

DOI: 10. 19650/j.cnki.cjsi.J2006080

基于磁光成像的低碳钢 WAAM 成形件 表面缺陷检测与分类^{*}

何 翔, 李亮玉, 王天琪, 钟 蒲

(天津工业大学 天津市现代机电装备技术重点实验室 天津 300387)

摘 要:针对电弧增材制造(WAAM)成形件表面及亚表面微小缺陷难以检测和识别的问题,结合图像纹理特征和神经网络提出一种基于磁光成像的无损检测方法,实现低碳钢 WAAM 成形件表面微小缺陷检测和分类。首先对二次表面精加工后的 WAAM 成形件进行磁化,并使用磁光成像仪获取成形件表面磁光图像作为试验样本,然后对磁光图像进行预处理,用灰度共生矩阵提取每幅图像的能量、熵、对比度和相关性纹理特征,对比分析无缺陷、熔合不良、凹陷和裂纹 4 种 WAAM 成形件表面质量纹理特征,最后通过建立的 LMBP 神经网络模型对成形件表面质量进行分类预测。试验预测结果表明,WAAM 成形件表面缺陷检出率为 97.33%,表面质量分类准确率可达 91.33%,验证了所提方法能够有效检测和识别低碳钢 WAAM 成形件表面微小缺陷。

关键词: 增材制造;磁光成像;缺陷检测;缺陷分类;纹理特征;神经网络

中图分类号: TG455 TH878 文献标识码: A 国家标准学科分类代码: 520.2040

Surface defects detection and classification of low carbon steel WAAM formed parts based on magneto-optical imaging

He Xiang, Li Liangyu, Wang Tianqi, Zhong Pu

(Tianjin Modern Electromechanical Equipment Technology Key Laboratory,
Tiangong University, Tianjin 300387, China)

Abstract: It is difficult to detect and identify small defects on the surface and subsurface of wire arc additive manufacturing (WAAM) formed parts. To solve this problem, the texture feature of images and neural networks are both utilized. A non-destructive detection method based on magneto-optical imaging is proposed to detect surface defects of low carbon steel WAAM formed parts detection and classification. Firstly, WAAM formed parts are magnetized after processing by surface finishing. Magneto-optical images of the surface of formed parts are obtained by the magneto-optical imager as test samples. Then, the texture feature of angular second moment, entropy, contrast and correlation of magneto-optical images are extracted by the gray-level co-occurrence matrix after preprocessing the images and texture feature data of four different surface qualities. To be specific, perfectness, poor fusion, depression and cracks are used to carry out comparison. Finally, the classification of formed parts is predicted by Leveberg-Marquard (LMBP) neural network. Experimental prediction results show that the surface defect detection rate of low carbon steel WAAM formed parts is 97.33% and the classification accuracy rate of the surface quality can reach 91.33%. These results verify that the proposed method can effectively detect and identify small surface defects on surface of low carbon steel WAAM formed parts.

Keywords: additive manufacturing; magneto-optical imaging; defect detection; defect classification; texture feature; neural networks

0 引言

电弧增材制造 (wire arc additive manufacturing, WAAM) 作为金属增材制造工艺中重要的组成部分,在制件及应用研究方面取得了大量成果,有较好的发展前景,但质量问题一直是制约该技术走向广泛应用的瓶颈之一^[1-2]。WAAM 技术以电弧为载能束,采用逐层堆积材料的方法制造金属零件,成形过程中存在复杂的质和传热过程,成形零件表面波动较大,成形质量较低,因此需要对其进行表面二次精加工后才能进行工业应用。但其表面及亚表面仍然可能存在熔合不良、凹陷和裂纹等微小缺陷^[3-4]。这些微小的表面缺陷的存在将影响工件的使用性能和使用寿命,甚至会导致严重的安全事故,因此有必要对 WAAM 成形工件表面进行有效的无损检测。国内外学者对金属增材制造的缺陷检测大多采用涡流、热成像和激光超声等检测方法^[5]。英国的 Rudlin 等^[6]采用涡流检测直径为 0.2 mm 表面缺陷以及直径为 0.6 mm 埋深 1 mm 缺陷的检出率可达 90%;北京工业大学赵昀等^[7]采用高速摄像机拍摄熔滴过渡行为分析成形质量,优化工艺参数;广东工业大学马波等^[8]采用激光视觉对成形件侧表面质量进行三维重构误差小于 0.2 mm。但以上检测方法对 WAAM 成形件表面质量检测皆存在一定的弊端,如热成像只能在成形过程中对成形质量进行检测,无法检测成形后质量;超声和涡流检测信号复杂且不能得到直观的图像;激光视觉在检测过程中易受到外界环境干扰,光照不稳定影响微小缺陷检测的稳定性和准确性。

磁光成像作为一种前沿的无损检测方法,无需进行复杂的信号处理就可将缺陷信息图像化,能有效地检测出被测工件表面及亚表面的微小缺陷,具有操作安全、灵敏度高和成像效果好且稳定等优点^[9-10]。国内外许多学者对其进行了研究和应用,美国科罗拉多大学 Deng 等^[11]通过结合飞机铆钉的磁光图像和磁场有限元模型,研究得出了关于检测参数的缺陷检出率曲线图;电子科技大学的 Cheng 等^[12-13]建立了一种磁光/涡流实时成像检测系统,用图像处理算法消除磁畴干扰,极大改善了涡流检测效率低和成像效果不好的缺点。广东工业大学高向东等^[14-15]将磁光成像技术应用于碳钢微间隙焊缝跟踪和焊接缺陷检测,整体识别率可达到 92.6%。上述学者的研究成果证明磁光成像能对微小缺陷进行可视化检测,检测效果良好且稳定。

本文针对 WAAM 成形件表面积大而缺陷小的特点,现有检测方法对其缺陷检测和分类准确率不高,提出以低碳钢成形件为研究对象,采用磁光成像检测方法,结合图像纹理特征与神经网络分类识别技术,对 WAAM 成形

件表面缺陷进行检测和分类研究。使用磁光成像仪获取成形件表面的磁光图像,对其进行预处理后,采用灰度共生矩阵提取图像纹理特征,将特征参数输入经 LM (Levenberg-Marquardt) 算法改进的 BP (back propagation) 神经网络模型进行预测分类。预测结果显示,低碳钢 WAAM 成形件表面缺陷检出率为 97.33%,分类预测准确率可达 91.33%。本文的研究工作为 WAAM 成形件表面质量可视化检测和准确识别提供了一种有效的检测方法。

1 磁光成像原理

磁光成像是一种基于法拉第磁致旋光效应的无损检测方法^[16],其原理如图 1 所示。光源发射的光波经起偏器形成线偏振光,通过磁光介质后被镜面涂层反射,透过检偏器后互补金属氧化物半导体 (complementary metal oxide semiconductor, CMOS) 相机接收光强信息。由于成形件表面缺陷处磁场的变化,将会导致介质中平行于光传播方向上的磁场分布也将发生相应变化,因此线偏振光通过磁光介质后会产生不同程度偏转,CMOS 相机接收到不同光强信息后,在上位机界面中显示带有缺陷的磁光图像^[17],线偏振光偏转角度 θ 即法拉第磁致旋光角满足下式。

$$\theta = VBL \quad (1)$$

式中: V 为费尔德常数,表征介质的磁光特性,与介质材料性质相关; L 为光在介质中通过的长度; B 为介质中平行于光传播方向的磁感应强度。




图1 磁光成像原理

Fig.1 Principle of magneto-optical imaging technique

2 磁光图像处理

获取得到彩色的磁光图像,对其进行灰度化、切片和压缩灰度级的预处理,突出缺陷信息并提高程序运行效率。图像纹理可反映图像中同质现象,不同表面质量的磁光图像纹理各不相同,灰度共生矩阵提取图像纹理特

征具有较强的适应性和鲁棒性^[18]。本文对磁光图像预处理后,采用灰度共生矩阵计算图像纹理特征值。

2.1 磁光图像的预处理

先对磁光图像进行灰度化处理,减少图像的复杂度和信息处理量。然后为突出成形件的表面缺陷信息,对磁光图像切片得到 400×400 pixel 图像,图 2 所示为切片后 4 种表面质量的磁光图像。由图 2 可看出,WAAM 成形件表面经过二次精加工,除存在微小缺陷位置,其余部分表面质量良好,图像中无明显噪声干扰,验证了磁光成像对 WAAM 成形件表面微小缺陷检测成像效果良好。最后将图像灰度级从 256 降低至 16,在保留图像基本特征的情况下,减少了图像处理的计算量。




图 2 切片后磁光图像

Fig.2 Magneto-optical image after crop

2.2 磁光图像纹理特征提取

在磁光图像空间中,相隔一定距离的两像素之间存在一定的灰度关系,即灰度的空间相关特性。通过灰度共生矩阵研究灰度空间特性,描述图像的纹理特征^[19]。灰度共生矩阵统计所有从灰度 i 的像素点沿 α 方向移动步距 d 到达灰度为 j 的像素点的概率 $p(i, j)$ 。选择能量、熵、对比度和相关性 4 种特征作为磁光图像的纹理特征,既便于计算又可得出较高的分类精度。

能量 W_1 是图像纹理灰度变化均匀性的度量,反映了图像灰度分布均匀程度和纹理粗细程度。

$$W_1 = \sum_{i=1}^g \sum_{j=1}^g \{p(i, j)\}^2 \quad (2)$$

熵 W_2 是图像具有信息量的度量,表示图像中纹理的非均匀程度或复杂程度。

$$W_2 = - \sum_{i=1}^g \sum_{j=1}^g p(i, j) \times \log_{10} p(i, j) \quad (3)$$

对比度 W_3 是灰度在矩阵中分布情况和图像局部变化的度量,直接反映了图像纹理的清晰度。

$$W_3 = \sum_{i=1}^g \sum_{j=1}^g [(i - j)^2 \times p(i, j)] \quad (4)$$

相关性 W_4 是用来衡量灰度共生矩阵的元素在行或列方向上的相似程度,反映了图像纹理的一致性。

$$W_4 = \sum_{i=1}^g \sum_{j=1}^g [i \times j \times p(i, j) - u_1 \times u_2] / (\delta_1 \times \delta_2) \quad (5)$$

其中:

$$u_1 = \sum_{i=1}^g \sum_{j=1}^g i \times p(i, j); u_2 = \sum_{i=1}^g \sum_{j=1}^g j \times p(i, j);$$

$$\delta_1 = (i - u_1)^2 \sum_{i=1}^g \sum_{j=1}^g p(i, j); \delta_2 = (j - u_2)^2 \sum_{i=1}^g \sum_{j=1}^g p(i, j)$$

通常计算灰度共生矩阵时,步距 $d=1$,方向 α 分别取 0° 、 45° 、 90° 和 135° 。每幅磁光图像可得到 4 个方向的灰度共生矩阵,根据式(2)~(5)即可计算每个灰度共生矩阵的能量 W_1 、熵 W_2 、对比度 W_3 和相关性 W_4 4 个特征值,即每幅磁光图像可得 16 个特征值。为提高分类模型的计算效率,将每幅磁光图像计算出的同类特征在 4 个 α 方向上取平均值 W_i-m 和标准差 $W_i-s (i=1, 2, 3, 4)$,作为神经网络分类模型的输入特征参数。

3 神经网络分类

BP 神经网络是一种前向传播求损失值,反向传播误差的神经网络学习算法,根据误差信号修正每层的权重与偏置直至网络的全局误差趋向极小值^[20-21]。LM 算法是一种介于高斯牛顿法和梯度下降法之间进行平滑调和的结合算法,可加快 BP 神经网络的训练速度,提高分类的准确性^[22]。

BP 神经网络结构如图 3 所示。根据输入输出数据特点构建 LMBP 神经网络模型,通过磁光图像纹理特征值,对不同表面质量的低碳钢 WAAM 成形件进行分类预测。输入层神经元节点数为 8,输入量分别为每幅磁光图像的能量、熵、对比度和相关性 4 种纹理特征的平均值和标准差,即输入向量 $\mathbf{x} = \{x_1 = W_{1-m}, x_2 = W_{1-s}, x_3 = W_{2-m}, x_4 = W_{2-s}, x_5 = W_{3-m}, x_6 = W_{3-s}, x_7 = W_{4-m}, x_8 = W_{4-s}\}$ 。通过多次试验,中间隐含层神经元节点数为 10 时能较好地对表面质量进行预测。依据 One-Hot 编码规则,输出层神经元节点数设为 4,输出向量 $\mathbf{y} = \{y_1, y_2, y_3, y_4\}$,任意时候只有一位状态寄存器有效为 1,其他位为 0,即无缺陷、熔合不良、凹陷和裂纹 4 种表面质量分别用 $\{1, 0, 0, 0\}$ 、 $\{0, 1, 0, 0\}$ 、 $\{0, 0, 1, 0\}$ 和 $\{0, 0, 0, 1\}$ 表示。激活函数选用 Sigmoid 函数,训练函数选用 trainlm。




图 3 BP 神经网络结构

Fig.3 Structure of BP neural network

4 试验方案和结果分析

4.1 磁光图像的预处理

磁光成像检测试验系统如图 4 所示。检测试件为经过机械精加工的低碳钢 WAAM 成形件,尺寸 60 mm×45 mm×5 mm($L\times W\times D$),利用预磁化座将试件磁化后,使用 Matesy GmbH 公司的 Cmos-Magview 型号磁光成像仪获取试件表面磁光图像。低碳钢 WAAM 成形件 4 种表面质量实物如图 5 所示。




图 4 磁光成像检测试验系统

Fig.4 Experimental system of magneto-optical imaging test

4.2 磁光图像纹理提取试验

取 1 200 幅磁光图像作为试验样本,其中无缺陷、熔合不良、凹陷和裂纹的磁光图像各 300 幅,如表 1 所示。计算每幅磁光图像在所取 α 方向的特征值,将同类表面质量磁光图像的特征值取平均值后进行对比,如图 6 所




图 5 低碳钢 WAAM 成形件实物



Fig.5 Low-carbon steel WAAM formed parts

示。由图 6 可知,不同表面质量磁光图像的特征值存在一定区别,但熔合不良与裂纹的能量、熵和对比度特征值较近似,无缺陷与凹陷的对比度特征值区别不大,因此综合 4 种图像纹理特征能更有效反映出磁光图像中成形件的不同表面质量。

表 1 LMBP 神经网络模型样本

Table 1 Samples of the LMBP neural network model 幅

表面 质量序号	表面 质量说明	训练集	测试集	图像序列	总计
1	无缺陷	225	75	1~300	300
2	熔合不良	225	75	301~600	300
3	凹陷	225	75	601~900	300
4	裂纹	225	75	901~1 200	300
总计	—	900	300	—	1 200






图 6 低碳钢 WAAM 成形件表面质量磁光图像特征值对比

Fig.6 Feature data comparison of low-carbon steel WAAM formed parts surface quality magneto-optical images

图 7 所示为 1 200 幅磁光图像特征值在所取 4 个 α 方向取平均值和标准差后得到的特征参数对比曲线。由图 7 可看出,由于成形试件表面经过二次表面精加工,每种表面质量磁光图像特征参数数据分布较为稳定,同时也验证了磁光成像对低碳钢 WAAM 成形件表面质量检测的稳定性。分析图 7 可知,无缺陷磁光图

像的特征参数与 3 种有缺陷的磁光图像有较大差距,而 3 种缺陷磁光图像的特征参数则较为相近,其中熔合不良与凹陷磁光图像的特征参数存在一定差别,裂纹磁光图像特征参数值则介于二者之间。不同表面质量的磁光图像的特征参数存在着一定差异,为神经网络模型分类提供了依据。




图 7 1 200 幅低碳钢 WAAM 成形件表面质量磁光图像特征参数对比

Fig.7 Feature parameters comparison of 1200 low-carbon steel WAAM formed parts surface quality magneto-optical images

4.3 神经网络试验

从每种表面质量的磁光图像中随机选取 225 幅,共 900 幅作为训练样本,剩余的 300 幅磁光图像作为测试样本。将样本特征参数输入已经建立好的 LMBP 神经网络模型,分类预测结果如图 8 所示。

预测表面质量序号	1	2	3	4	
	74 24.67%	0 0.00%	0 0.00%	0 0.00%	100%
	0 0.00%	68 22.67%	2 0.67%	5 1.67%	90.67%
	1 0.33%	3 1.00%	70 23.33%	3 1.00%	90.91%
	0 0.00%	4 1.33%	3 1.00%	67 22.33%	90.54%
	98.67% 1.33%	90.67% 9.33%	93.33% 6.67%	89.33% 10.67%	93.00% 7.00%
	1	2	3	4	
实际表面质量序号					

图 8 测试样本分类预测结果

Fig.8 Classification results of testing samples

在图 8 中,采用混淆矩阵^[23](confusion matrix)统计每一次预测分类结果。在矩阵中,每一列表示实际工件的表面质量,每一行表示预测表面质量的结果。最右下角方框表示所有测试样本表面质量分类预测的准确率和错误率,最后一行方框(除最右下角方框外)分别表示每种表面质量成形件测试样本分类预测的正确率和错误率。以第 2 列为例,在熔合不良(表面质量序号为 2)磁光图像的 75 个测试样本中有 68 个样本正确预测为熔合不良,有 3 个样本错误预测为凹陷和 4 个样本被错误预测为裂纹,第 2 行第 2 列的 22.67%代表的是 68 除以测试样本总数 300。采用这种形式统计分类预测结果,可以直接而清楚地读出测试样本中每种表面质量的分类情况和分类正确率。经过试验统计,测试样本 10 次的平均缺陷检出率为 97.33%,能有效检测出无缺陷的样件;熔合不良和凹陷的识别正确率分别为 89.33%和 92.00%,裂纹识别正确率偏低仅为 86.67%,整体分类准确率可达 91.33%。

文献[6]通过监测工件表面涡流产生的阻抗信号,实现表面缺陷的检测。本文可实现 WAAM 成形件表面微小缺陷的可视化检测,根据磁光图像纹理特征,即可较为准确地预测出缺陷及缺陷的种类。缺陷的检出率提高了约 7%,且实现缺陷种类的识别。

5 结 论

针对 WAAM 成形件表面及亚表面微小缺陷难以检

测和识别的问题,本文提出了采用磁光成像检测技术对低碳钢 WAAM 成形件表面进行检测,并基于图像的纹理特征,结合 LMBP 神经网络模型进行表面质量预测。通过电弧增材制造试验获得一批低碳钢成形试件,使用磁光成像仪获取了大量磁光图像并建立了部分样本数据库。从磁光成像检测缺陷机理和试验获得的磁光图像,验证了本文方法可实现低碳钢 WAAM 成形件表面可视化检测,成像效果好且稳定。对比分析了不同表面质量的磁光图像纹理特征,并构建 LMBP 神经网络模型进行了分类预测。试验结果显示,缺陷检出率为 97.33%,整体分类准确率可达 91.33%,表明该方法实现了低碳钢 WAAM 成形件表面质量分类。相比与超声、涡流和磁粉等检测方法,本文所提方法对 WAAM 成型件微小缺陷检测可视化效果好,缺陷检出率高,且实现了缺陷种类的识别。

本文方法虽然实现了低碳钢 WAAM 成形件表面质量检测 and 分类,但仍然有以下两点需要深入研究。1) 缺陷分类的准确性有待提高,这是由于试验样件缺陷的产生存在诸多不决定性因素,导致未熔透深度、凹陷形貌和裂纹长度等缺陷形态存在差异。因此相信在样本数量适当增加的情况下,本文所采用方法的整体识别正确率还会有所提高。2) 错误预测分类的样本中,熔合不良和裂纹相互识别是降低检测准确率的主要因素之一,对此未来将针对缺陷产生机理进行研究,结合其他无损检测方法对试件质量进行检测和识别。

参考文献

[1] 田彩兰,陈济轮,董鹏,等.国外电弧增材制造技术的研究现状及展望[J].航天制造技术,2015(2):57-60.
TIAN C L, CHEN J L, DONG P, et al. Current state and future development of wire arc additive manufacturing technology abroad [J]. Aeronautical Manufacturing Technology, 2015(2): 57-60.

[2] 陈超,刘李明,徐江敏.金属增材制造技术在船舶与海工领域中的应用分析[J].中国造船,2016,57(3):215-225.
CHEN CH, LIU L M, XU J M. Application of metal additive manufacturing in shipbuilding and construction of marine engineering [J]. Shipbuilding of China, 2016, 57(3): 215-225.

[3] 卢振洋,田宏宇,陈树君,等.电弧增材复合制造精度控制研究进展[J].金属学报,2020,56(1):83-98.
LU ZH Y, TIAN H Y, CHEN SH J, et al. Review on precision control technologies of additive manufacturing hybrid subtractive process[J]. Acta Metallurgica Sinica,

- 2020,56(1):83-98.
- [4] 李昂,刘雪峰,俞波,等.金属增材制造技术的关键因素及发展方向[J].工程科学学报,2019,41(2):159-173.
LI ANG, LIU X F, YU B, et al. Key factors and developmental directions with regard to metal additive manufacturing[J]. Chinese Journal of Engineering, 2019, 41(2):159-173.
- [5] 杨平华,高祥熙,梁菁,等.金属增材制造技术发展动向及无损检测研究进展[J].材料工程,2017,45(9):13-21.
YANG P H, GAO X X, LIANG J, et al. Development tread and NDT progress of metal additive manufacturing technique[J]. Journal of materials engineering, 2017, 45(9):13-21.
- [6] RUDLIN J, CERNIGLIA D, HENRIKSON P, et al. Inspection of laser powder deposited layers[EB/OL]. 11th European Conference on Non-Destructive Testing, Czech Republic, 2014 [2014-10-30]. https://www.ndt.net/events/ECNDT2014/app/content/Paper/55_Rudlin.pdf.
- [7] 赵昀,卢保洋,陈树君,等.薄壁结构冷金属过渡增材制造工艺优化[J].西安交通大学学报,2019,53(8):82-89.
ZHAO Y, LU ZH Y, CHEN SH J, et al. Optimization of manufacturing process for thin-walled structures based on cold metal transfer[J]. Journal of Xi'an Jiaotong University, 2019, 53(8):82-89.
- [8] 马波,黄怡洁,张艳喜,等.激光视觉传感系统的电弧增材制造侧表面成形分析[J].中国激光,2019,46(11):123-130.
MA B, HUANG Y J, ZHANG Y X, et al. Side-surface-form analysis of arc additive manufacturing based on laser vision sensing system[J]. Chinese Journal of Lasers, 2019, 46(11):123-130.
- [9] 张元良,张洪潮,赵嘉旭,等.高端机械装备再制造无损检测综述[J].机械工程学报,2013,49(7):80-90.
ZHANG Y L, ZHANG H CH, ZHAO J X, et al. Review of non-destructive testing for remanufacturing of high-end equipment[J]. Journal of Mechanical Engineering, 2013, 49(7):80-90.
- [10] 曾慧敏,高向东,张南峰,等.焊接裂纹无损检测方法[J].热加工工艺,2017,46(11):13-16.
ZENG H M, GAO X D, ZHANG N F, et al. Nondestructive testing methods of welding crack[J]. Hot Working Technology, 2017, 46(11):13-16.
- [11] DENG Y, LIU X, UDPA L. Magneto-optic imaging for aircraft skins inspection: A probability of detection study of simulated and experimental image data[J]. IEEE Transactions of Reliability, 2012, 61(4):901-908.
- [12] CHENG Y H, TIAN L L, YIN C, et al. A magnetic domain spots filtering method with self-adapting threshold value selecting for crack detection based on the MOI[J]. Nonlinear Dynamics, 2016, 86(2):741-750.
- [13] TIAN L L, CHENG Y H, YIN C, et al. Design of the MOI method based on the artificial neural network for crack detection[J]. Neurocomputing, 2017, 226:80-89.
- [14] 高向东,蓝重洲,陈子琴,等.焊接缺陷磁光成像动态检测与识别[J].光学精密工程,2017,25(5):1135-1141.
GAO X D, LAN ZH ZH, CHEN Z Q, et al. Dynamic detection and recognition of welded defects based on magneto-optical imaging[J]. Optics and Precision Engineering, 2017, 25(5):1135-1141.
- [15] GAO X, ZHOU X, WANG C. Skin depth and detection ability of magneto-optical imaging for weld defects in alternating magnetic field[J]. Journal of Manufacturing Systems, 2019, 55:44-55.
- [16] TSE W K, MACDONALD A H. Giant magneto-optical Kerr effect and universal Faraday effect in thin-film topological insulators[J]. Physical Review Letters, 2010, 105(5):057401. 1-057401. 4.
- [17] 高向东,甄任贺.微间隙焊缝磁光成像检测方法[J].焊接学报,2014,35(4):11-14.
GAO X D, ZHEN R H. A method to detect micro weld gap based on magneto-optical imaging[J]. Transactions of the China Welding Institution, 2014, 35(4):11-14.
- [18] 焦敬品,李思源,常予,等.集箱管接头内焊缝表面缺陷识别方法研究[J].仪器仪表学报,2017,38(12):3044-3052.
JIAO J P, LI S Y, CHANG Y, et al. Defect classification of weld surface in header pipe joint[J]. Chinese Journal of Scientific Instrument, 2017, 38(12):3044-3052.
- [19] 闵莉,王哲,董帅.基于 Hough 变换和 GLCM 的端铣表面粗糙度检测[J].控制工程,2019,26(4):645-651.
MIN L, WANG ZH, DONG SH. Surface roughness detection of end milling based on Hough transform and GLCM[J]. Control engineering of China, 2019, 26(4):645-651.

- [20] 董珍一,林莉,孙旭,等.基于 BP 神经网络的超声表面波定量表征金属表层裂纹深度研究[J].仪器仪表学报,2019,40(8):31-38.
DONG ZH Y, LIN L, SUN X, et al. Study on the quantitative characterization of metal surface crack depth through BP neural network combined with SAW technique[J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 31-38.
- [21] 陈科,顾森茂,郑红梅.滚动轴承实时智能故障诊断算法研究[J].电子测量与仪器学报,2018,32(1):66-72.
CHEN K, GU S M, ZHENG H M. Research on real-time intelligent fault diagnosis algorithm for rolling bearing[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 66-72.
- [22] 张淑清,任爽,师荣艳,等.基于多变量气象因子的 LMBP 电力日负荷预测[J].仪器仪表学报,2015,36(7):1646-1652.
ZHANG SH Q, REN SH, SHI R Y, et al. Multiple weather factors-based LMBP method for daily power load forecasting[J]. Chinese Journal of Scientific Instrument, 2015, 36(7): 1646-1652.
- [23] JIAO J Y, ZHAO M, LIN J, et al. A multivariate encoder information based convolutional neural network for intelligent fault diagnosis of planetary gearboxes[J].

Knowledge-Based Systems, 2018(7):1-24.

作者简介



何翔, 2017 年于天津工业大学获得学士学位,现为天津工业大学硕士研究生,主要研究方向为焊接自动化以及磁光成像无损检测。

E-mail: hexiang95@163.com

He Xiang received his B. Sc. degree from Tiangong University in 2017. He is currently a M. Sc. candidate at Tiangong University. His main research interests include welding automation and magneto-optical imaging.



李亮玉(通信作者), 1987 年于太原理工大学获得学士学位, 1992 年和 2000 年于哈尔滨工业大学分别获得硕士学位和博士学位, 现为天津工业大学教授, 主要研究方向为工业机器人技术以及焊接自动化。

E-mail: lilianyu1965@163.com

Li Liangyu (Corresponding author) received his B. Sc. degree from Taiyuan University of Technology in 1987, and received his M. Sc. degree and Ph. D. degree both from Harbin Institute of Technology in 1992 and 2000, respectively. He is currently a professor at Tiangong University. His main research interests include industrial robot technology and welding automation.