

DOI: 10.19650/j.cnki.cjsi.J2413188

基于 YOLOv8 的油气管道漏磁检测缺陷 智能识别技术研究*

李春晖, 吕 岩, 孟祥来, 李玲慧, 蒲晓晨

(中油管道检测技术有限责任公司 廊坊 065000)

摘 要:油气管道漏磁检测是评估管道完整性的重要手段,但传统人工分析方法存在效率低、误判率高等问题,故提出了一种基于 YOLOv8 深度学习算法的油气管道漏磁检测智能识别方法,实现管道缺陷的自动化检测。研究创新性地构建了一套基于人工标注经验的自动化训练数据集生成方法,有效继承了专家领域知识,显著提升了数据集构建效率。通过对漏磁信号进行预处理和图像增强,将原始数据转换为标准化灰度图像,并采用自适应图像增强策略,有效提升了图像质量和目标特征的可区分性。从实际工程项目中采集并生成 36 098 张高质量漏磁图像,其中 3 403 张含缺陷图像用作训练集。缺陷在管道轴向-周向平面上呈现相对均匀分布,在焊缝位置存在局部高密度区域,尺寸主要集中在较小范围内并呈现长尾分布特征,为模型训练提供了扎实的数据基础。训练过程中,模型的精确率 P 和召回率 R 指标分别稳定在 0.66 和 0.60, $mAP@0.5$ 指标稳定于 0.57,而 $mAP@[0.5:0.95]$ 达到 0.27。在实际工程数据测试中,模型的精确率、召回率和 $F1$ 分数分别达到 63.17%、65.24% 和 64.19%,验证了 YOLOv8 模型在管道检测任务中的可行性和优异的检测性能。该方法不仅显著提高了检测效率,降低了人工成本,而且有效避免了人为因素导致的判断偏差。研究结果表明,基于深度学习的智能识别方法在油气管道漏磁检测领域具有广阔的应用前景。

关键词: 油气管道;漏磁检测;深度学习;YOLOv8;目标检测;数据集

中图分类号: TH878 TP391.41 文献标识码: A 国家标准学科分类代码: 440.55

Research on intelligent defect recognition in oil and gas pipeline magnetic flux leakage detection based on YOLOv8

Li Chunhui, Lyu Yan, Meng Xianglai, Li Linghui, Pu Xiaochen

(China Petroleum Pipeline Inspection Technologies Co., Ltd, Langfang 065000, China)

Abstract: Magnetic flux leakage detection in oil and gas pipelines is a crucial method for evaluating pipeline integrity. However, traditional manual analysis methods suffer from low efficiency and high false detection rates. This study proposes an intelligent recognition method for pipeline magnetic flux leakage detection based on the YOLOv8 deep learning algorithm, achieving automated detection of pipeline defects. The research innovatively constructs an automated training dataset generation method based on manual annotation experience, effectively inheriting expert domain knowledge, and significantly improving dataset construction efficiency. Through preprocessing and image enhancement of magnetic flux leakage signals, raw data are converted into standardized grayscale images, and an adaptive image enhancement strategy is adopted to effectively improve image quality and feature distinguishability. In this study, a dataset of 36,098 high-quality magnetic flux leakage images is collected and generated from real-world engineering projects, including 3,403 defect-containing images used as the training set. The defects exhibit a relatively uniform distribution in the axial-circumferential plane of the pipeline, with localized high-density regions near weld seams. The defect sizes are predominantly within a smaller range, exhibiting a long-tailed distribution, providing a solid data foundation for model training. During training, the model's precision and recall metrics stabilized at 0.66 and 0.60, respectively, with an $mAP@0.5$ of 0.57 and an $mAP@[0.5:0.95]$ of 0.27. Testing on real-world engineering data achieves a precision of 63.17%, recall of 65.24%, and an $F1$ score of 64.19%. The feasibility and excellent detection performance of the YOLOv8 model for pipeline inspection tasks are verified. This method not only significantly

收稿日期: 2024-08-19 Received Date: 2024-08-19

* 基金项目: 中国石油管道局工程有限公司科技开发课题(2023-13)项目资助

improves detection efficiency and reduces manual costs but also effectively avoids judgment bias caused by human factors. The results show that deep learning-based intelligent recognition methods have broad application prospects in pipeline magnetic flux leakage detection.

Keywords:oil and gas pipeline; magnetic flux leakage detection; deep learning; YOLOv8; object detection; dataset

0 引 言

油气管道作为能源系统的命脉,其安全运行至关重要。然而,由于服役年限延长、地质条件变迁、介质侵蚀作用以及人为破坏等诸多因素,油气管道面临着失效风险^[1]。为全面开展管道完整性管理,有效检测管道缺陷尤为重要。多种无损检测(non-destructive testing, NDT)技术应运而生,如电磁超声导波(electromagnetic ultrasonic guided wave, EUGW)、漏磁检测(magnetic flux leakage, MFL)、涡流检测(eddy current, EC)、微波检测(microwave testing, MT)和声发射检测(acoustic emission, AE)等。其中,漏磁检测技术具有可靠性高、对环境要求低、无需耦合剂以及对高渗透性缺陷检测效果良好等优势,是当前应用最为广泛的管道检测方法之一^[2-3]。

通过分析检测到的漏磁信号,可详细了解管道实际运行状况及特征对象分布情况。然而,由于管道通常延伸数百甚至数千公里,因此获得的漏磁数据量庞大。传统的人工分析方式存在效率低下、误判率高、成本高昂等诸多问题。此外,缺乏统一的缺陷判别标准,使得分析结果容易受到人员专业水平和主观因素的影响,增加了漏检或误检的风险^[4]。

近年来,缺陷自动检测算法的研究取得了显著进展。传统机器学习方法中,文献[5]提出结合二维主成分分析与卷积自编码器的方法,实现半导体晶片表面缺陷的精确识别。文献[6]采用多尺度支持向量机与决策树的监督机器学习方法,成功应用于铝板裂纹缺陷检测。随着深度学习的发展,文献[7]通过改进 YOLOv5(you only look once, YOLO)网络架构,提出了一种适用于小管径弯头畸变漏磁缺陷检测的目标检测方法,实现了良好的检测性能。尽管传统机器学习方法在特定场景下表现出色,但其有限的特征表征能力难以适应复杂管道环境下多样化的缺陷形态,在检测效率和位置定位精度方面仍存在明显局限性。相比之下,深度学习技术构建的端到端智能识别模型能够自动从原始数据中提取高层次特征,有望突破传统算法瓶颈,实现高精度智能识别。将深度学习方法引入海量漏磁数据分析中,不仅能实现自动化批量处理,还可显著降低人为干预因素,从而提升分析结果的准确性和可靠性。因此,研发高性能深度学习智能识别算法已成为推动油气管道漏磁检测技术创新发展的关键方向。

本研究提出了一种基于 YOLOv8 目标检测算法的管道缺陷智能识别方法。创新性地构建了大规模自动生成的训练数据集,不仅显著提高了数据处理效率,还使模型能够学习到管道各个位置的特征。对 YOLOv8 网络进行充分训练,最终建立了高精度的漏磁曲线缺陷智能识别系统。该系统实现了缺陷的自动化、智能化识别,为管道完整性评估和维护决策提供了有力支撑。

1 构建管道特征目标检测数据集

1.1 管道漏磁内检测数据采集

漏磁检测是检测油气管道异常的有效手段。其原理是利用外加磁场使铁磁管壁饱和和磁化,然后通过磁传感器检测管壁表面的漏磁信号。在饱和磁化状态下,管壁缺陷或异常会导致磁力线畸变,从而产生可被探测的漏磁信号。通过对这些信号进行定量分析,可实现对管道进行定性和定量分析^[8]。管道漏磁检测的基本原理如图 1 所示。




图 1 管道漏磁检测原理

Fig. 1 Schematic of the pipeline magnetic flux leakage detection principle

管道漏磁内检测装置主要由 4 个部分组成:动力节、测量节、计算机节和电池节^[9]。系统的整体结构如图 2 所示。各部分采用密闭耐压结构,通过万向节软连接,并用皮碗支撑在管道内。测量节是核心部分,包含磁化装置和霍尔探头,用于产生稳定磁场和采集漏磁信号。计算机节负责过程控制、数据处理和数据存储,而里程轮用于触发数据采集并记录检测位置信息。

检测过程中采集的数据分为磁数据和非磁数据。磁数据是由磁传感器检测到的包含缺陷信息的漏磁数据,而非磁数据包括速度、压力和温度等参数。为区分数据块




图2 管道漏磁内检测装置结构

Fig. 2 The pipeline magnetic flux leakage internal detection device structure

并记录非磁数据,每个数据块末尾添加块尾记录,包含各种运行状态信息^[10]。

漏磁原始数据通常以二进制格式存储。在分析前,需进行数据预处理,包括坏通道处理、数据归一化和噪声滤波等,以提高信号质量,为后续分析奠定基础。

1.2 管道漏磁信号成像

目标检测作为计算机视觉领域的关键技术,在图像和视频中进行对象定位与识别方面具有重要应用价值^[11]。漏磁检测系统通常采集轴向、径向和周向3个空间分量的信号。其中轴向信号因具有最佳的信噪比和最显著的形态特征,被优先用于后续的图像处理与分析^[12]。

在数据处理过程中,数据分析系统处理预处理后的轴向分量数据。其数据结构反映了检测数据的空间分布:行方向对应检测的轴向采样位置,列方向对应周向采样位置。根据工程实践,单幅图像通常涵盖4 m轴向检测长度的信号数据。软件将这些轴向分量数据直接映射为灰度图像,可视化管道漏磁数据,便于机器学习算法进行识别和解析。

原始生成的灰度图像常存在对比度不足等质量问题,可能导致目标特征模糊,影响检测算法的性能。针对这一问题,提出了一种自适应图像增强策略,旨在提升图像质量和目标特征的可区分性。

所提出的图像增强策略包含以下关键步骤:

1) 对轴向数据进行统计分析,以准确量化数据的分布特性。

2) 基于数据分布特征,采用自适应阈值算法剔除异常值和极端数据点,从而有效抑制噪声干扰,并将数据优化至最佳动态范围。

3) 基于处理后的数据生成新的灰度图像,以增强目标信号的可见性和可辨识度。

如图3所示是两种方式生成的灰度图像和它们的灰度直方图的对比情况,实验结果表明该增强策略显著提升了缺陷特征的表现力。从图像效果上看,增强后的图像呈现出更为清晰的缺陷边缘和更高的局部对比度。从灰度直方图分析结果来看,处理后的图像灰度值分布更

加均匀,灰度层次更为丰富,说明图像整体对比度得到了有效改善。该策略在提升图像质量的同时,较好地保持了原始图像的细节信息,为后续的缺陷检测与分析提供了更可靠的数据支撑。




图3 管道漏磁信号轴向分量灰度图像及其直方图对比

Fig. 3 Comparison of grayscale images and their histograms for axial MFL signal component

在漏磁内检测过程中,检测器搭载的强磁铁通过钢刷将磁力线耦合入管壁,在管壁周向形成纵向磁回路场,使检测区域的管壁达到磁饱和状态。当管壁材质均匀完整时,磁力线在管壁内均匀分布;而当存在缺陷或结构不连续时,磁力线无法直接通过,就会形成畸变的、不连续的磁通回路,从而产生漏磁场。通过对这些漏磁信号形态特征的标定分析,可构建标准化的图像数据集,为目标检测算法的训练与验证提供数据支撑。

1.3 管道漏磁信号图像标注并构成数据集

深度学习模型的训练过程中,高质量的训练数据集是确保模型性能的关键因素。具体到管道缺陷检测领域,训练数据集主要由管道图像数据及其对应的缺陷位置标注文件构成。然而,传统人工标注方法不仅耗费大量人力资源,同时难以满足大规模数据集构建的需求。针对这一问题,提出了一种基于历史人工标注经验的自动化训练集生成方法,该方法可以有效继承专家领域知识,并显著提高数据集构建效率。

本方法的实现过程包含以下5个关键阶段:

1) 参数配置阶段:配置图像采集参数,包括工程信息、图像分辨率、图像增强参数、信号采集方向等。

2) 数据获取与预处理阶段: 基于配置参数从数据库中检索符合要求的管节列表, 并依次提取各管节数据构建二维特征矩阵。

3) 数据处理阶段: 采用 4 m 标准长度和预设重叠长度对管节特征矩阵执行滑动分割, 生成连续的子分割矩阵序列。

4) 图像生成阶段: 对子分割矩阵序列应用图像增强算法, 将原始数据转换为灰度图像。

5) 标注生成阶段: 提取并处理子分割矩阵中的已有工标注缺陷信息, 并将跨越 0 点周向的缺陷分离为独立缺陷, 最终生成符合深度学习训练要求的标注文件。

从实际工程项目中采集并生成了 36 098 张高质量的漏磁图像作为数据集。每张图像对应实际管道的 4 m 长度, 采用 960 pixels×640 pixels 的分辨率格式。研究中的检测目标为管道缺陷, 在漏磁图像中典型表现为线状或椭圆形信号模式, 采用矩形边界框进行标注, 如图 4 所示, 以便于后续的检测和定位。




图 4 管道漏磁信号图像数据集标注示例
Fig. 4 Annotation examples of pipeline MFL signal image dataset

数据集按照 8:2 比例划分, 随机抽取 28 878 张图像, 其中 3 403 张含有缺陷, 这部分作为训练集。其余的 7 220 张图像作为验证集。对训练集的统计分析显示包含 8 194 个缺陷实例, 为模型提供了充足的缺陷样本。如图 5(a) 所示, 缺陷在管道轴向-周向平面上呈现相对均匀分布, 在焊缝位置存在局部高密度区域, 而特定周向位置则表现为低密度分布。图 5(b) 的缺陷尺寸散点图显示, 缺陷尺寸主要集中在较小范围内, 同时在较大尺寸区域呈现长尾分布特征。这种分布特性有利于模型学习不同位置和类型的缺陷特征。




图 5 图像数据集缺陷对象分布分析
Fig. 5 Distribution analysis of defect objects in image dataset

2 YOLOv8 算法

YOLO 算法是一种单阶段目标检测算法, 它将目标检测任务转化为一个回归问题, 通过单次前向传播即可同时预测目标的位置和类别信息^[13]。采用 YOLOv8-l 模型进行实验, 该模型在检测精度、推理速度等性能指标具有显著优势。YOLOv8 的网络结构图如图 6 所示, 主要包含的关键组件有: 主干网络, 特征融合网络和检测头。




图 6 YOLOv8 网络结构
Fig. 6 Architecture diagram of YOLOv8 network

主干网络: 负责从输入图像中提取多尺度特征。采用改进的 CSPDarknet (cross-stage partial network Darknet) 架构, 通过创新性的 C2f 模块设计, 在保持网络轻量化的同时实现了更丰富的梯度流信息。

特征融合网络: 承担特征聚合与增强的功能。采用路径聚合网络 (path aggregation network, PANet) 的设计原理, 实现了自顶向下和自底向上的双向特征融合机

制^[14]。从而提升了网络对不同尺度目标的检测能力,特别是对小目标的检测效果。

检测头:生成最终检测结果。采用解耦式设计策略,将分类和边界框回归任务分离处理^[15]。检测范式从传统的基于锚框的方法转变为无锚框的方法^[16]。使用TaskAlignedAssigner样本分配策略^[17],并引入Distribution Focal Loss损失函数优化模型训练^[18]。

YOLOv8在漏磁检测中的工作流程为:

1) 图像预处理阶段:将输入图像规范化处理并划分为网格矩阵,通常采用13×13或26×26的网格结构配置。每个网格单元均作为独立的检测区域进行分析。

2) 特征提取阶段:通过深层卷积神经网络进行多尺度特征提取,构建层次化的特征表示,有效捕获目标的几何特征、纹理信息和语义特征。

3) 目标定位阶段:采用无锚框预测策略,模型对每个网格单元预测多个边界框,用于表征潜在目标的位置和尺寸信息。预测结果包含边界框的中心点坐标、宽度和高度,同时输出每个目标所属类别的概率分布。

4) 后处理优化阶段:通过非极大值抑制(non-maximum suppression, NMS)算法对初始检测结果进行优化。该算法通过评估重叠边界框的置信度,筛选并保留最优预测结果,有效消除冗余检测。

5) 结果输出阶段:生成标准化的检测结果列表,包含每个检测目标的预测类别、置信度分数以及边界框坐标,为后续的目标分析提供定量依据。

考虑到管道缺陷检测对高精度的需求,本研究选择性能优异的YOLOv8-l模型进行训练和部署。通过迁移学习策略和针对性的超参数优化,使其满足漏磁缺陷的检测需求^[19]。

3 模型训练

考虑到本研究中图像的灰度特性和周向旋转特征,设计了包括Mosaic数据增强、RandomBrightnessContrast亮度对比度调整以及随机水平/垂直翻转预处理方法。这些经过验证集优化的策略显著提升了训练数据的多样性和模型的鲁棒性。其中,Mosaic技术通过多图像拼接有效模拟复杂检测场景,特别增强了小目标的检测能力;RandomBrightnessContrast则模拟不同的亮度对比度条件;随机翻转扩展了目标的空间分布特征。这种组合增强策略不仅有效缓解了过拟合问题,同时提升了模型对不同尺度、方向和位置目标的检测鲁棒性。

采用基于Open Images V7数据集预训练的YOLOv8模型作为基础网络,保持它标准架构的基础上,对关键超参数进行了针对性优化。训练过程中主要关注以下评价指标:

损失函数(Loss):衡量检测模型预测结果与真实标

签之间差异的数值度量,通过最小化损失函数,可以使模型在训练过程中逐渐优化参数,提高模型的预测准确性。

交并比(intersection over union, IoU):定义为预测边界框与真实边界框的交集面积与并集面积之比,用于评估目标定位的准确度。计算公式为:

$$IoU = \frac{A \cap B}{A \cup B} \quad (1)$$

其中, $A \cap B$ 为预测框与真实框的交集面积, $A \cup B$ 为预测框与真实框的并集面积。

精确率(Precision, P):表示在所有被模型预测为正类的样本中,真实正类样本的比例。计算公式为:

$$P = \frac{TP}{TP + FP} \quad (2)$$

其中, TP 为真阳性样本数, FP 为假阳性样本数。

召回率(Recall, R):表示在所有真实正类样本中,被模型正确识别的比例。计算公式为:

$$R = \frac{TP}{TP + FN} \quad (3)$$

其中, FN 为假阴性样本数。

平均精度均值(mean average precision, mAP):在不同IoU阈值下计算得到的平均精度均值,是目标检测任务中最重要的综合性能指标。该值越高,代表检测结果就越好。 mAP 的计算公式如式(4)所示。

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (4)$$

其中, n 表示数据集中目标的种类数,本研究取 $n=1$; AP 是以召回率 R 为横轴、精确率 P 为纵轴所形成的PR曲线下的面积。 $mAP@0.5$ 表示在IoU阈值为0.5时的平均精度, $mAP@[0.5:0.95]$ 表示在IoU阈值从0.5到0.95(步长0.05)共10个阈值下的平均精度均值。

F1分数:精确率和召回率的加权调和平均值,该指标在精确率和召回率之间取得平衡,为模型性能提供综合评估。计算公式为:

$$F1 = \frac{2 \times P \times R}{P + R} \quad (5)$$

如图7是模型训练过程关键参数变化曲线。训练过程中,损失函数呈现持续下降趋势,模型的网络参数不断的优化和调整。实验结果表明,模型在训练过程中精确率与召回率均呈现单调上升趋势,最终分别收敛至0.66和0.60,证实了模型在查准率与查全率之间具有较好的均衡性。 $mAP@0.5$ 指标稳定于0.57,证实了模型在标准IoU阈值下的优异表现;而 $mAP@[0.5:0.95]$ 达到0.27的水平,显示了模型在严格评估标准下仍保持稳定的检测能力。各项指标的收敛趋势表明,模型已达到了理想的训练效果。




图 7 YOLOv8 模型训练过程关键参数变化曲线

Fig. 7 Key parameter variation curves during YOLOv8 model training

4 实验验证及分析

4.1 测试过程

将训练完成的 YOLOv8 模型部署至数据分析系统中,并采用训练过程中获得的最优模型权重进行推理。在实际工程数据测试中,模型在数据中识别结果示例如图 8 所示。

实验结果表明,YOLOv8 算法能够有效检测漏磁数据中的缺陷信号特征。该算法准确定位了漏磁图像中的缺陷位置,并生成精确的边界框标注,从而实现管道缺陷的自动化检测。这些结果充分验证了 YOLOv8 算法在漏磁检测领域的应用可行性。

4.2 测试结果评价

为客观评估模型性能,采用混淆矩阵作为主要评估工具。混淆矩阵通过矩阵形式展示模型预测结果与真实标签之间的对应关系,其中矩阵元素 (i,j) 表示实际属于类别 i 但被预测为类别 j 的样本数量^[20]。基于混淆矩阵,计算了精确率 P 、召回率 R 和 $F1$ 分数等关键性能指标。




图 8 基于 YOLOv8 的管道缺陷智能识别系统检测结果示例

Fig. 8 Detection result examples of pipeline defect intelligent recognition system based on YOLOv8

表 1 展示了模型在测试集上的混淆矩阵结果。根据式(2)~(4)计算得出:精确率 P 为 63.17%,召回率 R 为 65.24%, $F1$ 值为 64.19%。表明该方法在缺陷识别方面具有良好的准确性和检出能力,可有效降低误报和漏检风险。

表 1 缺陷检测结果混淆矩阵

Table 1 Confusion matrix of defect detection results		
实际\预测	缺陷	背景
缺陷	2 237	1 192
背景	1 304	—

在检测效率方面,本方法处理每公里管道数据仅需 0.58 min,相比传统人工检测方法(45 min/km)提升了约 76.6 倍。这一显著的效率提升对于大规模管道检测具有重要的实践意义。实验结果表明,基于 YOLOv8 的智能检测方法不仅保证了检测的准确性,还极大地提高了检测效率,为管道完整性评估提供了有力的技术支持。

5 结 论

本研究提出了一种基于 YOLOv8 深度学习算法的油气管道漏磁检测智能识别方法,针对传统人工分析存在效率低、误判率高等问题,实现了管道缺陷的自动化检测,对油气管道完整性评估具有重要意义。首先,构建了一种基于人工标注经验的自动化训练数据集生成方法,有效继承了专家领域知识,并通过预处理和图像增强策略显著提升了图像质量。通过这种方法,从实际工程项目中采集并生成了 36 098 张高质量漏磁图像,并从中筛选出 3 403 张含缺陷图像作为训练集,为模型训练提供了坚实的数据基础。在训练过程中,模型的 P 、 R 、 $mAP@0.5$ 和 $mAP@[0.5:0.95]$ 指标分别稳定在 0.66、0.60、0.57 和 0.27;而在实际工程数据测试中,其精确率、召回率和 $F1$ 分数分别达到 63.17%、65.24% 和 64.19%,验证了该方法的可行性和优秀的检测性能。在检测效率方面,本方法处理每公里管道数据仅需 0.58 min,相比传统人工检测方法提升了约 76.6 倍,对于大规模管道检测具有重要的实践意义。综上所述,实验结果表明,该方法不仅显著提高了检测效率、降低了人工成本,而且有效避免了人为判断偏差,在油气管道漏磁检测领域展现出广阔的应用前景。

参考文献

[1] HUANG S L, PENG L SH, SUN H Y, et al. Deep learning for magnetic flux leakage detection and evaluation of oil & gas pipelines: A review[J]. Energies, 2023, 16(3): 1372.

[2] 左万君,戴西斌,吴昌玉. 漏磁检测在管道损伤探测中的应用[J]. 无损检测, 2024, 46(3): 56-63.

ZUO W J, DAI X B, WU CH Y. Application of magnetic flux leakage detection in pipeline damage detection[J]. Nondestructive Testing, 2024, 46(3): 56-63.

[3] 熊毅,刘帅,黄鹏,等. 含缺陷管道磁化状态与漏磁

信号规律研究[J]. 电子测量技术, 2023, 46(12): 187-192.

XIONG Y, LIU SH, HUANG P, et al. Research on magnetization state and magnetic flux leakage signal law of defective pipeline[J]. Electronic Measurement Technology, 2023, 46(12): 187-192.

[4] 赵翰学,张咪,郭岩宝,等. 基于机器学习的管道金属损失缺陷识别方法[J]. 石油机械, 2020, 48(12): 138-145.

ZHAO H X, ZHANG M, GUO Y B, et al. Metal loss defect identification method of pipeline based on machine learning[J]. China Petroleum Machinery, 2020, 48(12): 138-145.

[5] YU J B, LIU J T. Two-dimensional principal component analysis-based convolutional autoencoder for wafer map defect detection [J]. IEEE Transactions on Industrial Electronics, 2021, 68(9): 8789-8797.

[6] PASADAS D J, BASKARAN P, RAMOS H G, et al. Detection and classification of defects using ECT and multi-level SVM model[J]. IEEE Sensors Journal, 2020, 20(5): 2329-2338.

[7] 赵鹏程,秦浩东,张颖. 小管径弯头畸变漏磁缺陷图像智能识别方法[J]. 电子测量技术, 2024, 47(8): 181-188.

ZHAO P CH, QIN H D, ZHANG Y. Intelligent recognition method for magnetic flux leakage defect image of small diameter elbow distortion[J]. Electronic Measurement Technology, 2024, 47(8):181-188.

[8] 杨理践,梁成壮,高松巍,等. 管道漏磁内检测的管壁缺陷漏磁场解析模型[J]. 电子测量与仪器学报, 2021, 35(7):106-114.

YANG L J, LIANG CH ZH, GAO S W, et al. Analytical model of magnetic flux leakage field for wall defects in pipeline magnetic flux leakage internal inspection [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(7):106-114.

[9] 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.

[10] 黄松岭,赵伟. 漏磁成像理论与方法[M]. 清华大学出版社, 2016: 168.

HUANG S L, ZHAO W. Theory and method of magnetic flux leakage imaging [M]. Tsinghua University Press, 2016: 168.

[11] 赵永强,饶元,董世鹏,等. 深度学习目标检测方法

- 综述[J]. 中国图象图形学报, 2020, 25(4): 629-654.
- ZHAO Y Q, RAO Y, DONG SH P, et al. Survey of deep learning object detection methods[J]. Journal of Image and Graphics, 2020, 25(4): 629-654.
- [12] 杜文飞, 李春光, 万四海. 管道漏磁检测的智能方法综述[J]. 西南师范大学学报(自然科学版), 2022, 47(6): 1-7.
- DU W F, LI CH G, WAN S H. A review of intelligent methods for pipeline magnetic flux leakage detection[J]. Journal of Southwest China Normal University (Natural Science Edition), 2022, 47(6): 1-7.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [14] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [15] GE ZH, LIU S T, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. Arxiv preprint arXiv: 2107.08430, 2021.
- [16] TIAN ZH, SHEN CH H, CHEN H, et al. FCOS: Fully convolutional one-stage object detection[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9627-9636.
- [17] FENG CH J, ZHONG Y J, GAO Y, et al. TOOD: Task-aligned one-stage object detection[C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 3490-3499.
- [18] LI X, WANG W H, WU L J, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection[J]. Advances in Neural Information Processing Systems, 2020, 33: 21002-21012.
- [19] ZHANG J, LI CH Y, SHENG L. Transfer learning-based defect detection for natural gas pipelines[C]. 2023 42nd Chinese Control Conference, 2023: 4979-4984.
- [20] SOKOLOVA M, LAPALME G. A systematic analysis of performance measures for classification tasks[J]. Information Processing and Management, 2009, 45(4): 427-437.

作者简介



李春晖(通信作者), 2013 年于哈尔滨工业大学获得学士学位, 2015 年于哈尔滨工业大学获得硕士学位, 现为中油管道检测技术有限公司工程师, 主要研究方向为管道检测技术及深度学习技术的应用等。
E-mail: jc_lichunh@cnpc.com.cn

Li Chunhui (Corresponding author) received his B. Sc. degree from Harbin Institute of Technology in 2013, received his M. Sc. degree from Harbin Institute of Technology in 2015. He is currently an engineer at China Petroleum Pipeline Inspection Technologies Co., Ltd. His main research interests include pipeline inspection technology and the application of deep learning technology, etc.



吕岩, 1999 年于青岛大学获得学士学位, 2004 年于中国科学院研究生院获得博士学位, 现为中油管道检测技术有限公司工程师, 主要研究方向为人工智能技术应用。
E-mail: 22910265@qq.com

Lyu Yan received his B. Sc. degree from Qingdao University in 1999, received his Ph. D. degree from Graduate University of Chinese Academy of Sciences in 2004. He is currently an engineer at China Petroleum Pipeline Inspection Technologies Co., Ltd. His main research interest includes the application of artificial intelligence technology.