DOI: 10.3901/JME.2019.17.061

旋转磁场下焊接缺陷磁光成像检测与强分类研究^{*}

高向东 郑俏俏 王春草

(广东工业大学广东省焊接工程技术研究中心 广州 510006)

摘要: 焊接缺陷的准确检测与分类对保证焊接产品质量十分重要。研究一种旋转磁场激励下焊接缺陷的磁光成像无损检测方法。分析基于法拉第磁光效应的焊接缺陷磁光成像机理,使用有限元法对焊接缺陷的磁场分布进行数值模拟与分析,并获得磁光图像采集的最佳提离度。分析旋转磁场形成机理,使用交叉磁轭产生旋转磁场激励焊件,通过磁光成像传感器获取焊接缺陷磁光图像。采用主成分分析法(Principal component analysis, PCA)对采集的磁光图像列像素灰度特征进行提取与降维,使用AdaBoost算法结合误差反向传播(Back propagation, BP)神经网络建立BP-AdaBoost焊接缺陷强分类模型。试验结果表明,所提出的方法可有效提高45钢焊接缺陷(弧形裂纹、线形裂纹、凹坑、未熔透)的分类精度,焊接缺陷强分类模型的整体识别率达到98.88%,有效实现焊接缺陷的检测与分类。

关键词: 焊接缺陷; 旋转磁场; 磁光检测; 有限元仿真; 主成分分析; BP-AdaBoost强分类器

中图分类号: TG441

Magneto-optical Imaging Detection and Strong Classification of Weld Defects in Rotating Magnetic Field

GAO Xiangdong ZHENG Qiaoqiao WANG Chuncao

(Guangdong Provincial Welding Engineering Technology Research Center,
Guangdong University of Technology, Guangzhou 510006)

Abstract: Accurate detection and classification of weld defects plays an important role in ensuring the quality of welding products. A magneto-optical imaging nondestructive detection method of weld defects under rotating magnetic field excitation is studied. The mechanism of magneto-optical imaging of weld defects based on Faraday magneto-optical effect is analyzed, the magnetic field distribution of weld defects is analyzed by using finite element simulation, and a best lift-off degree is found to collect magneto-optical images. The mechanism of rotating magnetic field is analyzed, a pair of cross yokes is used to generate a rotating magnetic to excite the weldment. Also, a magneto-optical sensor is used to obtain the images of weld defects. Using PCA to extract and reduce the dimension of gray-scale features of column pixels in magneto-optical images, the AdaBoost algorithm combined with BP neural network is used to establish a BP-AdaBoost weld defects classification model. Experimental results show that the proposed method can effectively improve the recognition accuracy of No.45 steel weld joint defects (curve crack, linear crack, sag, less penetration), the overall recognition rate of BP-AdaBoost weld defects classification model reaches 98.88%, and the detection and classification of weld defects can be realized effectively.

Key words: weld defects; rotating magnetic field; magneto-optical detection; finite element simulation; PCA; BP-AdaBoost strong classifier

0 前言

焊接过程中由于多种因素的干扰易造成焊接不稳定现象,产生裂纹、凹坑和未熔透等焊接缺陷,使焊接产品存在质量隐患^[1]。焊接缺陷无损检测方

法主要有超声、射线、磁粉和涡流检测等,这些方法在保证焊接质量方面起到重要作用,但也存在一定的局限性,例如超声和涡流检测难以对焊接缺陷直观成像;射线检测对人体有害;磁粉检测主要限于表面缺陷的检测,且对工件表面条件要求严格等^[2-3]。磁光成像作为一种新的无损检测方法,基于法拉第磁光效应,可对物体表面及亚表面缺陷进行可视化检测。该技术已应用于飞机铆钉和其他合成材料的检测^[4-5]。近年来,磁光成像技术被用于微

^{*} 国家自然科学基金(51675104)、广东省科技计划(2016A010102015)和广东省教育厅创新团队(2017KCXTD010)资助项目。20180925收到初稿,20190301收到修改稿

间隙焊缝的识别,可精确检测间隙小于 0.1 mm 的紧密对接焊缝^[6]。传统磁光检测方法使用直流磁场激励焊件,获得单一磁场方向下的焊接缺陷磁光图像,在一定程度上会丢失一些有用的焊缝信息。文献[7]设计了交流磁场激励下焊接缺陷磁光图像动态采集方法,该技术一定程度上改善了直流磁场激励下焊缝信息丢失的问题,但焊缝信息丢失问题并未完全解决。因此,研究一种旋转磁场激励下焊接缺陷磁光图像动态采集方法。用交叉磁轭产生旋转磁场激励焊件,并通过控制磁光成像采样频率,获取交叉磁场叠加下不同磁场方向的焊接缺陷磁光图像,有效解决焊缝信息丢失的问题。

磁光图像采集前使用有限元法对焊接缺陷处的磁场分布进行仿真与分析,获取磁光图像采集的最佳提离度,并应用于焊接缺陷的磁光成像。在旋转磁场激励下可获得更多的焊缝磁光图像有用信息,同时使用主成分分析法对获取的磁光图像主成分进行提取与降维,构建 BP-AdaBoost 焊接缺陷分类模型,分类精度可达 98.88%,相比 BP 神经网络分类模型,分类精度提高了 3.76%。试验结果表明,所提方法可对焊接过程中的缺陷(弧形裂纹,线形裂纹,凹坑,未熔透)进行有效的分类。

1 磁光成像与磁场仿真研究

1.1 磁光成像原理

图 1 为焊接缺陷磁光成像原理。磁光成像基于法拉第磁光效应^[8],如图 1a 所示,线性偏振光在介质中传播时,若在平行于光传播方向施加一个磁感应强度为 B 的磁场,则该线性偏振光的偏振角将会发生偏转,该偏振角 θ 即为法拉第旋转角,表示为

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

式中,比例系数 V 为费尔德常数; L 为偏振光穿过介质的有效长度。

图 1b 为磁光成像工作原理图,交变磁轭在焊件上产生交替变化的磁场,光源 LED 经过偏振器后生成线性偏振光,经反射镜进入磁光探头,磁光探头由磁光介质及镜面涂层构成,入射线偏振光通过磁光介质后,经由镜面涂层反射再次通过磁光介质,检偏器检测到相应的光信号并由互补金属氧化物半导体 (Complementary metal oxide semiconductor, CMOS) 相机成像。在未施加磁场的情况下,检偏器检测到的光强为

$$I_1 = I_0 \cos^2(2\alpha) \quad (2)$$

在施加磁场的情况下,偏振光顺时针与逆时针

偏转的反射光的强度分别表示为

$$I_2 = I_0 \cos^2 2(\alpha + \theta) \quad (3)$$

$$I_3 = I_0 \cos^2 2(\alpha - \theta) \quad (4)$$

式中, I_0 为入射线偏振光强度; α 为未施加外磁场下固有的线偏振光偏转角度; θ 为施加外磁场下的法拉第旋转角。

(a) 法拉第磁光效应

(b) 磁光成像工作原理图

图 1 焊接缺陷磁光成像原理

1.2 焊接缺陷磁场仿真研究

焊接缺陷的存在使焊件表面产生漏磁场,由磁光成像原理可知,漏磁场是造成偏振光偏转、实现焊接缺陷实时成像的前提条件。为分析焊接缺陷上方漏磁场分布规律,寻找磁光图像采集的最佳提离度,使用有限元法对焊接缺陷磁场分布进行数值仿真。

选择线形裂纹作为焊接缺陷仿真研究对象,仿真过程中采用实体建模方式,其中交变磁铁、线圈以及焊接材料的尺寸参照试验中实际尺寸建立,焊接线形裂纹仿真模型如图 2a 所示,焊件材料为 45 钢,尺寸(长宽高)为 150 mm×50 mm×2 mm,激励线圈材料为铜,分别加载顺时针与逆时针电流 80 A,交变磁铁材料为硅钢片。线形裂纹位于焊件中心位置,尺寸(长宽深)为 10 mm×0.2 mm×1 mm。

焊接线形裂纹仿真结果如图 2b 所示,焊件上磁场以裂纹中点为中心成对称分布,在线形裂纹处产生了明显的畸变现象,即线形裂纹位置产生了一定强度的漏磁场。以线形裂纹中心点为中心,提取左

右 1.5 mm 范围内线形裂纹上方磁场分布三维图, 如图 3 所示, 图 3a 为 z 轴(垂直于焊件方向)磁场分量分布图, 图 3b 为 y 轴(平行于焊件方向)磁场分量分布图。

图 2 焊接线形裂纹磁场仿真模型与结果图

图 3 焊接线形裂纹上方磁场分布三维图

由图 3a 可知, 焊接线形裂纹上方 z 轴磁场分量以线形裂纹中心(3 mm 处)成中心对称分布, 分别产生一个波谷一个波峰, 这表明线形裂纹左右两边分为正负两极, 这与焊接线形裂纹磁光图像以缺陷为中心一半较明亮一半较灰暗的现象相一致。由图 3b 可知, 线形裂纹上方 y 轴磁场分量以线形裂纹中心成轴对称分布, 并在线形裂纹中心产生一个波峰, 表明焊接线形裂纹上方 y 轴磁场分量对磁光图像的影响并不明显。这与磁光传感器只对垂直于焊件的磁场敏感的现象一致, 证明了仿真模型的准确性。

为探究线形裂纹上方磁场分布与提离度的关系, 提取了提离度分别为 0.2 mm、0.4 mm、0.6 mm、0.8 mm 处磁场分布对比图, 如图 4 所示。

图 4 不同提离度下磁场分布对比图

由图 4a 可知, 线形裂纹上方磁场 y 分量幅值随着提离度的增加而减小, 且磁场畸变的宽度也随之减小。由图 4b 可知, 线形裂纹上方磁场 z 分量幅值随着提离度的增加而减小, 且磁场畸变的宽度也随之减小。表明随着提离度的增加, 磁光图像的对比度会相应降低, 且缺陷的过度区域也会相应减少。因此, 试验过程中磁光传感器提离值越小, 磁光图像将会越清晰, 焊接缺陷的特征也越明显。为获得质量较高的磁光图像且保证磁光传感器的安全使用, 磁光传感器最佳提离值设为 0.8 mm 左右。

2 试验方法和方案

2.1 试验方法与试验装置

试验材料为 $150\text{ mm} \times 50\text{ mm} \times 2\text{ mm}$ 的 45 钢, 采用 TIG 焊接平板对接焊, 焊接速度为 90 mm/min , 焊接电流为 90 A 。试验装置主要由三轴运动平台、磁光传感器、旋转磁场发生器、工控机、TIG 焊机 and 图像采集计算机组成, 如图 5a 所示。

(b) 交叉磁轭及其复合磁场示意图

图 5 焊接缺陷磁光成像检测试验装置图

2.2 旋转磁场形成机理

旋转磁场发生器是一种相位差为 90° 的双磁轭磁场发生器, 接入具有一定相位差的正弦交流电, 通过调节电压大小而产生不同强度的复合磁场(旋转磁场), 交叉磁轭以及产生的复合磁场如图 5b 所示。

磁轭 1 以及磁轭 2 上电压表达式为

$$U_1(t) = U_{m1} \sin(2\pi ft) \quad (5)$$

$$U_2(t) = U_{m2} \sin\left(2\pi ft + \frac{\pi}{2}\right) \quad (6)$$

式中, U 为磁轭接入的电压; U_m 为额定电压; f 为电压频率; t 为时间。

磁轭 1 以及磁轭 2 所产成的感应磁场为

$$H_1(t) = H_{m1} \sin(2\pi ft) \quad (7)$$

$$H_2(t) = H_{m2} \sin\left(2\pi ft + \frac{\pi}{2}\right) \quad (8)$$

式中, $H(t)$ 为磁场强度; H_m 为最大磁场强度。

2.3 焊接缺陷磁光图像采集

焊接缺陷磁光成像试验中, 旋转磁场发生器置于焊件上方, 通入大小可调的交流电源以产生旋转磁场励磁焊件, 磁光传感器探头置于焊接正下方采集磁光图像, 提离度为 0.8 mm 。在外加磁场的作用下, 焊接缺陷处的磁场分布将发生变化(缺陷处产生漏磁场), 并引起该处垂直磁场分量的变化, 磁光传感器将磁场变化转换成相应的光强变化, 实现焊接区域的实时成像^[7]。表 1 中列取 5 种焊接过程产生的典型焊接状态磁光图像: 弧形裂纹、线形裂纹、凹坑、未熔透及无缺陷。

表 1 焊接缺陷实物与磁光图

缺陷	弧形裂纹	线形裂纹	未熔透	凹坑	无缺陷
实物图					
第 1 帧					
第 2 帧					
第 3 帧					

3 焊接缺陷磁光图像特征提取

主成分分析法是一种多变量统计分析技术, 能够将多个相关变量转化为少数几个不相关的综合变量, 顺序较前的几个主成分能反映大部分原始变量信息^[9]。在利用 PCA 对数据集提取主成分之前, 需要对数据集进行预处理。磁光图像大小为 $400\text{ 像素} \times 400\text{ 像素}$, 为提高 PCA 处理速度而不损失图像的大部分特征, 将磁光图像按隔点采样进行降维至 $50\text{ 像素} \times 50\text{ 像素}$, 降采样后的图像可以表示为维度 50×50 的矩阵 Y , 对 Y 进行标准化处理生成标准化矩阵 Z 。

$$Z_{ij} = \frac{x_{ij} - \bar{x}_j}{\bar{s}_j} \quad (9)$$

式中, $\bar{y}_j$ 和 $\bar{s}_j$ 分别为第 j 列像素点的均值和均方差, 标准化后的磁光图像为 $Z = (z_1, z_2, \dots, z_{50})$, 满足 $E(Z_j) = 0$ 且 $D(Z_j) = 1 (j = 1, 2, \dots, 50)$ 。

建立标准化磁光图像的相关系数矩阵 $R(r_{ij})_{50 \times 50}$ 。

$$r_{ij} = \frac{\text{cov}(Z_i, Z_j)}{\sqrt{D(Z_i)} \sqrt{D(Z_j)}} \quad (10)$$

由于 $E(Z_j) = 0$ 且 $D(Z_j) = 1 (j = 1, 2, \dots, 50)$ 成立,

相关系数矩阵矩阵 R 可简化为

$$R = \frac{1}{n-1} Z^T Z \quad (11)$$

计算矩阵 R 的特征值($\lambda_1, \lambda_2, \dots, \lambda_{50}$)及其对应的特征矢量($\alpha_1, \alpha_2, \dots, \alpha_{50}$)。磁光图像的列矢量像素灰度的各主成分 X_i 及方差贡献率 P_i 分别表示为

$$X_i = \sum_{k=1}^{50} a_{ik} z_k \quad (12)$$

$$P_i = \frac{\lambda_i}{\sum_{k=1}^{50} \lambda_k} \quad (13)$$

定义前 m 个主成分的累积方差贡献率 P 为

$$P = \frac{\sum_{i=1}^m \lambda_i}{\sum_{j=1}^{50} \lambda_j} \quad (14)$$

式中, λ 为降采样磁光图像相关系数矩阵的特征值, 设定 P 为 95%。

图 6 为一幅经过降采样后焊接缺陷磁光图像的 PCA 方差贡献率比例分布。由图 6 可知, 磁光图像前 2 个主成分的方差贡献率已超过 95%, 由于不同磁光图像的主成分贡献有所不同, 为使磁光图像特征提取较为充分, 将 m 选为 3, 即焊接缺陷磁光图像 BP-AdaBoost 识别模型的输入样本矩阵大小为 $150 \times 2\,500$ 。

图 6 焊接缺陷磁光图像的主成分贡献率

图 7 为提取的 2 500 幅降采样焊接缺陷磁光图像第 21 列、第 31 列、第 41 列像素分布第一个主成分 X_{21} 、 X_{31} 、 X_{41} 、以及第 41 列像素分布的第二个主成分 X_{91} 。由图可知, 不同缺陷类型主成分的特征各不相同, 且同一缺陷类型在不同列的特征也不相同, 这表明, 主成分分析法可以有效提取不同缺陷磁光图像的特征, 一定程度上保证分类模型的准确性。

图 7 焊接缺陷磁光图像主成分分布

4 BP-AdaBoost 强分类模型

4.1 BP-AdaBoost 模型

AdaBoost 算法通过组合弱分类器的方法构建强分类器, 以提高分类精度, 具有很强的自适应性, 随着弱分类器数量的增加, 错误分类的比率可以显著降低^[10]。BP 神经网络是一种由误差反向传播算法进行训练的多层前馈网络^[11]。以 BP 神经网络为弱分类器, 使用 AdaBoost 算法构建焊接缺陷 BP-AdaBoost 强分类模型。该分类模型的具体思想为: 第一次迭代时平均分配训练样本的权重, 运用 BP 神经网络算法迭代运算 T 次, 每次运算后按分类结果更新训练样本的权重分布, 对于分类失败的训练样本赋予较大的权重; 在进行下一次迭代运算时更加关注训练失败样本, 随着迭代次数的增加, 异常样本的数量会显著降低。通过对弱分类器的反复迭代获得分类函数序列, 根据函数分类结果对每个分类函数赋予一个权重, 分类结果越好, 其相应权重越大。经过 T 次迭代后, 最终由分类函数经过加权得到强分类函数, 即 BP-AdaBoost 强分类模型^[12], 如图 8 所示。

焊接缺陷磁光成像 BP-AdaBoost 强分类模型构建分为三步。

(1) 预处理阶段。在 2 500 幅磁光图像试验样本中选择 1 250 幅作为 BP-AdaBoost 网络的训练集, 剩下的 1 250 幅作为测试集, 其中弧形裂纹、线形

图 8 BP-AdaBoost 强分类模型结构图

裂纹、凹坑、未熔透以及无缺陷样本各 250 幅。将 2 500 幅磁光图像经主成分分析处理后的特征矢量作为 BP-AdaBoost 分类模型的输入量 X ，即 $X=(X_{1j}, X_{2j}, \dots, X_{150j})$ ， $(j=1, 2, \dots, 2\ 500)$ 。网络输出类标签分别设为 1、2、3、4、5，即输出量 $Y=(Y_{1j}, Y_{2j}, Y_{3j}, Y_{4j}, Y_{5j})$ ，其中 $Y_{1j}=1, Y_{2j}=2, Y_{3j}=3, Y_{4j}=4, Y_{5j}=5$ ， $(j=1, 2, \dots, 500)$ 。根据训练样本个数初始化训练样本的权值分布(第一次迭代时平均分配训练样本权值)

$$D_i(i) = \frac{1}{n} \quad (15)$$

式中， n 表示训练样本的个数， $i=1, 2, \dots, 1\ 250$ ； t 表示迭代次数，试验中设总迭代次数为 $T=10$ 。

(2) BP 神经网络弱分类器的训练。构建 BP 神经网络弱分类器，网络训练误差设为 0.004，学习速率设为 0.01，隐含层个数设置为 6。使用具有权值分布 D_t 的训练样本集进行弱分类器的训练，将网络预测输出记为 y_t ，令 $y_t = \text{round}(y_t)$ ，其中 round 为取整函数，将预测输出转变成期望输出的相同形式，用于计算分类误差。

计算弱分类器的分类误差 e_t 。

$$e_t = \sum_{i=1}^n D_t(i)(y_t \neq h) \quad (16)$$

式中， h 为网络训练期望输出。

根据弱分类器误差 e_t 计算弱分类器权重 α_t 。

$$\alpha_t = \frac{1}{2} \ln \frac{1-e_t}{e_t} \quad (17)$$

误差越小，表明弱分类器分类效果越好，其相应权重越大。

更新训练样本集权值分布，分类失败的样本赋予较大的权重，分类成功的样本赋予较小的权重，新的权值分布应用于下一轮的迭代。

$$D_{t+1}(i) = \begin{cases} \frac{D_t(i)}{z_t} \exp(-\alpha_t) & y_t(x_i) = h_t \\ \frac{D_t(i)}{z_t} \exp(\alpha_t) & y_t(x_i) \neq h_t \end{cases} \quad (18)$$

式中， z_t 是归一化因子，使所有样本对应的权值和为 1。

(3) 根据弱分类器权重将 m 个弱分类器组合成最终的强分类器，即

$$f(x) = \text{round} \sum_{m=1}^T \alpha_t y_t(x) \quad (19)$$

4.2 试验结果与分析

表 2 和表 3 分别是使用 BP 神经网络与 BP-AdaBoost 强分类器分类结果。由表 2 可知，BP 神经网络分类总精度为 95.12%，在 1 250 幅测试图像中，共有 61 幅图像被错分。250 幅弧形裂纹测试图像中，20 幅图像被错分为线形裂纹，1 幅未被检出；250 幅线形裂纹测试图像中，5 幅图像被错分为弧形裂纹，2 幅图像被错分为凹坑；250 幅凹坑测试图像中，13 幅图像被错分为未熔透，5 幅被错分为线形裂纹；250 幅未熔透测试图像中，7 幅图像被错分为凹坑；250 幅无缺陷测试图像中，8 幅图像被错分为未熔透。

表 2 BP 神经网络训练结果

缺陷类型	样本数量	训练集	测试集	结果	精度(%)
弧形裂纹	500	250	250	229	91.6
线形裂纹	500	250	250	243	97.2
凹坑	500	250	250	232	92.8
未熔透	500	250	250	243	97.2
无缺陷	500	250	250	242	96.8
总计	2 500	1 250	1 250	1 189	95.12

由表 3 可知，BP-AdaBoost 强分类器总分类精度可达 98.88%，在 1 250 幅测试图像中，只有 13 幅被错分。250 幅弧形裂纹测试图像中，3 幅图像被错分为线形裂纹；250 幅线形裂纹测试图像中，3 幅图像被错分为凹坑；250 幅凹坑测试图像中，6 幅图像被错分为未熔透；250 幅未熔透测试图像中，2 幅图像被错分为凹坑；无缺陷的识别率为 100%。相比于 BP 神经网络，使用 AdaBoost 算法构建的 BP-AdaBoost 强分类器模型有效提高了焊接缺陷的分类精度。

表 3 BP-AdaBoost 神经网络训练结果

缺陷类型	样本数量	训练集	测试集	结果	精度(%)
弧形裂纹	500	250	250	247	98.8
线形裂纹	500	250	250	247	98.8
凹坑	500	250	250	244	97.6
未熔透	500	250	250	248	99.2
无缺陷	500	250	250	250	100
总计	2 500	1 250	1 250	1 236	98.88

5 结论

(1) 与恒定磁场下焊接缺陷检测方法相比，旋

转磁场激励下焊接缺陷无损检测方法采集的磁光图像包含了更多的焊缝磁信息, 更有效地解决了磁场信息丢失的问题。

(2) 使用有限元法对焊接线形裂纹磁场分布进行数值模拟, 通过探究磁场分布规律与提离度的关系, 可获得磁光成像试验的最佳提离度, 采集清晰且特征明显的磁光图像。

(3) 主成分分析法可有效提取磁光图像列像素特征。以 BP 神经网络为弱分类器, 使用 AdaBoost 算法构建的焊接缺陷磁光图像 BP-AdaBoost 强分类模型能对焊接缺陷进行精确地分类, 相对于 BP 神经网络模型, 有效提高了焊接缺陷磁光图像的分类精度。

参 考 文 献

- [1] BOARETTO N, CENTENO T M. Automated detection of welding defects in pipelines from radiographic images [J]. NDT & E International, 2017, 86: 7-13.
- [2] TABATABAEIPOU M, HETTLER J, DELRUE S, et al. Non-destructive ultrasonic examination of root defects in friction stir welded butt-joints[J]. NDT & E International, 2016, 80: 23-34.
- [3] 迟大钊, 刚铁, 姚英学. 基于非线性小波收缩的超声信号缺陷识别方法[J]. 机械工程学报, 2011, 47(18): 1-6.
CHI Dazhao, GANG Tie, YAO Yingxue. Non-linear wavelet shrinkage based method for defect detection in ultrasonic signal[J]. Journal of Mechanical Engineering, 2011, 47(18): 1-6.
- [4] FITZPATRICK G L, THOME D K, SKAUGSET R L, et al. Magneto-optic/eddy current imaging of aging aircraft: A new NDI technique[J]. Materials Evaluation, 1993, 51: 12(12): 1402-1407.
- [5] RADTKE U, ZIELKE R, RADEMACHER H G, et al. Application of magneto-optical method for real-time visualization of eddy currents with high spatial resolution for nondestructive testing[J]. Optics & Lasers in Engineering, 2001, 36(3): 251-268.
- [6] 高向东, 莫玲, 萧振林, 等. 微间隙焊缝磁光成像卡尔曼滤波跟踪算法[J]. 机械工程学报, 2016, 52(4): 67-72.
GAO Xiangdong, MO Ling, XIAO Zhenlin, et al. Micro-gap weld tracking based on Kalman filtering of maneto-optical images[J]. Journal of Mechanical Engineering, 2016, 52(4): 67-72.
- [7] GAO X D, LAN C Z, YOU D Y, et al. Weldment nondestructive testing using magneto-optical imaging induced by alternating magnetic field[J]. Journal of Nondestructive Evaluation, 2017, 36(3): 55.
- [8] RICHERT H, SCHMIDT H, LINDMNER S, et al. Dynamic magneto-optical imaging of domains in grain-oriented electrical steel[J]. Steel Research International, 2016, 87(2): 232-240.
- [9] JIANG Q, YAN X, HUANG B. Performance-driven distributed PCA process monitoring based on fault-relevant variable selection and bayesian inference[J]. IEEE Transactions on Industrial Electronics, 2015, 63(1): 377-386.
- [10] VENKATESH T, JAIN T. AdaBoost classifiers for phasor measurements based security assessment of power systems[J]. IET Generation Transmission & Distribution, 2018, 12(8): 1747-1755.
- [11] 行鸿彦, 邹水平, 徐伟, 等. 基于 PSO-BP 神经网络的度传感器温度补偿[J]. 传感技术学报, 2015, 28(6): 864-869.
XING Hongyan, ZHOU Shuiping, XU Wei, et al. Temperature compensation of degree sensor based on PSO-BP neural network[J]. Chinese Journal of Sensors and Actuators, 2015, 28(6): 864-869.
- [12] WU H, ZOU B J, ZHAO Y Q, et al. An automatic video text detection method based on BP-adaboost[J]. Multimedia Tools & Applications, 2016, 75(13): 1-24.

作者简介: 高向东(通信作者), 男, 1963 年出生, 教授, 博士研究生导师。主要研究方向为焊接自动化。

E-mail: gaofd666@126.com

郑俏俏, 女, 1993 年出生, 硕士研究生。主要研究方向为无损检测。

E-mail: 13246883775@163.com

王春草, 女, 1993 年出生, 硕士研究生。主要研究方向为无损检测。

E-mail: 18680529185@163.com