

漏磁检测在管道损伤探测中的应用

左万君,戴西斌,吴昌玉

(江西省检验检测认证总院特种设备检验检测研究院,南昌 330000)

摘要:漏磁检测技术是油气管道损伤检测中最常用的方法之一。其是一种利用磁敏传感器检测漏磁信号进而探测管道缺陷的无损检测技术。首先介绍了漏磁检测的原理和操作流程,而后综述了近年来漏磁检测技术在信号预处理、异常识别以及缺陷量化3方面取得的重要成果。其中,重点介绍了基于深度学习的异常识别和缺陷量化方法,并分析了这些方法存在的不足。最后,对管道漏磁检测的未来发展进行了展望。

关键词:无损检测;漏磁检测;神经网络;异常识别;缺陷量化

中图分类号: TG115.28

文献标志码: A

文章编号:1000-6656(2024)03-0056-08

Application of magnetic flux leakage testing in pipeline damage detection

ZUO Wanjun, DAI Xibin, WU Changyu

(Jiangxi General Inspection and Certification Institute of Special Equipment Inspection and Testing, Nanchang 330000, China)

Abstract: Magnetic flux leakage detection technology is one of the most commonly used methods for damage detection in oil and gas pipelines. It is a nondestructive testing technology that uses magnetic sensors to detect magnetic flux leakage signals and then detect pipeline defects. This paper first briefly introduced the principle and operation process of magnetic flux leakage testing, and then summarized the important achievements of magnetic flux leakage testing technology in signal preprocessing, anomaly recognition, and defect quantification in recent years. Among them, anomaly recognition and defect quantification were the key points in the magnetic flux leakage detection process. The focus was on introducing deep learning based anomaly recognition and defect quantification methods, and then analyzing the current shortcomings of these methods. Finally, the future development of pipeline magnetic flux leakage testing was prospected.

Key words: nondestructive testing; magnetic flux leakage testing; neural network; abnormal identification; defect quantification

石油和天然气是社会生产的重要能源和化工材料。由于储罐的耐用性强、存储量大及易于操作等优势,故石油及化学工业材料在二级加工前大多使用储罐进行储存^[1]。在储罐中,化学品蒸发形式的烟雾会腐蚀储罐底部形成缺陷,并且储罐底板会因为储存含水物质加速腐蚀^[2]。据调查统计,70%的储罐损坏是地板腐蚀导致^[3]。此外,石油和天然气

常通过长距离输送管道进行运输;而管道大多铺设在地下并且暴露在高湿度或者高地压等环境中,容易发生腐蚀和变形。这些损伤如不能及时发现将导致灾难性事故,如人员伤亡、财产损失、生产中断以及环境污染等。然而,储罐、管道及此类设备对损伤检测技术要求较高,需要保证检测位置的多样性、检测结果的时效性以及防止检测过程中对设备产生破坏等。因此,无损检测技术因对检测区域无破坏损伤、操作简便且反应迅速等优势被广泛应用于该类设备的损伤检测。

无损检测是设备质量控制的重要组成部分,该技术的使用情况很大程度取决于检测对象的环境及

收稿日期:2023-10-19

作者简介:左万君(1981—),男,硕士,高级工程师,主要从事特种设备检验检测研究工作

通信作者:戴西斌,976504890@qq.com。

材料属性,如检测部位材料的直径、长度、厚度、制造方法、潜在不连续点位置等。在确保检测材料完整性基础上,不影响设备运行预期功能是无损检测的主要目的。在这种复杂的应用环境中,许多无损检测技术被开发,如射线检测、超声检测、磁粉检测以及漏磁检测(MFL)等^[4]。在所有无损检测方法中,漏磁检测是油气行业最常用的方法之一,可以得到可靠、及时并利于分析的结果,该项技术自20世纪60年代以来在管道检测领域得到了长足的发展。漏磁检测无需对检测对象进行预处理,易于获得检测信号,操作自动化程度高,并且能够探测不同类型的缺陷,如气孔、缩孔、腐蚀等^[5]。虽然,在长期的研究和应用过程中,该技术从对缺陷的定性检测转变为定量检测,但是仍存在挑战,如针对复杂的检测工况需要处理大量磁场信号,无法做到准确定性缺陷;在检测过程中对噪声的干扰非常敏感,一些较小的缺陷信号会被定性为噪声信号;当材料含有杂质时会显著影响检测信号;缺乏缺陷定量理论,针对检测信号无法反演准确的缺陷特征,并且高度依赖操作者的经验等^[6-8]。

文章综述了近年来漏磁检测技术的相关研究成果,介绍了针对信号去噪、设备缺陷识别以及缺陷量化分析等方面的重要成果,讨论了这些研究存在的不足,并重点介绍了人工智能技术在其中的应用。最后,针对漏磁检测技术的未来发展进行了展望。

1 漏磁检测原理及操作流程

1.1 漏磁检测原理

漏磁检测通过外磁场对铁磁性材料进行磁化,然后通过磁传感器检测材料中的漏磁信号来得到材料的连续性信息,其原理示意如图1所示。漏磁检测时,当被测试件表面完整时,磁感线在其中有序传播,无法检测到漏磁信号。当被测试件表面存在切割磁感线方向的缺陷时,缺陷处的低磁导率会导致磁感线无法正常传播进而改变传播方向,其中,改变方向的磁感线包括穿过缺陷或沿缺陷附近传播的磁感线以及离开物体表面传播至空气或其他介质中的磁感线,而后者则会形成漏磁^[9]。在电磁场的边界条件下,可利用磁场的折射来解释漏磁场现象,其示意如图2所示,其中折射角的表达式为

$$\alpha_2 = \arctan\left(\frac{v_1}{v_2} \tan \alpha_1\right)$$

式中: α_1 和 α_2 为入射角和折射角; v_1 和 v_2 分别为边界上下介质的渗透率。




图1 漏磁检测原理示意




图2 磁场在缺陷界面的折射示意

VISINTIN^[10]从微观角度对这一现象进行了说明,他假设实际的物体由许多称为“畴”的小区域组成,在无外加磁场的情况下每个区域的局部磁化是饱和的;不同畴的磁化方向不一定是平行的,在多晶样品中存在大量磁化方向不同的磁畴,这些磁畴呈随机分布,磁矩相互抵消,导致整个物体呈无磁性材料。单晶和多晶体合成零磁矩示意如图3所示。KITTEL^[11]研究提出,在外加磁场的作用下,有利取向(与外加磁场方向接近)的畴体积增大,且畴方向逐渐向外加磁场方向转变,而不利取向的畴体积逐渐缩小,最终使得试件表现出磁性。这种磁化方式通常是通过畴壁的移动来进行的,所以畴的体积会发生变化。当试件中存在缺陷时,缺陷处的磁畴壁势能发生改变,抑制畴壁在缺陷处的移动,导致磁场不能通过畴壁的移动来达到系统能量平衡。在系统能量平衡且达到最小化的过程中,缺陷部位产生磁场畸变进而导致试件漏磁。





图3 单晶和多晶体零磁矩示意

1.2 漏磁检测操作流程

漏磁检测操作流程如图4所示。漏磁检测内部探测器结构,如图5所示,该探测器由测量段、数据采集室以及电池室组成。其操作主要分为以下几个



步骤。

(1) 漏磁检测与信号采集: 将内部探测器牵引至管道中, 对管壁进行磁化并采集漏磁信号, 将采集信号存储至数据采集室后将探测器从管道内牵引出。

(2) 信号预处理与可视化: 首先, 在检测之前对探测器参数进行校准, 而后通过小波分解等方法提取缺陷信号, 最后借助可视化程序将缺陷信号以图像形式呈现出来。

(3) 异常信号识别: 通过对信号特征分析识别异常信号, 并对异常信号进行分类, 将管道损伤与非损伤状态区分开。

(4) 缺陷定量分析: 根据缺陷信号对缺陷位置、尺寸及深度进行反演。设备安全评估与预测: 结合缺陷反演结果和管道环境等因素对管道运行状态进行安全评估和预测。



图 5 漏磁检测内部探测器结构

2 检测信号的预处理

信号的预处理包括对检测信号进行压缩以及降噪等处理。一般情况下, 检测数据包含磁性数据和非磁性数据。磁性数据是指检测到的相关管道损伤的漏磁数据; 非磁性数据记录了内部探测器工作状态、时间、速度、管道温度以及空间位置等信息。由于漏磁检测信号数据量较为庞大, 且检测设备存储容量有限, 因此需要对检测信号进行压缩。通常情况下, 检测到异常部位时信号会产生峰值, 因此在压缩信号时, 对其峰值部分可选择轻微压缩或者不压缩以保证数据的真实性, 而其他小幅度信号则可以选择较大压缩比进行压缩^[12]。

此外, 为了提高信号质量以及信号表征缺陷的

准确性, 有必要对噪声信号进行处理。李小娟等^[13]将滤波算法改进为适用于过滤漏磁信号的多级滤波算法, 通过二级改进的中值滤波算法达到过滤漏磁信号中高频噪声以及基线漂移信号的目的。ZHANG 等^[14]提出了一种基于小波去噪结合中值滤波的多电平滤波方法, 通过选择两个最佳小波基, 即 sym 8 和 sym 6(8 阶和 6 阶的 Symlet 小波函数)并结合中值滤波方法实现了对漏磁信号的去噪。利用小波分解重构技术可以有效滤除漏磁信号中的噪声信号, 而小波分解重构的层数是决定信号去噪效果的关键, 过低的层数会使得去噪效果不佳, 过高的层数则会使得小缺陷信号被作为噪声信号去除而引起信号失真。SHI 等^[15]在综合考虑了信噪比、均方根误差以及平滑度等多个指标的基础上, 提出了一种基于交变系数的磁流变信号小波去噪方法, 该方法在实际应用中表现出了良好的信号去噪效果。

3 异常识别

3.1 设备异常类型

一般情况下, 工业设备如管道、储罐等表面存在的异常主要包括材料损伤、焊缝以及拼接部件。材料损伤分为材料损失、腐蚀、形变等。其中, 材料的表面损失主要指人为操作如安装、搬运等过程中造成的表面刮蹭; 腐蚀大多是外部环境的变化以及内部运输介质的化学反应引起的; 形变则是指设备长期处于某种压力作用下形成的塑性变形。焊缝主要存在于运输管道的拼接处, 主要分为直焊、环焊以及螺旋焊接^[16]。由于焊接材料与管材存在差异, 检测过程中材料性质的不连续会导致漏磁。拼接部件例如三通、弯头等主要用于管道连接, 这些连接部件会改变管道结构而导致检测过程中出现漏磁现象。

3.2 设备异常识别与分类

在漏磁检测过程中上述情况均会导致漏磁反应, 而焊缝以及拼接部件却是非损伤结构, 因此, 对设备异常进行识别与分类尤为重要。传统的检测信号异常识别流程包括管道检测位置选取、人工异常信号提取与识别以及异常分类。通常情况下, 采取人为选择检测区域并且定义检测信号特征(包括信号峰谷值、信号上升率、谷宽等)^[17]的方式, 其识别结果很大程度上依赖操作者的工作经验。此外, 漏

磁检测采集的信号数据体量庞大,除了一些常见的异常信号(见图 6)之外还会出现不同种类且类型和特征未知的异常信号。传统的异常分类方法主要有支持向量机模型(SVM)、极限学习机(ELM)、浅层神经网络模型等^[18],这些方法均依赖于人工信号特征的提取情况,检测精度较低。




图 6 漏磁信号检测中常见的异常信号

随着计算机技术的发展,一些异常信号建模和统计方法被提出并应用于漏磁信号的异常识别中。WANG 等^[19]提出了一种基于稀疏主题模型的半监督视频监控异常检测方法。SONG 等^[20]提出了一种基于行为模型的异常检测方法,通过行为模型提取的行为数据与实测的行为数据进行对比,检测异常情况。这些异常信号建模方法通常适用于异常信号固定或者精度要求较低的工况,但在实际中,异常信号的特征通常是复杂的、未知的,异常信号的数量亦极少,这些局限性使得其很少用于复杂工况。而如高斯过程回归法和基于贝叶斯的统计方法,被认为过于依赖工业数据分布情况而在实际中应用较少。此外,一些快速识别算法,如阈值分析法^[21]、差分阈值法^[22]、幅值阈值法^[23]以及模板匹配法^[24]等被提出,其通过程序自动化完成对漏磁信号的识别工作。阈值分析法需要手动设置管道异常识别的阈值,由于管道管径、壁厚、材料等条件不同,相应的阈值不一致,因此,手动设置阈值并不能满足所有情况。差分阈值法是比较磁信号数据相邻两点之间的差值与阈值来确定信号是否异常,该方法能够识别大部分情况下的异常数据,但会使得信号谷峰附近出现信号缺失等现象。幅值阈值法是将信号中多个信号数据最大值的平均值设定为阈值 T ,并通过比较原始数据与阈值 T 的大小来判定是否为异常信号,但该方法受幅值阈值设定的限制,当检测信号中同时存在缺陷大小差异过大的信号数据时小缺陷部分数据将被过滤。王婷婷^[25]基于差分阈值法和幅值阈值法提出了缺陷自适应阈值检测法,一定程度上弥补了两者的不足。然而,管道漏磁信号的复杂性仍然是限制传统方法识别精度的主要因素。

3.3 基于卷积神经网络的漏磁信号异常识别

近年来,随着人工智能的发展,深度学习方法在管道漏磁检测领域得到了应用。将预处理后的数据

输入深度学习模型后,模型自动进行特征提取,识别和分类,识别效果良好。卷积神经网络(CNN)是典型的前馈神经网络,也是最流行的深度学习算法之一。只要用样本数据对已知的卷积网络模型进行训练,就可以得到一个性能良好的网络模型来提取图像的局部特征信息。这种网络模型已经广泛应用于图像识别和分类、人脸识别、音频检索、自然语言处理、视觉跟踪等领域^[26]。卷积神经网络结构示意如图 7 所示,其由输入层、卷积层、池化层、全连接层以及输出层组成。其输入层采集原始图像数据;卷积层通过卷积计算获得特征图;池化层对特征图进行降采样操作,降低数据维数。其中,卷积层和池化层的数量通常根据实际情况决定,全连接层则是基于降维数据进行映射,最终通过输出层对信号进行分类。

常用的 CNN 信号分类算法有 LeNet、VGG、AlexNet、GoogleNet 等^[27],这些深度学习算法在油气管道异常分类的应用中已经取得了良好的效果。此外,LI 等^[28]提出了一种基于 CNN 的漏磁检测响应进行分类,如缺陷、三通以及阴极保护等。YANG 等^[29]为了更好地对漏磁信号进行分类提出了一种基于稀疏自编码的漏磁图像分类方法,该方法基于卷积神经网络自动提取特征,优化了管道环焊缝和螺旋焊缝的识别精度。曹辉等^[30]提出了基于 U-Net 卷积神经网络识别管道漏磁异常的方法,在 U-Net 提取管道图像异常的基础上采用 ResNet 网络替代下采样部分的网络结构,进而提升检测的准确性。LIU 等^[31]构建了基于 VGG16 卷积神经网络的改进深度残差网络,能够从检测图像信号中自动学习特征,并识别损伤信号与非损伤信号。相较于传统异常识别手段,基于深度学习方法的异常识别的准确性得到了明显的提升。

4 缺陷量化

油气管道的缺陷量化是评价管道损伤程度以及评估管道安全性的重要指标。同时,通过漏磁信号数据定量确定缺陷轮廓的大小也是漏磁检测中最困难的问题之一,因为这是一个不稳定的逆问题。而量化的最终目标是计算管道最大安全操作压力(MOP),可根据量化特征参数如等效长度、宽度和深度将缺陷等效为矩形或者立方体,并基于此来计算 MOP。虽然将缺陷等效为矩形等规则形状在实际工程中具有一定可行性,但是仍存在长足的进步




图 7 卷积神经网络结构示意

空间。

MFL 逆问题的求解包括基于迭代的方法和基于映射的方法。基于迭代的方法通常采用正演模型^[32], 将模型计算出的模拟信号与检测信号进行比较, 进而获得残差; 最后, 通过优化策略最小化残差, 进而迭代出缺陷大小。基于映射的方法通常采用神经网络构建函数, 建立 MFL 信号和缺陷几何特征之间的映射关系, 进而求解 MFL 逆问题^[33]。

4.1 基于迭代的量化方法

目前, 基于迭代的方法已广泛应用于油气管道的缺陷量化。基于迭代方法的原理示意如图 8 所示(其中缺陷的量化被认为是一个优化问题), 首先, 对缺陷轮廓进行初步估计, 通过正演模型生成 MFL 信号; 将计算得到的 MFL 信号与检测得到的 MFL 信号进行比较; 如果误差小于期望值 ϵ , 则将轮廓视为最终缺陷轮廓, 否则, 使用误差来更新缺陷轮廓并重复前向计算的过程。在更新缺陷轮廓的过程中, 常用的优化算法有梯度下降算法、遗传算法、粒子群优化以及布谷鸟搜索等^[34]。

然而, 上述的迭代方法仍然存在计算成本较高, 反应速度较慢等缺点。针对这些不足, 近几年许多被优化的迭代方法被提出。LU 等^[35]对传统粒子群优化算法的自适应惯性权重和速度更新策略进行了改进, 提出了一种基于有限元正演的快速全局收敛粒子群优化算法作为迭代算法, 该方法在加速优化速度的同时能够反演出精确的缺陷轮廓。ZHOU 等^[36]采用基于改进的粒子群优化算法的反演技术量化缺陷尺寸, 结果表明该方法可将缺陷深度的平均误差精度提高 5.83 %, 缺陷长度的平均误差精度提高 4.87 %。LI 等^[37]建立了适应矩形和 V 形缺陷轮廓的反演模型并基于混沌初始分布、S 型惯性权重系数和正弦余弦加速度系数对粒子群优化算法

进行了改进。LI 等^[38]提出了一种将漏磁检测技术与遗传算法改进的核函数极值学习机(GA-KELM)相结合的无损检测方法, 结果表明该方法能有效反演腐蚀缺陷的深度和长度, 量化精度优于传统极限学习机模型的精度。

4.2 基于映射的缺陷量化

近年来, 机器学习得到了快速发展, 特别是在人工神经网络(ANN)和深度学习领域。缺陷量化本质是一个分类或回归的问题, 因此, 人工神经网络已广泛应用于漏磁检测技术的缺陷量化。将神经网络视为一个函数, 该函数以漏磁检测的原始信号或从信号中提取出的特征作为输入量映射到具有缺陷类型或者缺陷尺寸性质的输出量上。其通过模拟各种尺寸、形状的缺陷对神经网络进行训练, 并将缺陷大小和相应的信号输入网络以优化权重。

最初, 受计算设备性能的制约, 神经网络的隐藏层数量被限制。CARVALHO 等^[39]使用原始 MFL 信号和滤波后的信号作为神经网络的输入, 将信号分为缺陷和非缺陷两类, 准确率达到 94.2 %。此外, 他还利用神经网络将缺陷分为外腐蚀、内腐蚀和未焊透, 准确率达到 71.7 %。K. HWANG 等采用小波基函数(WBF)神经网络将 MFL 信号转化为三维缺陷轮廓。KHODAYARI-ROSTAMABAD 等^[40]引入了各种机器学习技术和特征选择方法, 对缺陷深度的量化误差小于 8 %。浅层的神经网络学习能力较差且需要手动提取信号特征。而随着计算机性能的飞速提升, 深度神经网络的学习能力得以提升, 避免了手动提取特征引入的误差。LU 等^[41]提出了一种新的视觉变换 CNN(VT-CNN)方法来估算油气管道的缺陷尺寸, 该方法增加了一个视觉转换层来突出缺陷的特征信息, 可以将原始的 MFL 测量结果转换成任意视角的三维图像。在实际应用




图 8 基于迭代方法的原理示意

中,其采用 3 个 VT-CNN 来量化缺陷的长度、宽度和深度,估算精度分别提高了 26.9 %,27.1 % 和 33.3 %。WU 等^[42]基于深度强化学习(RL)的重建解决方案来估算检测中的缺陷深度。YUKSEL 等^[43]提出了 SwinYv5 目标检测算法的缺陷检测模型与检查残差卷积神经网络(CR-CNN)相结合的方法。该方法对缺陷的检测精度为 98.9 %,对缺陷量化的最大长度误差为 1.30 mm,最大宽度误差为 1.65 mm,最大深度误差为 0.47 mm。

5 总结与展望

漏磁信号检测是国内油气管道损伤检测的重要手段之一。漏磁信号去噪、异常识别以及缺陷反演是漏磁检测过程中的关键部分,尤其是缺陷反演的准确性。文章简要介绍了漏磁检测的基本原理及操作流程,综述了近年来在漏磁检测过程中对信号预处理、异常信号识别以及缺陷量化三方面的研究成果。其中,重点介绍了漏磁信号异常识别方法中的基于卷积神经网络的异常识别方法以及缺陷量化方法中基于迭代和基于映射的量化方法。这些方法相对于传统的人工检测方法,在人工经验存在的误差、信号处理能力与速度以及缺陷预测精度等方面有着巨大的优势,对漏磁检测技术在探测油气管道的应用上有着重要的工程价值。然而,这些方法虽然在突破传统漏磁信号异常识别以及缺陷反演中取得了一定的成果,但是仍然存在一些挑战,具体如下所述。

(1) 受限于计算设备的性能,深度学习的方法在漏磁检测领域的应用并不多,未来计算设备的发展能够给这个方法带来更广阔的应用场景。

(2) 无论是基于映射还是基于迭代的方法均是非现象方法,其决策与理论、经验相离,因此,深入研究漏磁现象机理,着力于研究漏磁信号与损伤特征之间的关联原理与机制尤为重要。

(3) 在应用中,深度学习的方法要求较大的实

际测量样本数量,故发展快速检测漏磁信号的方法,扩大学习的样本数量是该方法未来的研究方向。

参考文献:

- [1] 彭善碧,赵菂雯,卢泓方,等.国外石油天然气行业非金属管道检测技术[J].中国安全生产科学技术,2022,18(12):49-57.
- [2] 仵杰,李野.基于阵列感应的石油管道无损检测研究[J].西安石油大学学报(自然科学版),2021,36(5):121-128.
- [3] LIU F J, LING Z W, KONG S, et al. Application of zero-phase digital filter in magnetic flux leakage testing for tank floor inspection [J]. Applied Mechanics and Materials, 2013, 333/334/335: 1644-1648.
- [4] 王磊,柳亦兵,滕伟,等.风电机组叶片无损检测技术研究与进展[J].中国电力,2023,56(10):80-95.
- [5] WANG Y D, XU Y T, WANG B, et al. Research on metal atmospheric storage tank inspection method for standard in China[C]//Proceedings of ASME 2009 Pressure Vessels and Piping Conference. Prague, Czech Republic:447-452.
- [6] LI Y, TIAN G Y, WARD S. Numerical simulations on electromagnetic NDT at high speed[J]. Insight - Non Destructive Testing and Condition Monitoring, 2006, 48(2):103-108.
- [7] CHEN Q K, ZHANG J W, YE Q. Wire rope damage detection based on magnetic leakage and visible light [J]. Journal of Failure Analysis and Prevention, 2023, 23(3):1275-1287.
- [8] SAHOO S K, GOSWAMI S S. Investigating the causes and remedies for porosity defects in the casting process:a review[J]. BOHR International Journal of Engineering, 2023, 2(1):15-29.
- [9] ZHANG H, LI H X, ZHOU J T, et al. A multi-dimensional evaluation of wire breakage in bridge cable based on self-magnetic flux leakage signals[J]. Journal of Magnetism and Magnetic Materials, 2023, 566:170321.

- [10] VISINTIN A. A Weiss-type model of ferromagnetism [J]. *Physica B: Condensed Matter*, 2000, 275(1/2/3): 87-91.
- [11] KITTEL C. Physical theory of ferromagnetic domains [J]. *Reviews of Modern Physics*, 1949, 21(4): 541-583.
- [12] SOPHIAN A, TIAN G Y, ZAIRI S. Pulsed magnetic flux leakage techniques for crack detection and characterisation [J]. *Sensors and Actuators A: Physical*, 2006, 125(2): 186-191.
- [13] 李小娟, 李岩松, 田硕文, 等. 基于中值滤波的铁磁材料缺陷漏磁检测信号处理[J]. 电测与仪表, 2022, 59(3): 143-150.
- [14] ZHANG O, WEI X Y. De-noising of magnetic flux leakage signals based on wavelet filtering method[J]. *Research in Nondestructive Evaluation*, 2019, 30(5): 269-286.
- [15] SHI G N, HU P, CHEN J Z, et al. Wavelet de-noising method analysis of pipeline magnetic flux leakage In-line inspection based on coefficient of variation[C]// 2022 International Conference on Automation, Robotics and Computer Engineering (ICARCE). Wuhan, China: IEEE, 2022: 1-5.
- [16] 武要峰, 史冠男, 国滨, 等. 基于漏磁内检测的管道焊缝缺陷识别及应对策略研究[J]. 中国特种设备安全, 2023, 39(8): 1-7.
- [17] LIU B, LUO N, FENG G. Quantitative study on MFL signal of pipeline composite defect based on improved magnetic charge model[J]. *Sensors*, 2021, 21(10): 3412.
- [18] 王再辰, 程辉, 赵亮. 基于极限学习机的在线参数更新方法及工业应用[J]. 现代电子技术, 2023, 46(22): 126-130.
- [19] WANG J, XIA L M, HU X J, et al. Abnormal event detection with semi-supervised sparse topic model [J]. *Neural Computing and Applications*, 2019, 31(5): 1607-1617.
- [20] SONG Z W, LIU Z H. Abnormal detection method of industrial control system based on behavior model [J]. *Computers & Security*, 2019, 84: 166-178.
- [21] 张萍, 朱佳. 基于 Gabor 小波和阈值分析的声发射源定位方法[J]. 压电与声光, 2014, 36(4): 531-534, 537.
- [22] LONG Y, ZHANG J H, HUANG S L, et al. A novel crack quantification method for ultra-high-definition magnetic flux leakage detection in pipeline inspection [J]. *IEEE Sensors Journal*, 2022, 22(16): 16402-16413.
- [23] PAN F Y, LIU Z L, REN L Y, et al. Adaptive local flaw detection based on magnetic flux leakage images with a noise distortion effect for steel wire ropes[J]. *IEEE Transactions on Industrial Electronics*, 2024, 71(4): 4120-4129.
- [24] 李勇, 高洋, 叶泵, 等. 基于模板匹配法的主动源地震检测方法研究[J]. 大地测量与地球动力学, 2017, 37(7): 752-755.
- [25] 王婷婷. 金属表面缺陷特征智能提取及特征分析的方法研究[D]. 沈阳: 东北大学, 2016.
- [26] ZHANG J H, LI C, YIN Y M, et al. Applications of artificial neural networks in microorganism image analysis: a comprehensive review from conventional multilayer perceptron to popular convolutional neural network and potential visual transformer [J]. *Artificial Intelligence Review*, 2023, 56(2): 1013-1070.
- [27] 杨铄, 许清风, 王卓琳. 基于卷积神经网络的结构损伤识别研究进展[J]. 建筑科学与工程学报, 2022, 39(4): 38-57.
- [28] LI F M, FENG J, LU S X, et al. Convolution neural network for classification of magnetic flux leakage response segments [C]// 2017 6th Data Driven Control and Learning Systems (DDCLS). Chongqing, China: IEEE, 2017: 152-155.
- [29] YANG L J, WANG Z J, GAO S W, et al. Magnetic flux leakage image classification method for pipeline weld based on optimized convolution kernel [J]. *Neurocomputing*, 2019, 365: 229-238.
- [30] 曹辉, 杨理践, 杨文俊, 等. 基于 U-Net 卷积神经网络的管道漏磁异常检测[J]. 沈阳大学学报(自然科学版), 2020, 32(5): 402-409.
- [31] LIU S C, WANG H J, LI R. Attention module magnetic flux leakage linked deep residual network for pipeline In-line inspection[J]. *Sensors*, 2022, 22(6): 2230.
- [32] SCHIFINI R, BRUNO A C. Experimental verification of a finite element model used in a magnetic flux leakage inverse problem [J]. *Journal of Physics D: Applied Physics*, 2005, 38(12): 1875-1880.
- [33] MUKHERJEE D, SAHA S, MUKHOPADHYAY S. Inverse mapping of magnetic flux leakage signal for defect characterization[J]. *NDT & E International*, 2013, 54: 198-208.
- [34] 程述立, 汪烈军, 秦继伟, 等. 群智能算法优化的结合熵的最大类间方差法与脉冲耦合神经网络融合的图像分割算法[J]. 计算机应用, 2017, 37(12): 3528-3535, 3553.

- [35] LU S X, LIU J H, WU J, et al. A fast globally convergent particle swarm optimization for defect profile inversion using MFL detector[J]. Machines, 2022, 10(11):1091.
- [36] ZHOU Z M, LI J Y, XI Z D, et al. Real-time online inversion of GA-PSO-BP flux leakage defects based on information fusion: numerical simulation and experimental research[J]. Journal of Magnetism and Magnetic Materials, 2022, 563:169936.
- [37] LI J T, SU S Q, WANG W, et al. Fast reconstruction method for defect profiles of ferromagnetic materials based on metal magnetic memory technique [J]. Measurement, 2023, 215:112885.
- [38] LI Y Q, SUN C, LIU Y C. Magnetic flux leakage testing method for pipelines with stress corrosion defects based on improved kernel extreme learning machine[J]. Electronics, 2023, 12(17):3707.
- [39] CARVALHO A A, REBELLO J M A, SAGRILO L V S, et al. MFL signals and artificial neural networks applied to detection and classification of pipe weld defects[J]. NDT & E International, 2006, 39(8):661-667.
- [40] KHODAYARI-ROSTAMABAD A, REILLY J P, NIKOLOVA N K, et al. Machine learning techniques for the analysis of magnetic flux leakage images in pipeline inspection [J]. IEEE Transactions on Magnetics, 2009, 45(8):3073-3084.
- [41] LU S X, FENG J, ZHANG H G, et al. An estimation method of defect size from MFL image using visual transformation convolutional neural network [J]. IEEE Transactions on Industrial Informatics, 2019, 15(1):213-224.
- [42] WU Z N, DENG Y M, LIU J H, et al. A reinforcement learning-based reconstruction method for complex defect profiles in MFL inspection[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:2506010.
- [43] YUKSEL V, TETIK Y E, BASTURK M O, et al. A novel cascaded deep learning model for the detection and quantification of defects in pipelines via magnetic flux leakage signals [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72:2512709.

(上接第 37 页)

表 3 磁悬液体积分数为 2.0 时的检测

特征	效果对比			%
	平放状态	斜放状态	立放状态	
磁悬液流畅性	10	60	100	
磁化时间有效性	100	100	100	
分辨力	60	100	100	
对比度	50	100	100	
检测效率	50	100	100	

表 4 磁悬液体积分数为 2.4 时的检测

特征	效果对比			%
	平放状态	斜放状态	立放状态	
磁悬液流畅性	10	60	100	
磁化时间有效性	100	100	100	
分辨力	40	70	100	
对比度	30	80	100	
检测效率	30	80	100	

5 结语

试验结果证明对不同结构工件进行不同方位检测时,如不可转动的筒体环缝、接管角缝、支座、复杂

工件等,为保证检测效率及缺陷检出率,应根据不同检测方位选择最佳效果的磁悬液浓度,条件允许的情况下立面状态检测时,应避免磁悬液浓度靠近下限值;水平面状态检测时,应避免磁悬液浓度靠近上限值;磁悬液体积分数选择为 1.6~2.0 时,可同时兼顾多种检测方位。

参考文献:

- [1] 姚力,范吕慧,胡学知.承压设备磁粉检测技术发展现状[J].无损检测,2014,36(11):28-34.
- [2] 刁海波,孙晓明,马晶晶,等.磁轭放置方式对磁粉检测灵敏度影响的有限元分析[J].无损检测,2014,36(12):73-75,80.
- [3] 崔省安,赵伟军,魏波,等.标准 NB/T 47013.4—2015 中几处问题的探讨[J].无损检测,2022,44(11):62-64,68.
- [4] 崔克楠.风电塔架的磁粉检测工艺优化[J].无损检测,2022,44(2):57-59,72.
- [5] 宋志哲.磁粉检测[M].北京:中国劳动社会保障出版社,2007.