

DOI: 10.19650/j.cnki.cjsi.J1905421

基于数据融合的小波变换漏磁异常边缘检测^{*}

曹辉¹, 杨理践¹, 刘俊甫², 刘斌²

(1. 沈阳工业大学 沈阳 110870; 2. 沈阳大学 沈阳 110044)

摘要:漏磁内检测是目前管道无损检测的重要手段。在进行漏磁无损检测评估中,异常边缘检测是十分重要的环节,异常边缘的精确程度直接影响到后续的反演评估环节。由于数据噪声的存在,使得边缘检测精度大大下降,特别是复杂异常区域。同时,面对庞大的漏磁数据,一般机器学习算法耗时较多。因此,针对漏磁内检测中异常边缘检测问题,本文提出一种基于数据融合的小波变换漏磁异常边缘检测算法。该算法基于小波多尺度变换与分解,将数据层融合、特征层融合以及决策层融合相结合。首先,原始数据经过多色彩空间变换,并将变换结果进行数据融合。然后,融合数据进行小波多尺度变换。其次,针对每一尺度下变换数据进行小波多层分解,并对每一层级进行小波模极大值边缘检测,将边缘检测结果加入到细节分解系数融合中,并重构数据。最终将多尺度下的边缘检测效果进行融合得到最终检测边缘。实验分别在仿真数据集和真实管道数据集上进行,并和其他边缘检测算法,如 Sobel、Canny、Roberts、Prewitt、Log 进行了比较,实验结果显示,本文提出的异常边缘检测算法效果优于传统边缘检测算法,边缘指标 OA 高于 70%,能够满足实际工程需要。

关键词:漏磁检测;边缘检测;小波多尺度;数据融合

中图分类号: TH878 **文献标识码:** A **国家标准学科分类代码:** 440.55

Magnetic flux leakage anomaly edge detection based on data fusion and wavelet transformation

Cao Hui¹, Yang Lijian¹, Liu Junfu², Liu Bin²

(1. Shenyang University of Technology, Shenyang 110870, China; 2. Shenyang University, Shenyang 110044, China)

Abstract: The inner detection of magnetic flux leakage (MFL) is an important way of nondestructive testing (NDT) in pipeline. For the nondestructive evaluation, anomaly edge detection is an important part because its accuracy directly affects the subsequent inversion process. Due to the data noise, the accuracy of edge detection is greatly reduced, especially for complex anomaly. Meanwhile, general machine learning algorithms take more time to process huge MFL data. To address these problems, an edge detection algorithm based on data fusion and wavelet transform is proposed. This algorithm is based on wavelet multi-scale transformation and decomposition. The data layer fusion, feature layer fusion and decision layer fusion are combined. First, the original data are transformed by multi-color space, and the transformation results are fused together. The fused data are transformed by wavelet multi-scale. Secondly, wavelet multi-level decomposition is executed for each scale data, and the wavelet modulus maximum edge detection is performed for each level. In addition, the edge detection results are combined with detail decomposition coefficient for fusion and reconstruction. Finally, the edge detection results with multiple scales are fused to obtain the final detection edge. Experiments are conducted on the simulated data and the real pipeline dataset, respectively. Results are compared with other edge detection algorithms, including Sobel, Canny, Roberts, Prewitt, and Log. Experimental results demonstrate that the proposed anomaly edge detection method has better performance than traditional edge detection methods. OA evaluation for our method exceeds 70%, which satisfies requirement of practical application.

Keywords: magnetic flux leakage; edge detection; wavelet multi-scale; data fusion

0 引言

能源问题联系着国家的经济命脉,石油和天然气作为重要的能源材料越来越受到国家战略安全的重视,作为重要的能源约束手,管道的运行安全极其重要。随着使用时间增加,外界环境带来的腐蚀和物理破坏越来越严重^[1-2]。这些都导致了管道运行安全风险的增加。一旦泄漏处理不及时或者被忽视处理,经济损失将不可估量。泄漏严重时将会引起爆炸,带来重大人员伤亡。因此,管道的定期无损检测^[3-4]极其重要。

常用的管道无损检测手段包括涡流检测^[5-6],超声检测^[7-9],射线检测^[10-11]和漏磁检测^[12-13]。其中,超声检测是检测被测件的反射声波,但是检测过程中受人为因素影响较大,同时管道内外的回波交杂,难以区分。该方法操作简单,但是精度较差。涡流检测通过发射激励电流,在被测件产生涡流磁场,通过检测线圈电压变化得出检测结果。该方法一般用于检测内缺陷,但是由于敏感度较高,噪声也相对加大。射线检测主要利用射线对被测件进行拍照,通过测量照片中异常的尺寸,达到检测效果,但该方法相对不安全,容易发生辐射泄漏。漏磁检测是利用磁敏传感器被测件周围的漏磁场强度,由于该方法自动化程度高,且操作简单,灵敏度高,是目前管道无损检测中应用最为广泛的技术手段。

漏磁无损检测评估过程包括:异常边缘检测^[14]、缺陷组件识别^[15]、无损检测评估和管道维修。其中,异常边缘检测作为识别之前的重要环节,其重要性不容忽视。异常边缘检测准确性关系到后续尺寸反演和评估的精度,边界圈取太小容易导致反演结果尺寸偏低,大缺陷将被忽略处理,同样,一旦边缘检测范围过大,减低缺陷轮廓反演速度的同时,也会损失反演精度。因此,提升异常边缘检测的精度极其重要。同时,面对庞大的漏磁数据,实现快速检测也十分必要。

针对漏磁检测中的异常边缘检测,国内外学者所做研究有限。文献[16]采用阈值法对图像进行分割来获取波峰波谷,并设计了3层BP神经网络进行缺陷识别。对图像的大部分研究集中到缺陷识别、缺陷反演领域。同样,文献[17]也是利用阈值的方法进行缺陷和焊缝的检测识别。文献[18]运用边缘检测算子提取异常区域,并在一定程度上进行区域扩充,并设计了伤害性缺陷和非伤害性缺陷分类器。文献[19]运用Canny算子进行异常检测。在漏磁数据异常边缘检测研究中,大都基于阈值法或者边缘检测算子。然而以上方法对噪声的鲁棒性不高,同时边缘检测精度有限。

本文受小波模极大值边缘检测^[20]启发,提出了一种基于数据融合的小波变换漏磁异常边缘检测方法。小波

多尺度边缘检测方法被广泛用于工业异常检测中,本文在传统小波多尺度极大值边缘检测基础上,融入数据融合的思想,在算法中加入数据层融合、特征层融合和决策层融合。在数据层,考虑到不同色彩空间下边缘的显著程度不同,将数据进行多色彩空间变换。其次,在特征层,本文将每一层下小波分解系数与模极大值检测边缘融合,然后重构,进一步强化边缘。同时,为了平滑边缘,提出了边缘点相似性匹配准则,去除异常点。在决策层,将多尺度边缘检测效果融合,得到最终边缘检测结果。实验结果分别在仿真数据集和真实管道数据集中验证,并且和其他方法之间进行比较。

本文提出了一个基于数据融合的小波变换漏磁异常边缘检测框架,包括数据层多色彩空间数据变换、特征层多尺度小波系数融合,以及决策层边缘融合。在数据层,将数据进行多色彩空间变换,得到具有不同显著程度的数据源。在决策层,运用自适应方法进行融合后边缘提取,并提出了一种相似性度量函数用于边缘平滑。

1 漏磁检测原理

漏磁检测被广泛用于长输油管道的内检测中,由于其检测环境要求较低、操作简单、以及灵敏度高,该方法在国内外得到了广泛的推崇。漏磁检测通过磁敏传感器检测被测件周围产生的漏磁,漏磁量的大小与缺陷真实尺寸大小之间存在一定的非线性映射关系。通过分析这种非线性映射,最终对管道进行无损检测评估。

1.1 管道漏磁内检测原理

对缺陷参数精确量化的关键是尽可能全面准确获取缺陷漏磁场的大小及其分布特征。

管道漏磁内检测的主要原理为通过霍尔传感器检测出缺陷处被磁化材料表面泄漏出来的漏磁通量,原理如图1所示。




图1 漏磁检测原理

Fig.1 The schematic diagram of MFL detection

管壁中若存有缺陷,会导致缺陷处磁导率发生改变。若缺陷处的磁导率很小,磁阻很大,会造成磁通回路的磁通发生畸变,改变了磁感应线的传播方向,其中一部分的磁通会脱离管壁,通过空气这一传导介质绕过缺陷再次进入管壁,在管壁的缺陷处形成漏磁场。通常以将磁通分为3个部分:一部分直接穿过缺陷;一部分在管壁内部

迂回,通过缺陷周围的铁磁材料绕过缺陷;还有一部分磁通则会脱离管壁表面,通过空气绕过缺陷再次进入管壁。

图 1 中泄漏出的磁通量即为漏磁通 (magnetic flux leakage, MFL)。若管道出现缺陷时,缺陷处的漏磁通量会增大。在管道的内部和外部均有漏磁通量的产生与存在。霍尔传感器可以检测到泄漏出来的磁通量,还会发出与之相对应的检测信号,即缺陷漏磁报警信号。缺陷漏磁信号提供了缺陷信息,通过分析检测信号,可推断出缺陷尺寸等各项参数信息。

1.2 管道漏磁内检测的基本结构

管道漏磁内检测器结构如图 2 所示,主要结构包括测量节、计算机节和电池节和里程轮。各个结构之间通过万向节连接。电池节为整个系统提供电力支撑,计算机节负责存储所有检测数据并控制整个系统的运行。在测量节中,通过钢刷接触管壁,与永磁铁构成完整检测磁路,通过霍尔传感器检测漏磁场变化。




图 2 管道漏磁内检测器基本结构

Fig.2 Basic structure of the magnetic flux leakage detector

2 基于数据融合的小波变换漏磁异常边缘检测

2.1 多尺度小波变换原理

传统的或现代的图像边缘检测方法对传统图像的边缘定位虽然准确,但对漏磁图像异常边缘却无法准确检测定位出来,而小波多尺度边缘检测方法却能够准确地定位出漏磁图像异常边缘的位置。

对于任意一段漏磁数据 $D(x, y)$ 进行小波变换:

$$WT_s(D(x, y)) = D(x, y) \cdot \varphi(x, y) =$$

$$\iint_{R^2} D(u, v) \frac{1}{S^2} \varphi\left(\frac{x-u}{S}, \frac{y-v}{S}\right) du dv \quad (1)$$

设二维平滑函数 $\theta(x, y)$ 满足:

$$\theta(x, y) \geq 0, \iint_{R^2} \theta(x, y) dx dy = 1, \lim_{x, y \rightarrow \infty} \theta(x, y) = 0$$

对于平滑函数分别对两个自变量求导,即:

$$\theta^x(x, y) = \frac{\partial \theta(x, y)}{\partial x}, \quad \theta^y(x, y) = \frac{\partial \theta(x, y)}{\partial y} \quad (2)$$

对漏磁数据 $D(x, y)$, 分别在 x 和 y 两个方向进行小波变换为:

$$WT_s^x(D(x, y)) = \iint_{R^2} D \frac{1}{S^2} \varphi^x\left(\frac{x-u}{S}, \frac{y-v}{S}\right) du dv \quad (3)$$

$$WT_s^y(D(x, y)) = \iint_{R^2} D \frac{1}{S^2} \varphi^y\left(\frac{x-u}{S}, \frac{y-v}{S}\right) du dv$$

上式的向量表示形式为:

$$\begin{vmatrix} WT_s^x(D) \\ WT_s^y(D) \end{vmatrix} = S \begin{vmatrix} \frac{\partial}{\partial x} D \cdot \varphi_2(x, y) \\ \frac{\partial}{\partial y} D \cdot \varphi_2(x, y) \end{vmatrix} = S \nabla (D \cdot \varphi_s) \quad (4)$$

漏磁数据经过 $\varphi(x, y)$ 卷积操作平滑处理后得的梯度矢量的两个分量等于二维小波变换的两个分分量。上式的梯度矢量模值和幅角可计算为:

$$M_s D(x, y) = \sqrt{|WT_s^x D(x, y)|^2 + |WT_s^y D(x, y)|^2} \quad (5)$$

$$A_s D(x, y) = \arctan\left(\frac{WT_s^y D(x, y)}{WT_s^x D(x, y)}\right) \quad (6)$$

于是,通过检测小波变换模极大值点就可以确定漏磁数据中的边缘点,也就是异常区域。在小尺度变换下,得到的边缘点比较多,对于噪声的鲁棒性不够。在大尺度小波变换下,虽然边缘点误检较少,但出现了大量的漏检,异常检测精度不够。因此,为了得到较好的边缘识别精度,需要对不同尺度下的小波系数进行加权融合处理,根据融合后的小波系数,进行模极大值计算,最终得到边缘点,其中, $S=2^j$ 表示平滑尺度。

2.2 基于数据融合的小波变换漏磁异常边缘检测

针对传统小波变换模极大值边缘检测的不足,本文基于数据融合的思想,分别利用数据层融合、特征层融合,以及决策层融合相结合的方法对漏磁数据进行异常边缘检测。整体框架如图 3 所示。




图 3 基于数据融合的小波变换漏磁异常边缘检测框架

Fig.3 Framework of MFL anomaly edge detection based on data fusion and wavelet transformation

基于数据融合的小波变换漏磁异常边缘检测流程包括:

1) 数据预处理。原始漏磁数据中由于传感器故障以及检测器震荡,会存在大量的噪声和异常。数据预处理阶段完成漏磁数据的滤波和异常剔除。滤波函数采用高斯滤波和平滑滤波相结合,滤波后的数据为 $D'(x,y)$ 。异常剔除的规则如下:

$$\begin{cases} \text{异常,} & \text{if } D'(x,y) - u - \lambda\sigma \geq 0 \\ \text{非异常} & \text{else} \end{cases} \quad (7)$$

式中: u 和 σ 分别代表当前漏磁数据的均值和方差; $\lambda = 3$ 。异常剔除后,通过三次样条进行插值重构。

2) 多色彩空间数据变换。考虑到不同漏磁数据显著性水平以及人眼在不同色彩空间中识别能力的差异,本文将原始漏磁数据向多个色彩空间转换,即: RGB、Hsv、Lab、RGI、H 和 Intensity。其中, R 、 G 和 B 表示三原色(红、绿、蓝); s 表示深浅, v 表示明暗; $Intensity$ 表示强度。不同色彩空间下数据边缘效果如图4所示。图4中包含了2个尺寸大的缺陷(1号和3号),1个尺寸小的缺陷(2号)。从图4中可以看出:不同色彩空间下小缺陷的显著程度不同,同时对于边界的刻画也各有不同。

3) 小波变换图像数据层融合。利用小波对漏磁数据进行多尺度分解,将不同色彩空间下分解得到的低频和高频小波系数进行加权处理,使得最终数据最大程度的呈现边缘信息,同时去除噪声的影响。本文采用加权平均法,对低频和高频系数进行融合,最后根据融合后的低频和高频系数,进行漏磁数据重构,得到多色彩融合图像 $D(x,y)$ 。




图4 不同色彩空间下数据边缘效果

Fig.4 Edge performance of different color spaces

4) 小波多尺度变换,根据3.1节所述小波多尺度变换原理,对多色彩空间融合图像进行多尺度变换,得到多尺度变换图像结合 $D_s(x,y) = \{D_2(x,y), D_2(x,y), \dots, D_2(x,y)\}$ 。实际中, j 取3。

5) 小波多层分解系数特征融合。为了进一步提升边缘检测效果,强化边缘信息,降低噪声,需要对小波多尺度分解细节系数进行融合处理。以分解层数 K 取3为例,小波变换系数融合图像重构如图5所示。系数融合如下:

(1) 选择小波母函数进行小波多层分解,分解层数

为 K 。分别得到各层近似系数 CA , 水平分量 CH , 垂直分量 CV 和对角分量 CD 。

(2) 边缘矩阵计算。从第3层到第1层逐层处理,按照式(5)和(6)分别利用当前层水平细节系数和垂直细节系数求取梯度模值和幅角,并寻找模极大值,最终得到每一层的边缘图像 $Edge' = \{Edge'_1, Edge'_2, Edge'_3\}$, 边缘图像需要进行归一化处理,归一后的边缘图像变为 $Edge$ 。

(3) 细节系数变换。根据每一层得到的边缘矩阵,将当前层的水平分量,垂直细节分量和对角细节分量进行变换,即:

$$\begin{cases} CH'_i = CH_i \circ Edge_i \\ CV'_i = CV_i \circ Edge_i \\ CD'_i = CD_i \circ Edge_i \end{cases} \quad (8)$$

式中: $i=1,2,3$; $\circ$ 表示矩阵点乘运算算子。与 $Edge$ 进行运算后,使得边缘细节得到增强。

(4) 重构上一层近似细节系数。将变换后的细节系数和当前层的近似系数结合重构,重构结果作为上一层近似系数。即:

$$CA_{i-1} = REC(CA_i, CH'_i, CV'_i, CD'_i) \quad (9)$$

式中: REC 表示小波变换重构函数。重构结果需要进行归一化操作。

(5) 重构数据生成,将第一层的4个细节系数结合重构,重构结果作为最终的重构数据 $D'_2 = CA_0$ 。




图5 小波变换系数融合图像重构

Fig.5 Image reconstruction with wavelet transform coefficient fusion

6) 自适应阈值边缘提取。针对重构得到的数据,通过自适应阈值进行边缘提取。阈值可以被定义为:

$$\begin{aligned} TH &= \max(T_b, u + \gamma\sigma) \\ T_b &= 0.05 \times (Ma - Mi) + Mi \end{aligned} \quad (10)$$

式中: u, σ 表示均值和方差; T_b 是阈值基值; γ 是伸缩倍数, γ 取3; Ma 和 Mi 表示数据最小值和大值。

7) 相似性边缘平滑。考虑到边缘处噪声的影响,需要对得到的异常边缘进行平滑处理,去掉异常点。针对任意边缘曲线相邻点,进行相似性匹配,如果相似性大于

阈值,则保留。如果相似性小于阈值,则去除当前点,最终进行边缘拟合。本文分别计算模值相似性和幅角相似性,即:

$$S_T = \frac{\min(T_1, T_2)}{\max(T_1, T_2)} \quad (11)$$

$$S_A = 1 - \frac{|\text{mod}(A_1 - A_2, 360) - 360|}{360} \quad (12)$$

式中: T_1, T_2 表示相邻边缘点的幅值。 A_1, A_2 表示相邻边缘点的幅角。 S_T, S_A 越大,表明两个点的相似性越大。为了实际应用,通常会对这两个相似性进行加权处理,为了均衡两个参数,加权后的相似性度量函数为:

$$S\text{-measure} = \frac{2}{1/S_T + 1/S_A} \quad (13)$$

8) 多尺度边缘融合。由于不同尺度下体现的是不同边缘细节,因此,需要对所有结果进行融合和,提高检出水平。融合后的结果需要进行形态学腐蚀膨胀操作。

3 实验及讨论

3.1 数据集概述

本文数据集包括两个部分,即仿真数据集和真实管道数据集。仿真数据集是通过有限元软 ANSYS^[21] 模拟产生,仿真数据中包含 1 000 个缺陷样本,深度范围 1~10 mm,长度和宽度范围 10~100 mm。真实管道数据来源于实验场地,管道内检测试验场地如图 6 所示,其中图 6(a)所示为内检测图像。电池节为整个系统提供电力支撑,测量节负责检测漏磁数据,计算机节负责数据存储。图 6(b)所示为牵拉试验场地。所有实验管道由 X52 钢制成,它们的厚度和外径分别为 9.5 mm 和 219 mm。磁体的材料商标为 N48,其矫顽力为 876 000 A/m,剩磁为 1.37~1.43 T。磁轭的相对导磁率为 1 000,这确保磁通密度主要通过轭铁而不是空气。




图 6 管道内检测试验场地

Fig.6 Experimental field of pipeline inner inspection

3.2 算法评估标准

为了验证边缘检测效果的好坏,类似文献[22],计算了算法评价指标包括 Precision(查准率)、Recall(查全率)以及 F-measure,其中 F-measure 是对 Precision 和 Recall 的重加权,即:

$$F = \frac{(1 + \alpha^2) \text{Precision} \times \text{Recall}}{\alpha^2 \times \text{Precision} + \text{Recall}} \times 100\% \quad (14)$$

为了进一步说明边缘检测的准确率,检出边缘与真实标记边缘的交叠程度得计算,即:

$$OA = \frac{|op \cap G|}{|op \cup G|} \times 100\% \quad (15)$$

为了评估异常边缘检测的效果,需要对信号进行异常位置进行人工标记。异常边缘标记如图 7 所示。首先,需要人工标记异常区域跨越的传感通道数 n 。然后,针对每一个传感通道的信号 m_i 进行信号标记,主要是寻找异常信号峰值左右两侧的谷位置 l_i^1, l_i^2 。将所有跨越通道的谷位置进行连接,连接顺序为 $l_1^1, l_1^2, \dots, l_n^1, l_n^2, l_{n-1}^2, \dots, l_2^2, l_2^1$ 。最后对异常标记边缘进行平滑处理。




图 7 异常边缘标记

Fig.7 Schematic diagram of abnormal edge marking

3.3 仿真实验

首先为了验证提出算法的有效性,在仿真数据上测试边缘检测效果。1 000 个仿真样本的检测效果评价指标分布如图 8 所示,仿真结果中 4 个评价指标表现出较好的效果,精度基本在 75%左右波动。




图 8 仿真漏磁缺陷数据检测效果

Fig.8 Edge defect detection results of simulated pipelines

3.4 算法参数讨论

本文算法中主要参数包括自适应阈值边缘提取中的伸缩倍数 γ ,小波多尺度变换系数特征融合步骤中的母函数选择以及分解层数参数 K ,以及相似性边缘平滑步骤中的相似性匹配参数 $S\text{-measure}$ 。其中伸缩倍数 γ 由专家经验获得,剩余3个参数通过对比边缘检测效果得到。

本文选取 Daubenchies 小波系列 ‘db1’ ~ ‘db8’, Symlets 小波系列 ‘sym1’ ~ ‘sym8’, 以及 Coiflet 小波系列 ‘coif1’ ~ ‘coif5’。在不同小波母函数和不同分解层数下,仿真缺陷的边缘检测效果如图7所示,图7中只展示F指标的效果。分解层数由1层到10层,相似性参数 $S\text{-measure}$ 被设置0.5。从图9(a)中可以看出,小波母函数 ‘db5’ 效果最佳,分解层数在4层到7层之间F指标最大。其中在层数为5时,统计效果最佳。因此,对于 Daubenchies 系列小波母函数,小波母函数选择 ‘db5’, 层数设置为5。从图9(b)中可以看出, ‘sym3’ 拥有最好的效果,最佳分解层数为3。




图9 不同小波母函数系列以及不同分解层数效果对比

Fig.9 Comparisons of wavelet master functions and different decomposition layers

同样,根据图9(c)显示,Coiflet 小波系列中 ‘coif5’ 效果最好,最佳分解层数为6。为了方便说明比较,接下来所有实验中选取 Coiflet 小波系列中 ‘coif5’ 作为小波母函数,分解层数设置为6。

3.5 真实管道边缘检测试验

在实际中,提取的边缘由于边缘噪声的存在,使得边缘不清晰,最终检测的边缘会不规整,因此,为了获得更加平滑的边缘,获得更加准确的检测区域,需要设置合适的边缘相似性阈值,去除异常边缘。为了获得合适的相似性阈值,本文在相似性值在0.1~0.9之间遍历,依次检测边缘,检测如图10所示。从图10中看出,边缘检测效果在0.1~0.4之间逐渐上升,然而当阈值大于0.4之后,检测效果一直下降,这是因为,当相似性阈值设置过大时,会去掉真实边缘,使得边缘检测效果下降。因此,相似性预阈值最终设置为0.4。




图10 不同相似性匹配阈值检测效果

Fig.10 F values of different similarity matching threshold

为了进一步验证提出方法的有效性,本文在真实试验管道数据中进行边缘检测,为了更好地验证提出算的每个环节的必要性,本文设置整个算法分为以下部分:A-小波变换图像数据层融合,B-小波多尺度变换融合,C-小波多层分解系数融合,D-相似性边缘平滑。为了检测每个环节的效果,本文分别比较算法 A+ B+C+D, B+C+D, B+C,C+D。效果比较如图11所示,提出的不同融合环节后,效果均有所改善,其中增加了小波多层分解系数融合后,效果提升最大。




图11 实验真实管道边缘检测效果

Fig.11 Edge detection results of real pipelines

3.6 不同方法之间对比

为了与其他边缘算法比较,本文分别比较了经典的边缘检测算子 Canny、Sobel、Roberts、Prewitt、LOG。边缘检出位置精度指标 OA 对比效果如图 12 所示,结果表明本文提出方法优于其它边缘检测算法,Roberts 算子效果其次,LOG 算子效果最低。为了进一步体现不同算法的检测效果。本文选取一段真实管道数据进行边缘检测,视觉比较效果如图 13 所示。本文发现,虽然 Canny, Roberts 以及 Sobel 算子具有很好的定位效果,但边缘效果不佳,范围偏小。LOG 算子效果最低,基本失去区域定位能力。




图 12 不同边缘检测算法效果比较
Fig.12 Comparison of different edge detection operators




图 13 不同边缘检测算法效果视觉对比
Fig.13 Visual comparisons of different edge detection operators

4 结 论

针对目前漏磁内检测中由于噪声的存在使得异常边缘不清晰,本文提出了一种基于数据融合的小波变换漏磁异常边缘检测算法。该算法将小波多尺度变换以及分解与数据融合方法相结合。在数据层,将数据进行多色彩空间变换再融合。在特征层,将模极大值边缘检测结果与小波分解系数融合。在决策层,将多尺度边缘检测结果进行融合得出最终边缘结果。实验分别在仿真数据和真实管道数据集上进行,结果证明了所提出的算法的有效性。

虽然本文提出的基于数据融合的小波变换漏磁异常边缘检测在仿真结果中表现不错,但边缘检测效果还有待提高。在未来的研究中,需要继续改进该方法,同时将

该方法用于管道其他组件的边缘检测中,并进行量化分析。

参考文献

[1] 狄彦, 帅健, 王晓霖, 等. 油气管道事故原因分析及分类方法研究[J]. 中国安全科学学报, 2013, 23(7): 109.

DI Y, SHUAI J, WANG X L, et al. Study on methods for classifying oil&gas pipeline incidents [J]. China Safety Science Journal, 2013, 23(7):109.

[2] 赵晓鑫, 徐连勇, 荆洪阳, 等. 大变形海底管道工程临界评估研究进展[J]. 机械工程学报, 2019, 55(2): 82-90.

ZHAO X X, XU L Y, JING H Y, et al. Research progress of engineering critical assessment of submarine

- pipelines with large deformation [J]. Journal of Mechanical Engineering, 2019, 55(2):82-90.
- [3] LI F, FENG J, LIU J, et al. Defect profile reconstruction from MFL signals based on a specially designed genetic TABU search algorithm [J]. Insight-Non-Destructive Testing and Condition Monitoring, 2016, 58(7):380-387.
- [4] 王晓娟, 秦晨, 刘君. 管道点蚀检测的导波仿真优化研究[J]. 仪器仪表学报, 2019, 40(1):166-174.
- WANG X J, QIN CH, LIU J. Study on the simulation optimization of guided waves for the inspection of the pitting in pipeline [J]. Chinese Journal of Scientific Instrument, 2019, 40(1):166-174.
- [5] HUANG C, WU X, XU Z, et al. Ferromagnetic material pulsed eddy current testing signal modeling by equivalent multiple-coil-coupling approach [J]. NDT&E International, 2011, 44(2):163-168.
- [6] 党娜, 王维斌, 张涛, 等. 管道腐蚀脉冲涡流检测的三维仿真与试验[J]. 无损检测, 2017, 39(2):57-60.
- DANG N, WANG W B, ZHANG T, et al. 3D simulation and experiment of pulsed eddy current testing for pipeline corrosion[J]. Nondestructive Testing, 2017, 39(2):57-60.
- [7] VILKICKAS M, KAZYS R. Ultrasonic non-destructive evaluation with spatial combination of wigner-ville transforms[J]. NDT&E International, 2003, 36(6):441-453.
- [8] 唐东林, 魏子兵, 潘峰, 等. 基于 PCA 和 SVM 的管道腐蚀超声内检测[J]. 传感技术学报, 2018, 31(7):64-69.
- TANG D L, WEI Z B, PAN F, et al. Ultrasonic internal detection of pipeline corrosion based on PCA and SVM [J]. Chinese Journal of Sensor and Actuators, 2018, 31(7):64-69.
- [9] 行鸿彦, 吴红军, 徐伟, 等. 三维超声波换能器测风阵列研究[J]. 仪器仪表学报, 2017, 38(12):2943-2951.
- XING H Y, WU H J, XU W, et al. Study on ultrasonic transducer array for three-dimensional wind[J]. Chinese Journal of Scientific Instrument, 2017, 38(12):2943-2951.
- [10] ROBINI M C, MAGNIN I E. Radiographic testing of anomalies in thick metal components: fitting the standard line-integral model [J]. IEEE Transactions on Nuclear Science, 2007, 54(4):1285-1297.
- [11] 刘涵, 郭润元. 基于 X 射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J]. 仪器仪表学报, 2018, 39(4):247-256.
- LIU H, GUO R Y. Detection and identification of SAWH pipe weld defects based on X-ray image and CNN [J]. Chinese Journal of Scientific Instrument, 2018, 39(4):247-256.
- [12] 杨理践, 曹辉. 基于深度学习的管道焊缝法兰组件识别方法[J]. 仪器仪表学报, 2018, 39(2):193-202.
- YANG L J, CAO H. Deep learning based weld and flange identification in pipeline [J]. Chinese Journal of Scientific Instrument, 2018, 39(2):193-202.
- [13] LIU J, FU M, LIU F, et al. Window feature-based two-stage defect identification using magnetic flux leakage measurements[J]. IEEE Transactions on Instrumentation & Measurement, 2017, 67(1):12-23.
- [14] 张伟, 李焱骏, 师奕兵, 等. 石油管道脉冲远场涡流信号特征分析与处理[J]. 仪器仪表学报, 2019, 40(1):15-23.
- ZHANG W, LI Y J, SHI Y B, et al. Feature analysis and processing of pulsed remote field eddy current signal in oil pipes[J]. Chinese Journal of Scientific Instrument, 2019, 40(1):15-23.
- [15] WU J B, ZHU J ZH, XIA H, et al. DC-biased magnetization based eddy current thermography for subsurface defect detection [J]. IEEE Transactions on Industrial Informatics, 2019:1-1.
- [16] 唐永刚, 宁建国, 周松强, 等. 漏磁检测缺陷识别方法[C]. 全国计算爆炸力学会议, 2008:689-694.
- TANG Y G, NING J G, ZHOU S Q, et al. Defect recognition method of magnetic flux leakage inspection[C]. National Conference on Computational Explosive Mechanics, 2008:689-694.
- [17] 高松巍, 郑树林, 杨理践. 长输管道漏磁内检测缺陷识别方法[J]. 无损检测, 2013, 35(1):38-41.
- GAO S W, ZHENG SH L, YANG L J. Method of defect recognition of magnetic flux leakage inner detection for pipeline [J]. Nondestructive Testing, 2013, 35(1):38-41.
- [18] FENG J, LI F, LU S, et al. Injurious or noninjurious defect identification from mfl images in pipeline inspection using convolutional neural network[J]. IEEE Transactions on Instrumentation & Measurement, 2017, 66(7):1883-1892.

[19] RAVAN M, AMINEH R K, KOZIEL S, et al. Sizing of 3D arbitrary defects using magnetic flux leakage measurements [J]. IEEE Transactions on Magnetics, 2010, 46(4) :1024-1033.

[20] 万福, 杨曼琳, 贺鹏, 等. 变压器油中气体拉曼光谱检测及信号处理方法 [J]. 仪器仪表学报, 2016, 37(11) :2482-2488.

WANG F, YANG M L, HE P, et al. Raman spectroscopy detection and signal processing method for the gases in transformer oil [J]. Chinese Journal of Scientific Instrument, 2016, 37(11) :2482-2488.

[21] PARK G S, PARK S H. Analysis of the velocity-induced eddy current in MFL type NDT [J]. IEEE Transactions on Magnetics, 2004, 40(2) :663-666.

[22] FAWCETT T. An introduction to ROC analysis [J]. Pattern Recognition Letters, 2006, 27 (8) :861-874.

作者简介



曹辉, 2001 年于辽宁大学获得学士学位, 2009 年于东北大学获得硕士学位。现为沈阳大学讲师, 主要研究方向为管道检测和图像处理。

E-mail: 376421002@qq.com

Cao Hui received her B. Sc. degree from Liaoning University

in 2001 and received her M. Sc. degree from Northeastern University in 2009. She is currently a lecturer at Shenyang University. Her main research interests include pipeline detection and image processing.



杨理践 (通信作者), 1984 年于哈尔滨工业大学获得硕士学位。现为沈阳工业大学教授、博士生导师, 主要研究方向为无损检测、长输油气管道内检测技术及理论。

E-mail: yanglijian888@163.com

Yang Lijian (Corresponding author) received his M. Sc. degree from Harbin Institute of Technology in 1984. He is currently a professor and a Ph. D. advisor at Shenyang University of Technology. His main research interests include nondestructive testing, detection technology and theory of long oil and gas pipeline.



刘俊甫, 2009 年于西南石油大学油气储运专业获得学士学位, 目前为中石化长输油气管道检测有限公司高级工程师, 主要从事管道的内、外检测及评价工作。

E-mail: liujunfu86@126.com

Liu Junfu received his B. Sc. degree in the major of oil gas storage and transportation from Southwest Petroleum University in 2009. He is currently a senior engineer at Sinopec Oil and Gas Pipeline Inspection Co., Ltd. He engages ILI and integrity assessment of the oil and gas pipeline.