案例
Fig.8 Examples of defect quantitative characterization index

2.2 缺陷分类方法设计

由于所获取的训练样本均是可以判断所属类别的,即全部具备分类标签,因此采用监督学习进行分类器的

设计与训练。决策树分类法作为最常用的判别分类器之一,方法简单且计算速度快、执行效率高,因此,选择决策树算法对缺陷进行细化分类。

基于缺陷提取时已完成的初步分类工作,后续只用分别区分出低灰度缺陷中的凸包状粉堆与飞溅情况、高灰度缺陷中的熔覆层偏高与供粉不足情况即可,遂选取以下特征进行描述:①缺陷面积 S , S 为缺陷中所包含的像素点的个数;②缺陷处灰度值与图像灰度均值之比 G ;③缺陷的长宽比 R ,表达如下:

$$R = \begin{cases} \frac{L}{W} & (L \geq W) \\ \frac{W}{L} & (L < W) \end{cases} \quad (2)$$

式中, L 为缺陷的长度; W 为缺陷宽度。待分类缺陷特征定性描述见表 2。可以看出,在低灰度缺陷与高灰度缺陷内部,由于不同缺陷面积差异较大,基本可以准确完成分类。

表 2 缺陷特征定性表述

Tab.2 Qualitative description of defect characteristics				
缺陷种类		灰度值	面积	长宽比
低灰度缺陷	块状粉堆	低	较大	较大
	飞溅	低	较小	较小
高灰度缺陷	熔覆层偏高	高	较小	较小
	供粉不足	高	较大	较大

由于对两类不同灰度缺陷下进行详细分类,只需要将其各自分为两类即可,因此选用 CART 算法来设计二叉决策树。

当 CART 算法用于设计二叉决策树对样本进行分类时,多采用熵不纯度、基尼不纯度和错分类不纯度这 3 类度量方法中的某一种来作为分类的依据。这 3 类度量方法的原理相似,都是表达样本集分类结果的不确定性。其中,基尼不纯度使用最为频繁,因此,选用基尼指数最小来作为分类依据。

设样本集中样本的数量为 D ,一共可以分为 K 类,第 i 类样本的数量为 D_i ,则总样本集中挑选出第 i 类样本的概率为:

$$P_i = \frac{D_i}{D} \quad (3)$$

挑选出其他样本的概率为:

$$P_{i-} = 1 - \frac{D_i}{D} \quad (4)$$

则总样本集的分类结果不确定性就是取得随机某个样本不确定性的数学期望,即样本的基尼指数:

$$\begin{aligned} \text{Gini}(D) &= \sum_{i=1}^K \frac{D_i}{D} \cdot \left(1 - \frac{D_i}{D}\right) = \\ &1 - \sum_{i=1}^K \left(\frac{D_i}{D}\right)^2 = 1 - \sum_{i=1}^K P_i^2 \end{aligned} \quad (5)$$

基尼指数越小,则表明取得某个样本的不确定性越小,即分类越明确。因此,CART 分类二叉决策树的设计准则就是尽可能使得基尼指数最小化。

当选择特征 F_i 时,决策树将集合 D 分为 D^L 和 D^R 两部分,此时针对特征 F_i 的基尼指数为:

$$\begin{aligned} \text{Gini}(D, F_i) &= \frac{D^L}{D} \cdot \text{Gini}(D^L) + \frac{D^R}{D} \cdot \text{Gini}(D^R) = \\ &\frac{D^L}{D} \cdot \left[1 - \sum_{i=1}^{K_L} \left(\frac{D_i^L}{D^L}\right)^2\right] + \frac{D^R}{D} \cdot \left[1 - \sum_{i=1}^{K_R} \left(\frac{D_i^R}{D^R}\right)^2\right] = \\ &1 - \frac{1}{D} \cdot \left[\frac{\sum_{i=1}^{K_L} (D_i^L)^2}{D^L} + \frac{\sum_{i=1}^{K_R} (D_i^R)^2}{D^R}\right] \end{aligned} \quad (6)$$

而针对每个特征,还需要选取某个阈值 T_i ,小于或等于 T_i 的分为一类 D^L ,大于 T_i 的分为另一类 D^R ,因此,阈值的选取也同样重要,它决定了被划分的两类数据集集中样本数目的多少。基尼指数应由所选取的特征 F_i 与其对应的阈值 T_i 共同决定。

对于 T_i 的确定,由于特征值都是连续数据,因而采用二分法来进行处理。将 F_i 的取值按从小到大的顺序排布,记为 $\{a_1, a_2, \dots, a_n\}$,则 T_i 的取值就有 $n-1$ 个:

$$T_i = \left\{ \frac{a_j + a_{j+1}}{2} \mid 1 \leq j \leq n-1 \right\} \quad (7)$$

对于每一个 T_i 都计算相应的基尼指数 $\text{Gini}(D, F_i, T_i)$,则使得基尼指数最小的取值 T_i 即为当前划分种类所需的特征 F_i 的阈值。再与其他特征的基尼指数进行比较,最小的基尼指数对应的特征则是当前要分类的特征。

对于特征集 $F = \{F_1, F_2, F_3, F_4\}$,CART 分类二叉决策树的具体构造步骤如下:①判断数据集 D 中的样本是否为同一类别,若是,则不必再分裂结点;否则,进入下一步;②对于特征集中的每个特征 F_1, F_2, F_3, F_4 ,按照所述方法,分别求取当前特征下最小基尼指数 $\text{Gini}(D, F_i, T_i)$;③比较 4 个特征下的最小基尼指数 $\text{Gini}(D, F_i, T_i)$,选择其中最小的对应的特征 F_i 作为当前分类依据,其阈值 T_i 作为分类阈值, $\leq T_i$ 的分为一类 D^L , $> T_i$ 的分为另一类 D^R ;④对于 D^L 与 D^R 两个子节点,分别递归调用步骤①至步骤③,直至所有结点都不必再进行分裂,则结束。

搜集了缺陷样本数量共 775 个,其中块状粉堆、飞溅、熔覆层偏高及供粉不足缺陷数量分别为 105、100、300、270。对于每类缺陷都采用 70% 的样本数据用于本次决策树的训练,剩下的 30% 作为测试集。同时采用最小代价复杂度算法进行剪枝,剪枝后的决策树见图 9。

经剪枝后,决策树对于验证集的分类精度仍高达 97.84%,见表 3。




图 9 训练所得的决策树
Fig.9 Decision tree obtained by training

表 3 验证集分类结果

Tab.3 Classification results of validation set						
缺陷种类	分类结果				总数	准确率/%
	块状粉堆	飞溅	熔覆层偏高	供粉不足		
块状粉堆	31	—	—	—	31	100
飞溅	—	30	—	—	30	100
熔覆层偏高	—	—	87	3	90	96.67
供粉不足	—	—	2	79	81	97.53

3 试验验证

为了验证所设计的识别与分类算法,设计相应的实验,打印了一个接近最大成形面积的方框,其中,外框尺寸为 102 mm×102 mm,内框尺寸为 96 mm×96 mm,高度为 6 mm。使用的粉末材料为 GH4169 镍基高温合金,每层层厚为 0.02 mm,共计打印 300 层。在打印过程中,对每一层铺粉后的图像进行采集,对 300 张粉床铺粉图像进行处理,部分铺粉图像处理效果见图 10。



图 10 部分图像及识别结果
Fig.10 Partial images and recognition results

验证结果见表 4。除去第 1~8 层及 24、25 层的识

表 4 验证结果

Tab.4 Verification results				
层数	铺粉状态	识别分类结果	检测时间/s	准确率/%
1~8	合格	铺粉不足	0.457	96.67
24	划痕、熔覆层过高	熔覆层过高	0.320	
25	划痕、熔覆层过高	熔覆层过高	0.335	
57	铺粉不足、熔覆层过高	铺粉不足、熔覆层过高	0.402	
300	熔覆层过高	熔覆层过高	0.387	

别结果有误之外,整体识别准确率为 96.67%,响应时间平均为 400 ms,能够较快且准确地完成缺陷检测识别及分类任务。

4 结 论

搭建了 SLM 粉床铺粉缺陷图像监测硬件系统,将采集到的 SLM 粉床铺粉图像为研究对象,设计了基于图像处理的 SLM 粉床铺粉缺陷检测算法,利用数字图像处理技术对所采集到的图像进行处理,进一步完成缺陷识别与分类。结果表明,对于 SLM 粉床铺粉图像缺陷的检测识别与分类准确度可达到 96.67%,响应时间在 400 ms 左右,具有较高的识别精度与检测效率。

参 考 文 献

[1] 何垚垚,张航,陈子豪,等. 多材料增材制造技术进展[J]. 特种铸造及有色合金, 2021, 41(10): 1 092-1 098.

[2] TAPIA G, ELWANY A A. Review on process monitoring and control in metal-based additive manufacturing[J]. Journal of Manufacturing Science & Engineering, 2014, 136(6): 60 801.

[3] ZHANG J, SONG B, WEI Q, et al. A review of selective laser melting of aluminum alloys: Processing, microstructure, property and developing trends[J]. Journal of Materials Science & Technology, 2019, 35(2): 270-284.

[4] 卢秉恒,李涤尘. 增材制造(3D 打印)技术发展[J]. 机械制造与自动化, 2013(4): 1-4.

[5] BRANDT M, SUN S J, LEARY M, et al. High-value SLM aerospace components: from design to manufacture[J]. Advanced Materials Research, 2013, 633: 135-147.

[6] YAP C Y, CHUA C K, DONG Z L, et al. Review of selective laser melting: Materials and applications[J]. Applied Physics Reviews, 2015, 2(4): 041 101.

[7] WU B, JI X Y, ZHOU J X, et al. In situ monitoring methods for selective laser melting additive manufacturing process based on images-A review[J]. China Foundry, 2021, 18(4): 265-285.

[8] CRAEGHS T, CLIJSTERS S, YASA E, et al. Online quality control of selective laser melting[A]. 2011 International Solid Free-form Fabrication Symposium[C]. Austin: University of Texas at Austin, 2011.

[9] ZHANG B, ZIEGERT J, FARAHI F, et al. In situ surface topography of laser powder bed fusion using fringe projection[J]. Additive Manufacturing, 2016(12): 100-107.

[10] SONKA M, HLAVAC V, BOYLE R. Image Processing, Analysis, and Machine Vision[M]. Stamford: Cengage Learning, 2014.

[11] EL-ZAART A. Images thresholding using ISODATA technique with gamma distribution[J]. Pattern Recognition and Image Analysis, 2010, 20(1): 29-41.

[12] 张鹏. 基于视觉的激光选区熔化成形铺粉质量在线监控系统研究[D]. 武汉: 华中科技大学, 2017.

[13] ZHANG Z Y. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1 330-1 334.

[14] 傅可清,马源,伍缘杰,等. 铝合金压铸件 X 射线成像典型缺陷特征提取算法与实现[J]. 特种铸造及有色合金, 2021, 41(12): 1 472-1 477.

(编辑:刘卫)