

DOI: 10.3901/JME.2022.21.266

基于超分辨率改进 Faster R-CNN 的点阵结构 内部缺陷判识方法*

温银堂^{1,2} 付 凯^{1,2} 张玉燕^{1,2} 张芝威^{1,2}

(1. 燕山大学电气工程学院 秦皇岛 066004;

2. 燕山大学测试计量技术及仪器河北省重点实验室 秦皇岛 066004)

摘要: 利用增材制造技术制备金属三维点阵结构件过程中, 结构内部经常会出黏连、断裂等多种细小缺陷, 导致样件结构功能下降。根据缺陷结构与正常结构之间的特征区别, 提出了一种针对金属点阵结构内部出现的细小缺陷自动判识的方法。利用 X-射线微聚焦 CT 扫描金属点阵结构获得原始输入图片, 在 Faster R-CNN(Faster region-based convolutional neural networks) 框架的基础上, 改进原有特征提取网络, 开发图像超分辨率重建模块。通过对工业 CT 图片的局部细节特征增强, 实现了快速有效地识别细小缺陷的类型, 以及缺陷位置信息的标注。试验证明, 改进 Faster R-CNN 模型对金属点阵结构样件内部的两类典型细小缺陷识别的平均正确率高达 93.5%。研究结果表明, 通过超分辨率网络对图像进行放大, 可以提高细小缺陷的特征提取, 通过加深网络加强特征学习, 从而实现了点阵结构内部细小缺陷的自动判识。

关键词: 金属点阵结构; 缺陷识别; CT 切片图像; 改进 Faster R-CNN; 超分辨率重建

中图分类号: TG115

A Method of Improved Faster R-CNN for Detecting Internal Defect of Metal Lattice Structure Based on Super-resolution Reconstruction

WEN Yintang^{1,2} FU Kai^{1,2} ZHANG Yuyan^{1,2} ZHANG Zhiwei^{1,2}

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004;

2. Key Lab of Hebei Measurement Technology and Instrumentation of Hebei Province, Yanshan University, Qinhuangdao 066004)

Abstract: In the process of fabricating metal 3D lattice structure with additive manufacturing technology, many small defects such as adhesion and fracture often occur in the structure, which leads to the structural function decline of the sample. According to the characteristic difference between defective structure and normal structure, an automatic identification method for small defects in metal lattice structure is proposed. The original input images are obtained by scanning metal lattice structures with X-ray microfocusing CT, and the original feature extraction network is improved based on the Faster R-CNN(Faster region-based convolutional neural networks) framework. The image super-resolution reconstruction module is developed. By enhancing the local detail features of industrial CT images, it can quickly and effectively identify the types of small defects and mark the location information of defects. Experimental results show that the improved Faster R-CNN model has an average correct rate of 93.5% for identifying two typical small defects in metal lattice structure samples. The results show that the feature extraction of small defects can be improved by using super-resolution network to enlarge the image, and the feature learning can be enhanced by deepening the network, thus realizing the automatic identification of small defects in the lattice structure.

Key words: metal lattice structure; defect identification; CT slices; improved Faster R-CNN; super-resolution reconstruction

* 河北省自然科学基金(E2017203240)和河北省科技计划(20310401D)资助项目。20211118 收到初稿, 20220408 收到修改稿

0 前言

金属点阵材料是一种新型多功能材料^[1-2], 被广泛应用于生物医疗^[3]、航空航天^[4]、汽车制造等行业。增材制造(Additive manufacturing, AM)技术能够制造出传统制造方法无法实现的具有几何形状的坚固、轻便的结构, 包括复杂的点阵结构。

2011 年, LIANG 等^[5]利用选择性激光熔炼(Selective laser melting, SLM)技术^[6]成功的制备了单位尺寸为 2 mm 至 8 mm 的石墨烯蜂窝点阵结构, 证明了点阵结构的高度可制造性。但在 SLM 点阵结构制备过程中, 由于激光功率、熔池温度、应力残存等等因素^[7-9], 使得点阵结构出现裂纹、黏连、坍塌等不良效应, 严重影响点阵结构的结构-功能特性。无损检测可以探测金属点阵结构的可靠性及完整性, 是结构质量控制和安全评估的有效手段, 为点阵结构的使用提供理论依据。复杂点阵结构内部检测对传统的无损检测方式^[10-14]是个巨大一挑战。

KRAUSS 等^[15]利用热成像技术对 SLM 过程的温度分布进行分层监测, 根据热量分布随着各个参数(扫描矢量长度、激光功率、层厚和工件布局中的部件距离)的不同而改变对制造过程进行监测, 通过这些参数可以判断样件内部的缺陷。但是金属点阵结构成品具有优异的吸能吸声性, 并且缺陷位置、尺寸随机分布, 不能采用热学检测、光学检测等技术对样件内部进行检测。NOURI 等^[16]利用 X 射线扫描点阵结构, 从微层析成像角度观察增材制造的点阵结构缺陷。工业 CT (Computerized tomography) 系统通过 X 射线扫描金属点阵结构, 以二维层析成像的形式呈现样件内部的结构情况, 可以更加直观的了解样件内部是否含有缺陷。然而, 工业 CT 检测技术仍存在当层析图像数目较多, 样件内部缺陷较小时, 长时间的识别、筛选图像易引起鉴定人员的视觉疲倦, 出现缺陷漏判、误判等问题。针对如何快速、有效的识别金属点阵结构 CT 图像中缺陷缺乏一种行之有效的智能检测方法, 国内外也鲜有报道。因此, 针对工业 CT 无损检测图像的智能评阅问题需要进行深入研究。

近几年, 人们逐渐将目标检测算法^[17-21]应用在安全检查、工业生产、车牌检测等领域^[22-24], 推动社会生活的智能化, 避免人员浪费, 提高工作效率。然而, 在 CT 切片图像中缺陷检测^[25]方面目标检测算法的训练网络层数较少, 仅适用于少量样本训练, 存在辨识缺陷类型单一, 对于缺陷特征更细微的结

构断裂缺陷则不能识别等问题。目前, 针对目标检测网络的改进多数集中于快速性和准确性, 然而对于内部含有细小缺陷的点阵结构的 CT 图像的检测方法却鲜有报道。因此, 如何快速有效地对大量点阵结构 CT 图像样本数据中的细小缺陷分类识别、数目统计以及准确定位, 是亟需研究和解决的问题。

本文针对含有细小缺陷的点阵结构内部的 CT 图像提出了一种基于超分辨率重建改进 Faster R-CNN 算法。通过扩展网络深度和设计超分辨率重建网络, 加强原始图像目标细节信息, 增强目标特征, 提高了金属点阵结构内部细小缺陷的识别率, 并且实现了缺陷分类。

1 图像获取

本文的研究对象是利用 SLM 技术制备的金刚石结构样件。金刚石结构是由正四面体结构单元等密度有序排列组成, 每一个节点与周围节点等距、等角度连接。待检测的样件及内部缺陷如图 1 所示。




图 1 SLM 点阵结构

利用多功能 X 射线微聚焦 CT 系统对样件分别从三个方向对 SLM 点阵结构进行 X 射线扫描。根据被测样件特点, z 方向切片获得的图像面积大, 蕴含有效信息更多, 缺陷特征相对 x, y 两个方向来说更为明显。如图 2 所示。




图 2 SLM 点阵结构 CT 灰度图像

由于连续两张工业 CT 二维灰度图像之间存在 0.1 mm 的间距, 图 1b 中的缺陷在相邻切片图像的形态特征会呈现一种从出现到消失的变化趋势, 如

图 3 所示。在此过程中,缺陷的形态、尺寸会有一些的改变。并且,CT 切片图像中缺陷尺寸较小,每一个缺陷标记框最大仅占整张图的 0.15%。图像中缺陷的渐变性和微小性为智能检测算法的设计带来较大困难。




图 3 实际缺陷在连续切片图像中的形态变化

2 基于超分辨率改进 Faster R-CNN 的缺陷识别方法

2.1 Faster R-CNN 特征提取网络

Faster R-CNN 由 REN 等^[19]在 R-CNN, Fast R-CNN 的基础上提出,充分利用网络卷积特征,采用区域生成网络(Region proposal networks, RPN)直接生成目标候选区域取代选择性搜索。整个检测过程可以分为两步,首先提取候选区域,进行前景与背景的判断,其次是对前景的分类,属于两阶段检测器。与一阶段检测器(例如:YOLO 算法)相比,两阶段检测器的准确度要更高^[26]。因此,采用 Faster R-CNN 作为基础检测网络。

原有 Faster R-CNN 的特征提取网络默认为 VGG16。通过试验发现黏连缺陷的识别率为 86%,而断裂缺陷的识别率仅有 56%。考虑特征网络深度较浅时,对目标特征提取不足,导致后期学习、检测过程中识别率低下。因此,在原有的 VGG16 网络基础上进行网络加深。

网络梯度是从后往前传播,靠前的卷积层梯度随着网络深度增加而变小,出现学习停滞,即梯度消失问题。为解决梯度消失问题,在输入和输出之间建立直接连接,新增层在原输入层的基础上学习新的特征,即学习残差。基于时间和准确度的综合考虑,采用网络加深 34 层代替原网络。

同时,为防止出现过拟合问题,降低加深后的特征提取网络模型的参数量,采取批量归一化和全局平均池化取代 Dropout 进行正则化。结果表明,加深后的特征提取网络 VGG16+,与 VGG16 和 VGG19 相比,缺陷识别率明显提高。VGG16+作为特征提取网络,黏连缺陷的识别率相对于 VGG16

和 VGG19 分别提高了 4%、3%。对于断裂缺陷,尽管识别率提高了 4%,但仍不能满足工业检测需求。因此,需要超分辨率重建网络的开发,增强缺陷细节信息,提高缺陷识别率。此时的检测网络未嵌入图像重建模块,结果如表 1 所示。

表 1 对比试验结果

特征提取网络	黏连缺陷(%)	断裂缺陷(%)
VGG16	86	56
VGG19	87	56
VGG16+	90	60

2.2 图像超分辨率重建

针对小目标检测最简单常用的方法是将小目标放大,如何保证图像细节信息则是该方法的关键问题。针对复杂点阵结构内部典型细小缺陷目标图像放大问题,在 SRCNN^[27]算法的基础上设计 DSRCNN,较大程度增强图片中微小目标的像素信息和局部细节。该网络是本算法的关键环节,重建图像质量直接影响到微小目标缺陷的检测效果。DSRCNN 超分辨率重建网络结构如图 4 所示。




图 4 超分辨率重建网络

超分辨率重建网络可以分为三大部分,分别是特征提取,非线性映射和图像重建。重建的目标是将经过双三次插值放大的图像尽可能地贴近原图像,还原原图像的特征。

特征提取:从输入图像的 Y 通道提取图像特征组成高维特征图。网络深度对图像重建性能有很大影响。网络深度过浅会导致图像特征提取不全,网络深度过深则代表参数量过大,运算时间增长。综合考虑,选取 64 个 9×9 的卷积层进行特征提取。

非线性映射:非线性映射是影响图像重建质量的关键阶段。在 SRCNN 中,直接将高维低分辨率特征图映射到高分辨率特征空间,引起计算量的增加。因此,在设计该部分时先将高维特征量进行压缩,缩减参数特征量,再映射到高分辨率特征空间,

提高学习效率。采用 32 个 1×1 的卷积层完成到低维空间的特征映射。

图像重建: 汇聚所有的高分辨率图像块构成最终的高分辨率图像。由于图像重建层只需要输出一张特征图, 即 HR 图像, 故最后一层采用 1 个的 5×5 的卷积层。

使用均方误差(Mean squared error, MSE)作为损失函数 $L(\Theta)$, 定义为

$$L(\Theta) = \frac{1}{n} \|F(Y_i; \Theta) - X_i\|^2 \quad (1)$$

式中, n 为训练样本数; $F(Y_i; \Theta)$ 为重构结果; X_i 为实际图像; Θ 为通过梯度下降算法优化权重。通过 MSE 作为损失函数有利于得到较高的峰值信噪比(Peak signal to noise ratio, PSNR)。

2.3 改进 Faster R-CNN 网络模型

将超分辨重建网络嵌入到 Faster R-CNN 模型中, 整体网络模型如图 5 所示。首先输入图像尺寸的统一化处理, 即将输入的任意图像尺寸(如 $M \times N$)统一化为 $P \times Q$ 尺寸。然后, 将尺寸为 $P \times Q$ 的

图像经过双三次插值放大, 通过三次卷积即 DSRCNN 网络进行图像重建, 重建图像尺寸为 $n \times (P \times Q)$, n 为放大倍数。重建图像输送至特征提取网络生成卷积特征图。在区域生成网络(Region proposal networks, RPN)中, 通过 3×3 的卷积窗口在网络最后一卷积层生成的特征图上进行滑动操作。每一个窗口上生成 k 个目标候选区域, 每个候选区域有不同的尺寸和宽度比, 即 k 个锚点框(anchor boxes), anchor 位于卷积窗口的中心位置。每个窗口映射到新的 n 维 (n -dimensionality, n -d)特征图, 随后经过 Softmax 分类层和边界框回归层生成区域建议。其中, 分类层输出的是每个 anchor 属于目标或背景的概率, 回归层输出的是每个 anchor 的平移缩放的值, 即 anchor boxes 坐标值。

RoI 池化层则是负责收集 RPN 网络生成的大小、形状各不相同的目标候选区域建议。同时, 最后一层卷积特征图传输至 RoI 池化层, 得到固定输出尺寸大小的区域建议, 保护原始图像原始信息。

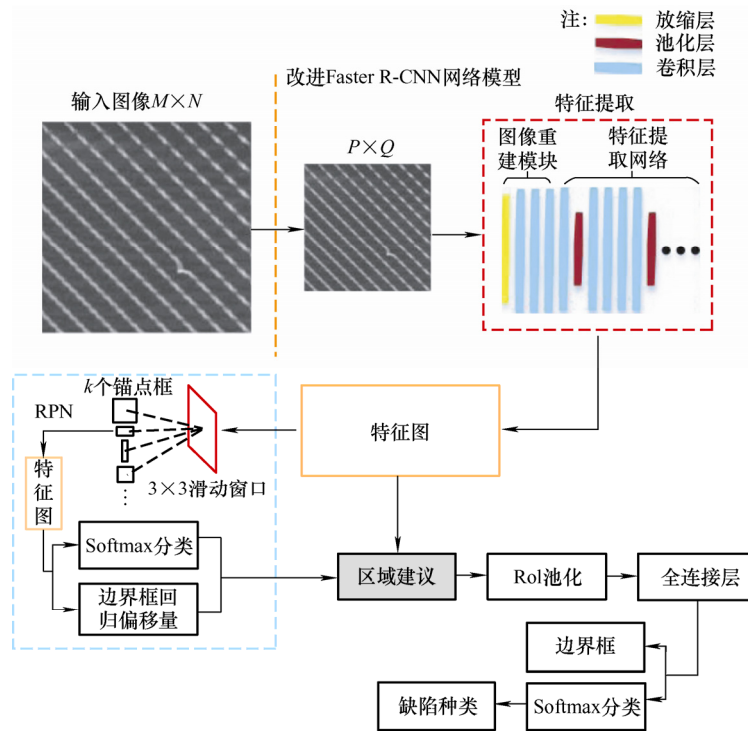


图 5 改进 Faster R-CNN 网络模型

RPN 层训练时的损失函数 L , 如式(2)所示

$$L(\{p_a\}, \{t_a\}) = \frac{1}{N_c} \sum_a L_c(p_a, p_a^*) + \lambda \frac{1}{N_r} \sum_a p_a^* L_r(t_a, t_a^*) \quad (2)$$

式中, a 表示锚点框的索引值; p_a 为锚点框的分类

概率; p_a^* 表示对应的背景预测概率。当 $p_a^* = 1$ 时, 说明第 a 个锚点框与实际目标区域 GT(ground truth) 的交集并集之比 IoU(intersection-over-union) 大于 0.8, 锚点框内为检测目标; $p_a^* = 0$ 时, 此时 IoU 小于 0.2, 锚点框内为背景, 且此时 p_a^* 不参与回归损失函数; $0.2 < p_a^* < 0.8$ 时, 锚点框不参与训练。 t_a

表示的预测边界框的坐标值, t_a^* 为目标对应的实际边界框的坐标值, N_c 和 N_r 分别为分类层和回归层损失函数的归一化系数。其中, λ 是两个系数之间的平衡参数, $\lambda = N_r / N_c$ 。 L_c 与 L_r 分别代表分类损失函数与位置回归损失函数, 函数定义如下

$$\begin{aligned} L_c(p_a, p_a^*) &= -\lg[p_a^* p_a + (1 - p_a^*)(1 - p_a)] \\ L_r(t_a, t_a^*) &= \sum_{a \in (x, y, w, h)} \text{smooth}_{L_1}(t_a - t_a^*) \end{aligned} \quad (3)$$

式中, (x, y, w, h) 表示锚点框的中心坐标位置以及宽度、高度。 $\text{smooth}_{L_1}(x)$ 为鲁棒损失函数, 函数定义为

$$\text{smooth}_{L_1}(x) = \begin{cases} 0.5x^2 & |x| < 1 \\ |x| - 0.5 & \text{其他} \end{cases} \quad (4)$$

3 试验验证验证与分析

3.1 数据集与评估标准

对 SLM 复杂点阵结构样件进行 CT 扫描后等距离截取图像。通过数据增强手段对得到的 124 张 CT 切片图像样本数据进行扩充, 最后数据集中总共包含 3 700 张图片。针对样件中的两类缺陷进行检测, 一类为断裂缺陷, 标注为 **breakpoint**; 一类为黏连缺陷, 标注为 **defect**。训练样本如图 6 所示。

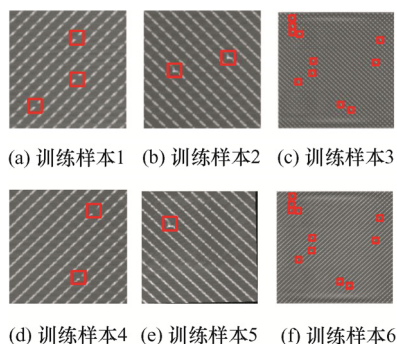


图 6 数据集

试验环境配置参数如下: GPU 为 NVIDIA GTX1080TI, 运行环境为 Ubuntu 16.0 系统, Tensorflow-GPU1.6, Python 3.6。数据集图片训练周期为 20 000 轮, 学习率初始值为 0.001, 在 11 000 轮时减小十倍。数据集分为两批(即 $\text{batch}=2$), 通过 CUDA9.0 进行并行计算框架进行加速运算。采用 mAP (mean average precision) 检测模型评估指标, mAP 是不同种类缺陷的平均正确率, 是目前检测模型应用最合理、最稳定的评估指标。计算公式如下

$$mAP = \frac{1}{S} \sum_{q=1}^S AP(q) \quad (5)$$

式中, s 为缺陷标注种类; $AP(q)$ 为每一类缺陷的平均正确率。在缺陷检测模型训练前, 数据集按照 9:1 的比例随机分为训练集和验证集两部分。测试集由未采用数据增强的干净图像组成。

3.2 超分辨率重建试验结果

图像重建效果如图 7 所示。针对超分辨率网络的重建性能, 采用峰值信噪比(Peak signal-to-noise ratio, PSNR)和结构相似性(Structural similarity index, SSIM)进行评估, 表述如下

$$\text{PSNR} = 10 \times \lg \left(\left(2^n - 1 \right)^2 / I_{MSE} \right) \quad (6)$$

$$\text{SSIM}(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

式中, μ_x 和 μ_y 分别表示图像 x, y 的均值; σ_x 和 σ_y 表示图像 x, y 的标准差; σ_{xy} 表示图像 x 和图像 y 的协方差; C_1 、 C_2 及 C_3 则为常数, 避免分母为 0。基于性能和准确度, 图像设置为放大 2 倍, 试验结果如图 7 所示。

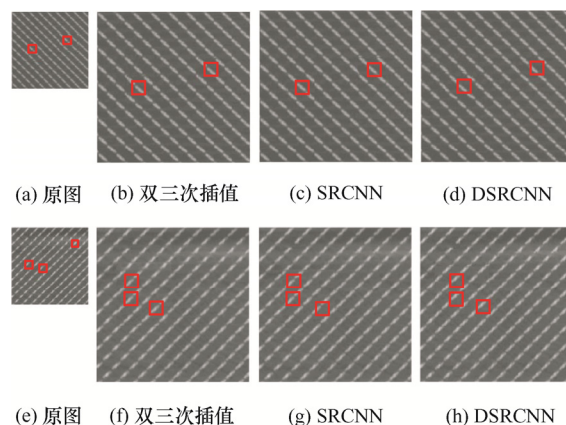



图 7 超分辨率重建


图 7b~7d, 7f~7h 的 PSNR、SSIM 值, 以及全部图像的平均 PSNR、SSIM 值, 如表 2 所示。其中, DSRCNN 算法的全部图像平均 PSNR 值为 40.53, 平均 SSIM 为 89.12, 均要高于双三次插值法, 与 SRCNN 相比基本一致。试验结果表明本文提出的 DSRCNN 算法可以有效地对细小缺陷图像进行重建, 虽然在重建部分对特征量进行了压缩, 但并未影响图像重建质量。但是通过对特征量的有效压缩, 提高了图像重建网络的计算速度, SRCNN 平均每张图重建时间需要 23 s, DSRCNN 平均每张图重建时间需要 20 s, 每张图平均提高 3 s 左右。

表 2 超分辨率试验对比结果

评价标准	算法	图像 a	图像 c	全部图像
PSNR	双三次插值	36.99	37.46	37.75
	SRCNN	40.20	41.63	40.95
	DSRCNN	42.45	41.68	40.53
SSIM	双三次插值	77.35	78.38	78.25
	SRCNN	87.49	88.93	88.98
	DSRCNN	88.11	88.10	89.12



(a) 识别结果1



(b) 识别结果2

图 8 缺陷识别结果

表 3 不同模型性能对比

模型	AP-breakpoint	AP-defect	mAP
试验一	0.78	0.86	0.82
试验二	0.79	0.90	0.845
试验三	—	0.98	0.49
MSCNN	0.86	0.93	0.895
本文算法	0.89	0.98	0.935

试验一、试验二、本文算法检测结果与表 1 相比证明图像重建网络的引入有助于细小缺陷识别正确率的提升。其中，试验一的缺陷识别平均正确率提高了 11%，试验二的缺陷识别平均正确率提高了 13%，本文算法的缺陷识别平均正确率提高了 18.5%。试验结果表明超分辨率算法可以有效增强小目标缺陷细节特征信息，达到提高金属点阵结构内部细小缺陷的识别率的目的。与试验三相比，本文算法实现了不同种类缺陷的识别，并且可以自动判识更加微小的缺陷。最后，与现

3.3 算法试验结果及分析

通过 DSRCNN 网络优化 VGG16、VGG19 作为对比试验一和对比试验二，文献[25]所提方法作为对比试验三，与本文算法即 DSRCNN 网络优化 VGG16+算法，以及 MSCNN 算法^[20]，进行试验对比验证。结果表明本文提出的改进 Faster R-CNN 算法在两种缺陷占比均为 0.15%的图像中可以实现缺陷自动判识，并且两种缺陷的平均识别正确率达到 93.5%，优于其他四种算法。部分缺陷识别结果如图 8 所示，其中 breakpoint 表示断裂缺陷，defect 表示黏连缺陷，算法性能如表 3 所示。

有的小目标检测算法 MSCNN 相比，缺陷识别正确率高 4%，验证了本文算法在细小缺陷目标检测方面的有效性，可以为点阵结构的性能评价提供坚实的基础。

基于超分辨率改进 Faster R-CNN 可以识别 80 类不同目标，但由于测试样件内部缺陷仅存在黏连和断裂两类典型缺陷，缺乏其余缺陷类型样本数据，该算法的优势未能全部展现。在今后工作中，随着样本数据的增加，数据库的逐渐完善，缺陷识别种类将会越来越多，达到辅助检测人员的目的，为点阵结构的结构-功能评价以及安全评估做出贡献。

4 结论

(1) 特征提取网络的加深有利于提高缺陷识别率，但针对一些细小缺陷目标时，结合超分辨率重建网络，可以达到更高的识别精度。

(2) 在切片图像中目标特征连续变化且与图片背景高度相似的情况下, 超分辨重建网络可以有效增强结构断裂和黏连两种结构细小畸变类型缺陷的特征。

(3) 通过在目标检测算法中设计图像重建模块, 实现了对缺陷尺寸占比 0.15% 的切片图像中缺陷的有效分类判识, 与未加图像重建网络相比, 本文算法缺陷平均检测正确率提高了 18.5%, 达到 93.5%。

(4) 本文算法可以对在 CT 图像中连续变化的细小缺陷有效判识, 可以极大的提高工业检测人员的工作效率。今后, 应结合检测网络输出的缺陷类型及位置信息对检测样件进行三维表征, 增强算法功能。

参 考 文 献

- [1] MOON S K, TAN Y E, JIHONG H, et al. Application of 3D printing technology for designing light-weight unmanned aerial vehicle wing structures[J]. International Journal of Precision Engineering and Manufacturing -Green Technology, 2014, 1(3): 223-228.
- [2] XIONG Jian, MA Li, WU Linzhi, et al. Fabrication and crushing behavior of low density carbon fiber composite pyramidal truss structures[J]. Composite Structures, 2010, 92(11): 2695-2702.
- [3] SHIDID D, LEARY M, CHOOG P, et al. Just-in-time design and additive manufacture of patient-specific medical implants[J]. Physics Procedia, 2016, 83: 4-14.
- [4] ZHOU Hao, ZHANG Xiaoyu, ZENG Huizhong, et al. Lightweight structure of a phase-change thermal controller based on lattice cells manufactured by SLM[J]. Chinese Journal of Aeronautics, 2019, 32(7): 1727-1732.
- [5] LIANG Hao, RAYMONT David, YAN Chunze, et al. Design and additive manufacturing of cellular lattice structures[C]//The International Conference on Advanced Research in Virtual and Rapid Prototyping (VRAP). Taylor & Francis Group, Leiria. 2011: 249-254.
- [6] LIU Fei, ZHANG David, ZHANG Peng, et al. Mechanical properties of optimized diamond lattice structure for bone scaffolds fabricated via selective laser melting[J]. Materials, 2018, 11(3): 374.
- [7] 郑聃, 李瑞迪, 宋波, 等. NiTi 气雾化制粉工艺对选区激光熔化成型性、制件超弹性的影响[J]. 机械工程学报, 2020, 56(15): 104-109.
- ZHENG Dan, LI Ruidi, SONG Bo, et al. Effect of NiTi powder gas atomization process on the selective laser melting moldability and alloys' superelastic[J]. Journal of Mechanical Engineering, 2020, 56(15): 104-109.
- [8] SING S L, WIRIA F E, YEONG W Y. Selective laser melting of lattice structures: A statistical approach to manu-facturability and mechanical behavior[J]. Robotics and Computer-Integrated Manufacturing, 2018, 49: 170-180.
- [9] MAZUR M, LEARY M, SUN Shoujin, et al. Deformation and failure behaviour of Ti-6Al-4V lattice structures manufactured by selective laser melting (SLM)[J]. The International Journal of Advanced Manufacturing Technology, 2016, 84(5-8): 1391-1411.
- [10] 郭冠华, 熊鸿建. 中国射线检测技术现状及研究进展[J]. 仪器仪表学报, 2016, 37(8): 1683-1695.
- WU Guanhua, XIONG Hongjian. Radiography testing in China[J]. Chinese Journal of Scientific Instrument, 2016, 37(8): 1683-1695.
- [11] 姬文苏, 丁玉奎. 火箭发动机多层粘接结构超声检测研究[J]. 兵工学报, 2015, 36(S1): 364-368.
- JI Wensu, DING Yukui. Study of ultrasonic detection for multi-layer adhesive joints of solid propellant rocket engines[J]. Acta Armamentarii, 2015, 36(S1): 364-368.
- [12] 郭健, 张丹, 马国义, 等. 无损检测(NDT)——磁粉检测(MT)技术[J]. 工程与试验, 2011, 51(3): 55-58.
- GUO Jian, ZHANG Dan, MA Guoyi, et al. Nondestructive testing-magnetic particle testing technology[J]. Engineering & Test, 2011, 51(3): 55-58.
- [13] 杨理践, 耿浩, 高松巍. 长输油气管道漏磁内检测技术[J]. 仪器仪表学报, 2016, 37(8): 1736-1746.
- YANG Lijian, GENG Hao, GAO Songwei. Magnetic flux leakage internal detection technology of the long distance oil pipeline[J]. Chinese Journal of Scientific Instrument, 2016, 37(8): 1736-1746.
- [14] GARCIA-MARTIN J, GOMEZ-GIL J, VAZQUEZ-SANCHEZ E. Non-destructive techniques based on eddy current testing[J]. Sensors, 2011, 11(3): 2525.
- [15] KRAUSS H, ZEUGNER T, ZAEH M F. Layerwise monitoring of the selective laser melting process by thermography[J]. Physics Procedia, 2014, 56: 64-71.
- [16] NOURI H, GUEDDASMA S, BELHABIB S. Structural im-perfections in additive manufacturing perceived from the X-ray micro-tomography perspective[J]. Journal of Materials Processing Technology, 2016, 234: 113-124.
- [17] SANDE K, UIJLINGS J, GEVERS T, et al. Segmentation as selective search for object recognition[C]//

- International Conference on Computer Vision. Barcelona, Spain: IEEE Computer Society, 2011: 1879-1886.
- [18] SERMANET P, EIGEN D, ZHANG Xiang, et al. Overfeat: Integrated recognition, localization and detection using convolutional networks[C]//2nd International Conference on Learning Representations, ICLR 2014. Banff, Canada, Université de Montreal, 2014.
- [19] REN Shaoqing, HE Kaiming, GIRSHICK Ross, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 39(6): 1137-1149.
- [20] CAI Zhaowei, FAN Quanfu, FERIS R, et al. A unified multi-scale deep convolutional neural network for fast object detection[J]. Lecture Notes in Computer Science, 2016, 354-370.
- [21] JOSEPH R, ALI F. Yolov3: An incremental improvement[EB/OL]. arXiv preprint [2020-2-25]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [22] 田珠, 桂志国, 张鹏程, 等. Faster-RCNN 用于工业火花塞图像焊缝缺陷检测[J]. 测试技术学报, 2020, 34(1): 34-40.
- TIAN Zhu, GUI Zhiguo, ZHANG Pengcheng, et al. Faster-RCNN for industrial spark plug image weld defect inspection[J]. Journal of Test and Measurement Technology, 2020, 34(1): 34-40.
- [23] 梁杰, 李磊, 任君, 等. 基于深度学习的红外图像遮挡干扰检测方法[J]. 兵工学报, 2019, 40(7): 1401-1410.
- LIANG Jie, LI Lei, REN Jun, et al. Infrared image occlusion interference detection method based on deep learning[J]. Acta Armamentarii, 2019, 40(7): 1401-1410.
- [24] XIE Lele, AHMAD T, JIN Lianwen, et al. A new CNN-based method for multi-directional car license plate detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(2): 507-517.
- [25] 张玉燕, 李永保, 温银堂, 等. 基于 Faster R-卷积神经网络的金属点阵结构缺陷识别方法[J]. 兵工学报, 2019, 40(11): 2329-2335.
- ZHANG Yuyan, LI Yongbao, WEN Yintang, et al. Internal defect detection of metal three-dimensional multi-layer lattice structure based on Faster R-CNN[J]. Acta Armamentarii, 2019, 40(11): 2329-2335.
- [26] ZOU Zhengxia, SHI Zhenwei, GUO Yuhong, et al. Object detection in 20 years: A survey[EB/OL]. arXiv preprint [2019-05-16] <https://doi.org/10.48550/arXiv.1905.05055>.
- [27] DONG Chao, LOY Chenchang, HE Kaiming, et al. Learning a deep convolutional network for image super-resolution[C]// European conference on computer vision. Springer, Cham, 2014: 184-199.

作者简介: 温银堂, 男, 1978 年出生, 博士, 研究员, 博士研究生导师。主要研究方向为智能检测与评估技术。

E-mail: ytwen@ysu.edu.cn

张玉燕(通信作者), 女, 1976 年出生, 博士, 教授, 博士研究生导师。主要研究方向为动态测量与分析、结构健康监测、电容层析成像。

E-mail: yyzhang@ysu.edu.cn