

基于二维阻抗特征的管道环焊缝缺陷涡流检测*

梁子千¹, 玄文博², 王 婷², 封 皓¹, 曾周末¹

(1. 天津大学 精密测试技术及仪器国家重点实验室 天津 300072;

2. 中国石油管道科技研究中心 中国石油天然气集团公司 油气储运重点实验室 廊坊 065000)

摘 要:油气长输管道环焊缝处缺陷对管道安全的危害性巨大,管道缺陷造成的事故大部分发生在管道焊接处。目前,对管道进行无损检测(NTD)是预测事故隐患、保证管道安全运行的常用手段,但传统无损检测方法无法有效识别位于环焊缝处等表面形貌复杂位置的缺陷。为了克服传统检测方法的缺点,提出一种基于图像处理 and 神经网络的嵌入式涡流检测系统。从涡流信号合成的二维阻抗图入手,对其进行霍夫变换和轮廓提取得到特征分量,使用类内散布矩阵筛选分类特性好的特征用以训练基于 FPGA 加速的神经网络,实现在焊缝基底噪声较大的情况下对缺陷的自动分类与识别。实验结果表明,本系统可以有效识别位于环焊缝处等形貌复杂位置的缺陷信号,正确率可达 92%,且系统体积小、功耗低,适合应用于管道内检测环境。

关键词:管道内表面;环焊缝缺陷;涡流无损检测;图像处理;神经网络

中图分类号: TG115.28 文献标识码: A 国家标准学科分类代码: 460.40

Eddy current NDT for the cracks of girth welds of pipes based on 2D impedance characteristics

Liang Ziqian¹, Xuan Wenbo², Wang Ting², Feng Hao¹, Zeng Zhoumo¹

(1. State Key Laboratory of Precision Measurement Technology and Instrument, Tianjin University, Tianjin 300072, China; 2. CNPC Key Laboratory of Oil & Gas Storage and Transportation, PetroChina Pipeline R&D Center, Langfang 065000, China)

Abstract: Cracks of girth welds of long-distance oil and gas pipeline bring extremely harm to the pipeline safety, and most of accidents caused by pipeline defects occurred at pipeline welds. So far non destructive testing (NDT) is a common method for predicting potential risk and ensuring the safe operation of pipeline, but traditional NDT methods can't effectively identify the defects lying in girth welds or other complex surface. In order to overcome the disadvantages of traditional methods, an embedded eddy current testing system is presented based on image processing and neural network. Hough transform and contour extraction are used to extract the features from 2D impedance image composed of eddy current signals. Features with good classification characteristics are selected by the within class scatter matrix to train neural network based on FPGA speeding up. Automatic cracks of girth welds classification and identification is realized with a heavy weld noise floor. Experimental results show that this system can effectively identify the defect signals lying in weld of the cylinder or other complex surface. The accuracy of the system is as high as 92%, and has lower power consumption and smaller size, which is suitable for pipeline inner inspection.

Keywords: inner surface of pipes; cracks of girth welds; eddy current non destructive testing (NDT); image-processing; neural network

0 引 言

随着经济、社会的高速发展,管道运输成为一种高效且经济的物料运输方式。由于管道运输行业的大规模发

展、管道里程的不断增长,如何保证管道安全运行成为越来越重要的问题。针对管道缺陷的定期检测以及安全评估对预测和及时消除管道的安全隐患有着重要的意义^[1]。

由于管道一般为金属且长期处于运行状态,易受到

潮湿土壤、内部电解质及运送物料的侵蚀,导致出现裂纹、腐蚀、形变等缺陷从而引起事故^[2]。受到施工水平的限制、焊接质量控制不当等问题的影响,环焊缝是管道最为薄弱的部位,环焊缝开裂是管道失效的主要形式,其开裂长度大、泄露量大,对环境与周围人员危害性较大。美国管道与危险材料安全协会公布的2010~2012年失效事故中,仅环焊缝开裂导致的事故就高达8起。而据王婷等人^[3]调研可知,目前国内外油气管道开裂事故致因多为管道内表面环焊缝处出现裂纹。而环焊缝处表面形貌复杂,不易检测,所以如何检测管道内表面缺陷,尤其是叠加在环焊缝处的缺陷成为管道无损检测的重点与难点。

目前常用的管道内检测方法是利用搭载无损检测(non destructive testing, NDT)设备的清管器进行检测^[4],而目前较为成熟的无损检测设备多以漏磁法^[5-6](magnetic flux leakage testing, MFT)和电磁超声法(electromagnetic acoustic transducer, EMAT)为理论基础。其中漏磁检测法精度较低,不能检测较小尺寸的缺陷;电磁超声法抗干扰能力差,信号质量低^[7],无法区分环焊缝处缺陷;这两种方法均很难检测环焊缝处缺陷。涡流无损检测技术(eddy current testing, ET)具有检测灵敏度高、精度高、非接触、易实现自动化检测等优点,在管道内表面检测领域得到了广泛的应用^[8-9],但少有对管道内表面焊缝的检测应用。而在焊缝检测领域,林俊明等人^[10]利用电流扰动探头对焊缝进行检测,检测人员根据检测波形进行评估,该法主要依赖检测人员经验,发生误判的几率较大;Hench K. W. 等人^[11]利用常规涡流对激光焊缝进行质量评估,但很难实现在线检测以及其他种类焊缝检测;加拿大 Eddyfi 公司研制的涡流阵列探头对常规缺陷的检测较为出色,但经实测其对环焊缝处缺陷检测效果不理想。

可以看出,虽然涡流无损检测近年来发展迅速,但由于管道内环焊缝的特殊性,鲜有在检测其缺陷上的应用。

本文利用涡流检测技术,提出了一种基于图像处理和神经网络的嵌入式管道内表面环焊缝缺陷识别方法。将涡流信号合成阻抗图,利用类内散布矩阵选取分类效果好的阻抗图几何特征并通过图像处理方法提取,结合基于FPGA的识别算法实现管道环焊缝处缺陷的分辨与识别。本法可信度高、识别速度快、功耗低,实现了一种嵌入式涡流检测方法,易于实现在线检测且易于搭载于管道内检测器上,而且在识别环焊缝处缺陷时依旧保持高正确率。

1 涡流检测原理及管道内表面缺陷涡流原始信号表征


1.1 涡流检测原理

涡流无损检测以电磁感应原理为基础,利用通电线圈在导电材料表面感应出涡流;涡流探头在试件表面移动,当遇到缺陷或者导电材料的尺寸、材质变化,涡流场发生相应变化,从而引起线圈阻抗发生变化。测量线圈阻抗的变化量就能得到试件表面是否存在缺陷等信息^[12]。


1.2 涡流检测原始信号表征

目前,大部分管道涡流检测设备通过对涡流检测的原始信号进行分析^[13],实现缺陷信号的识别;但管道内表面环焊缝处焊料本身就存在较复杂的材质与尺寸变化,在焊缝的基底噪声之上对缺陷进行识别难度较大,信号分析较为复杂。

如图1所示,图1(a)所示为一个存在缺陷的环焊缝的涡流检测原始信号,图1(b)所示为一个环焊缝的涡流检测原始信号,两者均为管道切片实测信号,管厚13 mm,缺陷深度为管厚的20%,开口宽度约0.5 mm。可以看出,两者信号表现形式类似,在焊缝处信号均出现较大跳变,且表现形式类似,所以从原始信号中很难分辨焊缝处是否存在缺陷。



(a) 环焊缝处缺陷的原始信号
(a) Original signals of defect lying in girth weld



(b) 环焊缝的原始信号
(b) Original signal of girth weld

图1 原始信号对比

Fig.1 Contrast of original signals

2 基于阻抗图的涡流检测信号特征提取

本文使用绝对式探头进行涡流无损检测。首先采用正交锁相技术分解涡流检测原始信号^[14],将分解后的信号合成反映线圈阻抗变化的二维阻抗图,通过图像处理算法提取阻抗图的特征分量,利用焊料与缺陷对探头造成的阻抗变化不同对环焊缝处的缺陷进行识别。实验系统如图2所示。本文所有测试试件均为 APISPEC5LX70 型管材的管道切片。





图2 实验系统实物

Fig.2 Physical map of experiment system


2.1 分解涡流原始信号合成阻抗图

由于合成阻抗图需要得到涡流信号的实部、虚部分量,而且涡流探头原始信号能量较小,信噪比较低,所以采用锁相放大器进行信号提取与分解。这样不仅得到反映线圈阻抗的实部与虚部信号,而且大大提高了检测信号的信噪比^[15-16]。图3所示为环焊缝处存在缺陷的管道试件实测信号,管厚 13 mm,缺陷深度为管厚的 80%,开口宽度约 0.5 mm。经锁相放大器分解得实测信号实部分量如图3(a)所示,虚部分量如图3(b)所示。


以实部信号为横坐标,虚部信号为纵坐标,可以得到反映探头阻抗变化的二维轨迹图,以下简称阻抗图。环焊缝处缺陷阻抗图如图3(c)所示。可以看出,环焊缝处缺陷阻抗图是由两簇斜率不同直线组成的图形。经过



(a) 环焊缝处缺陷实部信号
(a) Real part of defect signals at girth weld



(b) 环焊缝处缺陷虚部信号
(b) Image part of defect signals at girth weld



(c) 环焊缝处缺陷阻抗图
(c) Impedance cardiogram of defect at girth weld

图3 环焊缝处缺陷原始信号及阻抗图
Fig.3 Original signal and impedance cardiogram of defect at girth weld

测试发现不同缺陷类型、不同尺寸的缺陷产生的二维阻抗图存在不同的几何特征,典型环焊缝缺陷阻抗图如图4所示。可以看出,环焊缝处缺陷阻抗图与环焊缝阻抗图有较大几何特征差异。所以,提取阻抗图中的何种几何特征参数为神经网络输入参数是整个识别系统的关键问题。




图4 典型环焊缝及其缺陷阻抗图
Fig. 4 Impedance cardiogram of typical defect at girth weld and girth weld

2.2 利用散布矩阵选取阻抗图的特征分量

由于待识别信号采用阻抗图表现形式,所以特征值为阻抗图几何参数。利用散布矩阵评价方法^[17]对阻抗图几何特征进行评价与选择。

散布矩阵是用来估计多维正态分布协方差的统计量。类内散布矩阵定义为类内方差的大小。

$$S_w = \sum_{i=1}^M P_i \Sigma_i \quad (1)$$

式中: Σ_i 是类的协方差矩阵。

$$\Sigma_i = E[(x - \mu_i)(x - \mu_i)^T] \quad (2)$$

$P_i \approx \frac{n_i}{N}$ 是 w_i 的先验概率,样本 N 中属于类 w_i 的样本数为 n_i 。那么类间散布矩阵可以表示为:

$$S_b = \sum_{i=1}^M P_i (\mu_i - \mu_0)(\mu_i - \mu_0)^T \quad (3)$$

式中: $\mu = \sum_{i=1}^M P_i \mu_i$ 。 $\{S_b\}$ 能够衡量全局均值以及每一类样本平均值的测度。混合散布矩阵是所有类均值的协方差矩阵。混合散布矩阵是类内散布矩阵和类间散布矩阵之和,表示如下:

$$S_m = E[(x - \mu_0)(x - \mu_0)^T] = S_w + S_b \quad (4)$$

$\{S_m\}$ 为全局方差的和,通过上述定义可以得到准则值:

$$J_1 = \frac{\text{tr}\{S_m\}}{\text{tr}\{S_w\}} \quad (5)$$

可以看出,若某一特征值类内方差较小,也就是每一类在均值附近都比较紧密,不同的类相距较远,分类效果好,准则值较大;而相反的,如果特征的准则值比较小,说明该特征对于分类识别的作用比较小。在实际应用中通常使用以下两个准则值:

$$J_2 = \frac{|S_m|}{|S_w|} = |S_w^{-1} S_m| \quad (6)$$

$$J_3 = \text{tr}\{S_w^{-1} S_m\} \quad (7)$$

本文选取了10个阻抗图几何特征进行散布矩阵准则值计算,准则值计算结果如图5所示。图5中横坐标的1~10分别代表阻抗图中拟合直线斜率期望、闭合曲线面积期望、闭合曲线面积方差、拟合直线斜率方差、超过阈值面积的闭合曲线个数、闭合曲线长度期望、闭合曲线长度方差、阻抗图拟合直线个数、拟合直线斜率最大差值、闭合曲线个数。




图5 几何特征准则值

Fig. 5 Criterion value of geometric characteristic

当选择5个准则值最大的特征分量作为阻抗图特征参数时,数据集分类效果即可达到满意效果。按照图5选择的特征分量如下:阻抗图拟合直线斜率期望、拟合直线斜率方差、超过阈值面积的闭合曲线个数、闭合曲线包围面积期望、闭合曲线包围面积方差。本文使用霍夫变换和轮廓提取算法提取阻抗图中的特征参数。

2.3 通过图像处理算法提取阻抗图特征

霍夫变换^[18]是一种在二值化图像中寻找直线、圆形以及其他简单形状的快速算法。图像空间中的直线标准参数方程为:

$$\rho = x \cos \theta + y \sin \theta \quad (8)$$

式中: ρ 为 l 相对于原点的距离,为 l 与 x 轴的交角。那么,根据式(8),直线 l 上不同的点在参数空间中表现为相交于一点的正弦曲线。若确定了交点,即局部最大值,就实现了线变换。记大小为 $N \times N$ 的二值化图像位于 (x_i, y_i) 的像素灰度值为 $I(x_i, y_i)$,而在参数空间中, θ 在 $[0, \pi)$ 间均匀的取 M 个离散值,的采样个数为 Q ,那么标准霍夫变换可表示为:

$$H(d_q, \theta_m) = \sum_{i,j=0}^{N-1} I(x_i, y_j) \Big|_{d_q - 1/2 \leq x_i \cos \theta_m + y_j \sin \theta_m \leq d_q + 1/2} \quad (9)$$

$m = 0, 1, \dots, M - 1; \quad q = 0, 1, \dots, Q - 1$

轮廓提取算法^[19]即掏空内部点法。若输入二值化图中有一点为黑,且其周围相邻点均为黑色,则认为该点为

内部点,将该点掏空。掏空所有内部点就可得到轮廓线。

阻抗图几何特征量提取过程如图6所示。由于原始图片中可能存在噪声或者个别错误数据点,所以先采用开运算与闭运算结合的方法进行形态学滤波^[20]。一般开运算可以去除独立的小点与毛刺,闭运算可以填充小孔,保持图像的位置与形状不变。图3(c)经过特征提取算法得到的特征参数如表1所示。

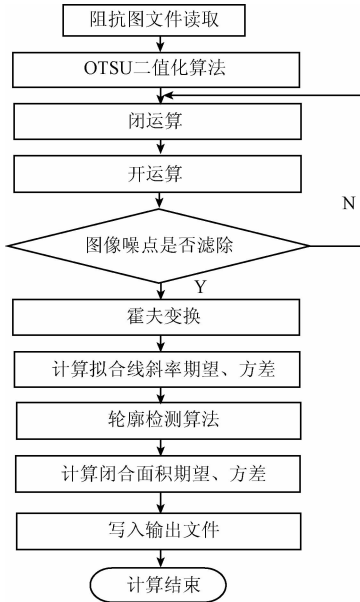


图6 阻抗图特征量提取流程

Fig.6 Flowchart of extracting feature parameters of impedance cardiogram

表1 环焊缝处缺陷的阻抗图特征参数

Table 1 Feature parameters of impedance cardiogram of defect at girth weld

| 参数 | 超过阈值的 闭合面积个数 | 闭合面 积期望 | 闭合面 积方差 | 拟合直线 斜率期望 | 拟合直线 斜率方差 |
|-----|-----------------|------------|------------|--------------|--------------|
| 参数值 | 1 | 385 | 0 | 19.38 | 160.38 |

3 基于BP神经网络的缺陷识别

神经网络是由具有适应性的简单单元组成的广泛并行互联网络,能够模拟生物神经系统对真实世界物体所做出的交互反应。误差逆传播(error back propagation, BP)算法是神经网络的杰出代表,是迄今为止最为成功的神经网络学习算法^[21-22]。

本文采用基于梯度下降策略的BP算法,不需要计算二次导数但仍具有二次收敛特性,收敛速度较快,计算量较小。由2.2节可知,BP神经网络的输入为5个由图像处理算法提取的阻抗图特征参数,且均为实数;输出为被

测试件存在缺陷概率,为一个(0,1)间的实数,综上所述,设置输入层节点数为5,输出层节点数为1。传递函数又称激励函数,由于本文BP网络输出为概率值,而Sigmoid^[23]函数可以将输入(范围为实数集)映射到0~1内,且可微,非常适合于神经网络反向传播算法,所以传递函数选择Sigmoid函数。

对于学习速率,若其过大,网络调整幅度增大,可能会造成震荡或者不收敛问题;若其过小,那么调整幅度小,收敛慢,训练时间加长。本文采用自适应学习速率^[24],算法如下:

$$\eta(n) \begin{cases} a \cdot \eta(n-1), & E(n) < E(n-1) \\ b \cdot \eta(n-1), & E(n) > cE(n-1) \end{cases} \quad (10)$$

式中: $\eta(n)$ 为迭代第 n 次的学习速率, $E(n)$ 为迭代第 n 次的输出误差。 a 的范围是(1,2), b 的范围是(0,1), c 的范围是(1,1.1)。本文选择 $a=1.5$, $b=0.5$, $c=1$ 。由于初始误差较大,所以选择初始学习速率 $\eta(0)=0.5$ 。

对于隐含层层数与隐含层节点数的选择,目前没有确定的定理可循。理论证明,一个只有单隐含层的3层BP网络可以逼近任何函数^[25],增加隐含层数会需要更多的训练样本与训练时间,所以本文采用单隐含层的3层BP神经网络。对于隐含层节点数的选择,实验表明,若隐含层结点数过少,网络不能具有必要的学习能力和信息处理能力。反之,若过多,不仅会大大增加网络结构的复杂性,网络在学习过程中更易陷入局部极小点,而且会使网络的学习速度变得很慢^[26]。根据经验,选择隐含层节点数为13~17个。经过反复试验对比训练误差,发现隐含层节点数为15个时,BP网络在大训练集下训练误差最小,故选择隐含层节点数为15个。训练结果如表2所示。

表2 不同隐含层节点数的网络训练结果

Table 2 Training results of different hidden nodes network

| 网络结构 (输入×隐含×输出) | 隐含层 节点数 | 训练次数 | 均方误差 |
|--------------------|------------|--------|----------|
| 5×13×1 | 13 | 5 000 | 0.007 46 |
| | | 10 000 | 0.007 17 |
| | | 20 000 | 0.007 09 |
| 5×14×1 | 14 | 5 000 | 0.006 76 |
| | | 10 000 | 0.006 59 |
| | | 20 000 | 0.006 44 |
| 5×15×1 | 15 | 5 000 | 0.007 06 |
| | | 10 000 | 0.006 09 |
| | | 20 000 | 0.005 46 |
| 5×16×1 | 16 | 5 000 | 0.006 80 |
| | | 10 000 | 0.006 62 |
| | | 20 000 | 0.006 43 |
| 5×17×1 | 17 | 5 000 | 0.007 05 |
| | | 10 000 | 0.006 51 |
| | | 20 000 | 0.006 27 |

选取 50 个管道试件获取涡流数据并合成阻抗图,其中包含环焊缝处缺陷等复杂形貌处缺陷。利用图像处理

算法提取阻抗图特征值作为测试数据,输入神经网络进行识别,识别结果如表 3 所示。

表 3 神经网络预测结果
Table 3 Results predicted by neural network

| 编号 | 输入变量 | | | | | 输出结果 | | 实际结果 | 正确与否 |
|----|--------|--------|---------|--------|---------|------------------------|--|------|------|
| | 闭合面积个数 | 闭合面积期望 | 闭合面积方差 | 拟合直线期望 | 拟合直线方差 | (<0.5 视为 0, >0.5 视为 1) | | | |
| 1 | 2 | 139 | 0 | -4.27 | 852.06 | 0.999 | | 1 | 是 |
| 2 | 1 | 762 | 0 | 0.55 | 11.39 | 0.408 | | 1 | 否 |
| 3 | 0 | 0 | 0 | -3.47 | 108.39 | 0.981 | | 1 | 是 |
| 4 | 1 | 283 | 0 | -8.76 | 32.94 | 0.976 | | 1 | 是 |
| 5 | 1 | 190 | 0 | 24.07 | 4.44 | 0.408 | | 0 | 是 |
| 6 | 2 | 547.75 | 176.190 | 16.53 | 552.45 | 0.999 | | 1 | 是 |
| 7 | 2 | 135.5 | 210.25 | 26.02 | 1.68 | 0.325 | | 0 | 是 |
| 8 | 2 | 305.25 | 3.06 | -12.47 | 813.69 | 1 | | 1 | 是 |
| 9 | 2 | 242.5 | 15.129 | -12.60 | 1370.56 | 0.997 | | 1 | 是 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | | ⋮ | ⋮ |
| 50 | 0 | 0 | 0 | 29.9 | 0.09 | 0.045 | | 0 | 是 |

50 个测试数据中有 4 个判断错误,正确率达到 92%。其中有 10 组为无缺陷的环焊缝信号,30 组为环焊缝处存在缺陷信号,这 40 组数据中有 3 组判断错误,正确率达到了 92.5%,证明该识别系统可以有效识别环焊缝处缺陷信号,克服了传统涡流检测设备难以正确识别位于管道环焊缝处等形貌复杂位置缺陷的缺点。

4 基于 FPGA 加速的缺陷识别算法

目前,神经网络的硬件加速在国内外都得到了广泛的研究。由于神经网络运算的并行程度很高,所以目前的硬件加速手段主要为 GPU 加速与 FPGA 加速^[27]。GPU 的优点是通用性较高,开发较为简单,但功耗较高;而利用 FPGA 开发不仅可以达到较高的性能,而且功耗很低,灵活性很高,可以根据不同的应用环境配置为不同的专用神经网络芯片。故本文使用 FPGA 实现 BP 神经网络,其较 CPU 运行速度更高,功耗更小^[28]。

现在使用相同的训练集分别测试 FPGA 神经网络算法与 CPU 神经网络算法的运行速度与功耗。CPU 与 FPGA 计算时间与功耗对比结果如表 4 所示。可以看出相较于 CPU, FPGA 计算速度提升了 30 倍左右,而功率却只有 CPU 的 1/10。

表 4 CPU 与 FPGA 训练时间与功耗对比
Table 4 Comparison of CPU and FPGA training time and power consumption

| 数据集 | 阈值 误差 | Intel Pentium G2020 | | EP4CE15F23C8N | |
|-----|----------|---------------------|------|---------------|-------|
| | | 计算 时间/ms | 功耗/W | 计算 时间/ms | 功耗/mW |
| 1 | | 36 | 35 | 0.98 | 339 |
| 2 | 0.000 1 | 28 | 32 | 0.96 | 345 |
| 3 | | 34 | 37 | 1.1 | 325 |

5 结 论

本文针对管道内表面环焊缝处缺陷涡流检测与识别问题,提出了一种采用图像处理与 BP 神经网络结合的嵌入式系统。本系统从涡流检测信号的二维阻抗图入手,首先利用类内散布矩阵选择有较好分类效果的阻抗图几何特征参数,然后利用图像处理算法提取筛选出的阻抗图特征参数作为训练集;最后使用特征参数训练集训练 BP 神经网络,实现了缺陷信号的自动识别。识别正确率较高,能够有效识别管道内表面环焊缝处缺陷信号,为管道无损检测方法提供了新思路,克服了常规管道内检测无法有效检测环焊缝处缺陷的缺点。设计基于 FPGA 实现嵌入式缺陷识别算法,在较低的功耗下达到了远高于

常规 CPU 的计算性能,实现了基于嵌入式的管道内表面环焊缝处缺陷涡流检测与识别,为系统应用于管道内检测器提供了基础。

参考文献

- [1] AHAMMED M. Probabilistic estimation of remaining life of a pipeline in the presence of active corrosion defects [J]. *International Journal of Pressure Vessels & Piping*, 1998, 75(4):321-329.
- [2] 詹湘琳. 超声相控阵油气管道环焊缝缺陷检测技术的研究[D]. 天津:天津大学, 2007.
ZHAN X L. Research on flaw detection technology of ultrasonic phased array for Oil and Gas pipeline girth welds [D]. Tianjin: Tianjin University, 2007.
- [3] 王婷, 杨辉, 冯庆善, 等. 油气管道环焊缝缺陷内检测技术现状与展望[J]. *油气储运*, 2015, 34(7):694-698.
WANG T, YANG H, FENG Q SH, et al. Current status and prospect of inline inspection technologies for defects in girth weld of oil and gas pipeline [J]. *Oil & Gas Storage and Transportation*, 2015, 34(7):694-698.
- [4] 周燕, 董怀荣, 周志刚, 等. 油气管道内检测技术的发展[J]. *石油机械*, 2011, 39(3):74-77.
ZHOU Y, DONG H R, ZHOU ZH G, et al. The development of oil and gas pipeline detection technology [J]. *China Petroleum Machinery*, 2011, 39(3):74-77.
- [5] ATHERTON D L. Magnetic inspection is key to ensuring safe pipelines [J]. *NDT & E International*, 1997, 87(32):40.
- [6] 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 L J, GENG H, GAO S W. Magnetic flux leakage internal detection technology of the long distance oil pipeline [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(8):1736-1746.
- [7] 李育忠, 郑宏丽, 贾世民, 等. 国内外油气管道检测监测技术发展现状[J]. *石油科技论坛*, 2012, 31(2):30-35.
LI Y ZH, ZHENG H L, JIA SH M, et al. The current situation of the development of Oil & Gas pipeline detection monitoring technology at home and aboard [J]. *Oil Forum*, 2012, 31(2):30-35.
- [8] 杨理践, 郭晓婷, 高松巍. 管道内表面缺陷的涡流检测方法[J]. *仪表技术与传感器*, 2014(10):78-81.
YANG L J, GUO X T, GAO S W. Method of the eddy current testing to pipeline inner surface defects [J]. *Instrument Technique and Sensor*, 2014(10):78-81.
- [9] JANOUSEK L, GOMBARSKA D, CAPOVA K. Advances in eddy-current non-destructive evaluation [J]. *Advances in Electrical & Electronic Engineering*, 2008, 7(1-2):318-321.
- [10] 林俊明, 张开良, 林发炳, 等. 焊缝裂纹快速检测与深度测量[J]. *无损探伤*, 2003, 27(6):35-38.
LING J M, ZHANG K L, LING F B, et al. Rapid detection and depth measurement of weld cracks [J]. *NDT*, 2003, 27(6):35-38.
- [11] HENCH K W, CHRISTENSEN W, LOPEZ A A, et al. An optimization technique for the evaluation of eddy current inspection data to determine weld quality [C]. *IEEE International Conference on Systems, Man and Cybernetics*, 2006:1535-1539.
- [12] 冯婷婷. 双频涡流无损检测关键技术研究[D]. 长沙:国防科学技术大学, 2008.
FENG T T. The key technology research of the dual-frequency eddy current testing [D]. Changsha: National University of Defense Technology, 2008.
- [13] LU Y, BOWLER J R, THEODOULIDIS T P. An analytical model of a ferrite-cored inductor used as an eddy current probe [J]. *Journal of Applied Physics*, 2012, 111(10):3455.
- [14] 范孟豹, 黄平捷, 周泽魁. 涡流检测中阻抗信号的分解技术[J]. *仪器仪表学报*, 2005, 26(增刊2):725-726.
FAN M B, HUANG P J, ZHOU Z K. The decomposition technique of impedance signal in eddy current testing [J]. *Chinese Journal of Scientific Instrument*, 2006, 26(Suppl. 2):725-726.
- [15] 高普占. 微弱信号检测[M]. 北京:清华大学出版社, 2004.
GAO P ZH. Detection of weak signals [M]. Beijing: Tsinghua University Press, 2004.
- [16] WU J, CHEN S, WHIDBORNE, et al. An improved closed-loop stability related measure for finite-precision digital controller realizations [J]. *IEEE Transactions on Automatic Control*, 2001, 46(7):1162-1166.
- [17] 孙茜. Φ -OTDR 光纤预警系统模式识别方法研究[D]. 天津:天津大学, 2015.
SUN Q. Research on recognition method for Φ -OTDR optical fiber pre-warning pattern [D]. Tianjin: Tianjin University, 2015.
- [18] 孙丰荣, 刘积仁. 快速霍夫变换算法[J]. *计算机学报*, 2001, 24(10):1102-1109.
SUN F R, LIU J R. Fast Hough transform algorithm [J]. *Chinese Journal of Computers*, 2001, 24(10):1102-1109.
- [19] BRADSKI G R, KAEHLER A. Learning OpenCV [M].

- Sebastopol; O'Reilly Media, 2008.
- [20] 陈鑫元, 李筠, 杨海马, 等. 自适应阈值图像二值化及形态学处理的 FPGA 实现 [J]. 电子测量技术, 2016, 39(7):67-71.
CHENG X Y, LI J, YANG H M, et al. Adaptive threshold binarization and morphological image [J]. Electronic Measurement Technology Chinese Journal of Computers, 2016, 39(7):67-71.
- [21] 焦敬品, 李勇强, 吴斌, 等. 基于 BP 神经网络的管道泄漏声信号识别方法研究 [J]. 仪器仪表学报, 2016, 37(11):2588-2596.
JIAO J P, LI Y Q, WU B, et al. Research on acoustic signal recognition method for pipeline leakage with BP neural network [J]. Chinese Journal of Scientific Instrument, 2016, 37(11):2588-2596.
- [22] 吴成中, 王耀南, 冯明涛, 等. 基于神经网络的医药微弱异物视觉检测机器人 [J]. 电子测量与仪器学报, 2015, 29(12):1746-1756
WU CH ZH, WANG Y N, FENG M T, et al. Neural network based pharmaceutical insoluble foreign matter inspection robot [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(12):1746-1756.
- [23] 陈桥. 基于 BP 神经网络的五子棋自学习系统的设计与实现 [D]. 秦皇岛:燕山大学, 2016.
CHEN Q. Self learning system design and implementation based on BP neural network of gobang [D]. Qinhuangdao: Yanshan University, 2016.
- [24] 张光建. BP 神经网络人口预测模型研究与仿真 [J]. 智能计算机与应用, 2016, 6(1):88-90.
ZHANG G J. Research and simulation of population forecasting model of BP neural network [J]. Intelligent Computer and Applications, 2016, 6(1):88-90.
- [25] HAGAN M T, DEMUTH H B, MARKBEALE D. Neural network design [M]. Beijing: China Machine Press, 2002.
- [26] 丁硕, 巫庆辉, 常晓恒, 等. 基于灰色 BP 神经网络的实验材料供应预测 [J]. 国外电子测量技术, 2016, 35(12):78-82.
DING SH, WU Q H, CHANG X H, et al. Prediction of laboratory equipment support based on grey relation analysis and BP neural network [J]. Foreign Electronic Measurement Technology, 2016, 35(12):78-82.
- [27] HE Y F, WANG S, PENG Y. High performance heterogeneous embedded computing: A review [J]. Instrumentation, 2014(2):1-12.
- [28] ZHUO R, HAN Y, HAN Y. Bp neural network implementation on real-time reconfigurable FPGA system for a soft-sensing process [C]. IEEE International Conference on Neural Networks and Brain, 2005: 959-963.

作者简介



梁子千, 2015 年于天津大学获得学士学位, 现为天津大学硕士研究生, 主要研究方向为电磁涡流无损检测。

E-mail: L790447287L@126.com

Liang Ziqian received his B.Sc. degree from Tianjin University in 2015. Now he is M.Sc. candidate in Tianjin University. His main research interest is eddy current nondestructive testing.



封皓 (通讯作者), 分别在 2006 年和 2011 年于天津大学获得学士学位和博士学位, 现为天津大学讲师, 主要研究方向为光纤传感技术和信号处理。

E-mail: fenghao@tju.edu.cn

Feng Hao (Corresponding author) received his B.Sc. and Ph.D. degrees both from Tianjin University in 2006 and 2011, respectively. Now he is a lecturer in Tianjin University. His main research interests include fiber optic sensor and signal processing.