

小管径弯头畸变漏磁缺陷图像智能识别方法^{*}

赵鹏程 秦浩东 张颖

(常州大学安全科学与工程学院 常州 213164)

摘要: 为了解决小管径弯头不饱和磁化造成的缺陷漏磁信号图像畸变问题,实现弯头畸变漏磁缺陷图像智能化、高精度识别,提出一种小管径弯头畸变漏磁缺陷图像智能识别方法。采用 MSRCR-HF 图像增强算法处理弯头缺陷畸变图像,并在 YOLOv5 网络中集成 CBAM 和 SPD-Conv 模块进行网络优化,通过仿真建立弯头缺陷数据集输入网络中进行训练和测试。结果表明,提出的 MSRCR-HF 算法能有效解决弯头漏磁缺陷图像畸变问题,改进的 YOLOv5 模型在建立的数据集上具有较高的识别精度,矩形槽缺陷识别精度为 95.5%,半球形缺陷识别精度为 93.0%。该方法对于小管径弯头畸变漏磁缺陷智能识别具有较高的可行性,可提高管道安全检测效率。

关键词: 弯头;漏磁;缺陷识别;YOLOv5;图像增强

中图分类号: TN06 文献标识码: A 国家标准学科分类代码: 620.5040

Intelligent identification method for distortion magnetic flux leakage defects image of small-diameter pipe elbows

Zhao Pengcheng Qin Haodong Zhang Ying

(School of Safety Science and Engineering, Changzhou University, Changzhou 213164, China)

Abstract: In order to solve the problem of image distortion of defect magnetic flux leakage (MFL) signal caused by unsaturated magnetization of small pipe diameter elbow, and realize intelligent and high-precision identification of elbow distortion magnetic flux leakage defect image. This paper proposed an intelligent image identification method for distortion MFL defects in small-diameter pipe elbows. The MSRCR-HF image restoration algorithm was applied to process the distorted images, which to solve the problem of defective image distortion caused by the weak MFL signal of the elbow. The YOLOv5 network was optimized by integrating the CBAM and the SPD-Conv module to improve the network's feature extraction ability for elbow distortion and MFL defects. Finally, the elbow defect datasets were established through simulation, and it was input into the network for training and testing. The results shown that the MFL signal image of the same defect at the elbow was distorted, and the defect feature information cannot be directly and effectively obtained. The proposed MSRCR-HF algorithm effectively resolved the image distortion problem associated with elbow MFL defects. Additionally, the improved YOLOv5 model achieved high recognition accuracy on the established dataset, with accuracy rates of 95.5% for rectangular groove defects, and 93.0% for hemispherical defects. This method exhibited strong feasibility for intelligent identification of distortion MFL defect in small-diameter pipe elbows and can improve the efficiency of pipeline safety inspection.

Keywords: elbow; magnetic flux leakage; defect identification; YOLOv5; image enhancement

0 引言

管道是油气输送的主要载体,由于长期服役于地下复杂内外环境中,易形成腐蚀等缺陷^[1]。受通过能力和磁化效果等因素影响,漏磁内检测技术难以在 DN100 小管径管道中有效实施。此外,弯头对改变油气输送方向至关重要,

弯头受腐蚀等缺陷造成的油气泄露是油田安全生产的难题^[2],且对环境土壤造成严重的污染,亟需高效的缺陷识别方法保障其安全运行。

漏磁检测技术是一种广泛应用于油气管道的缺陷检测方法^[3-5],诸多学者基于漏磁信号,采用神经网络和图像处理方法对缺陷进行了有效识别。Ege 等^[6]设计了两种新的

MFL 检测器, 可用于研究速度变量对漏磁信号的影响, 同时实现了管道缺陷的识别。Tzelepi 等^[7]采用模型再训练方法获得了更有效的缺陷特征描述。Yang 等^[8]提出一种优化卷积核的管道焊缝漏磁图像分类方法, 引入稀疏约束和图像同源相似性约束规则提高了网络的分类能力。Pan 等^[9]采用改进的 CLIQUE 缺陷标记算法, 对缺陷的数量和位置进行了识别预测。刘金海等^[10]建立了一种自监督的管道漏磁缺陷检测方法, 克服了缺陷检测方法对样本数量的依赖性。陈俊杰^[11]提出一种油气管道缺陷分段识别方法, 通过阈值判断较好地区分缺陷区域与非缺陷区域。赵翰学等^[12]采用 3 种机器学习模型对管道金属损失缺陷进行了识别分类, 获得了较高的识别效果。卢森壤等^[13]提出一种基于多维度选择性搜索的小样本缺陷识别方法, 有效解决了缺陷识别边界定位不准确问题。上述方法主要针对长输油气管道展开研究, 注重对缺陷特征的提取和神经网络分析方法, 而对小管径管道漏磁缺陷识别的研究相对较少。同时, 受弯头结构特性和信号检测能力的影响, 弯头处缺陷漏磁信号在图像上会发生畸变现象, 易导致缺陷识别的误判和漏判。因此, 解决小管径弯头漏磁内检测缺陷图像畸变问题, 提高缺陷识别精度具有重要意义。

为解决上述问题, 本文提出一种小管径弯头畸变漏磁缺陷图像智能识别方法。首先, 利用图像增强方法, 处理弯头畸变漏磁缺陷图像; 其次, 对 YOLOv5 网络结构进行优化, 利用小管径弯头漏磁仿真模型建立弯头畸变漏磁缺陷数据集, 输入网络建立弯头畸变漏磁缺陷识别模型; 最后, 通过牵拉实验验证模型对缺陷的识别性能。经过训练和测试, 该方法能有效识别小管径弯头畸变漏磁缺陷。

1 小管径弯头漏磁检测仿真分析

1.1 弯头漏磁内检测仿真模型

利用 ANSYS Maxwell 19.0 软件建立了小管径弯头漏磁内检测仿真模型, 模型示意图如图 1 所示。模拟管道尺寸为 $\Phi 114 \times 8$ mm(外径 \times 壁厚), 弯头曲率半径为 3 D(D 为管道外径)。模拟将缺陷视为理想的规则形状, 通过局部减少壁厚来实现。为满足管道漏磁内检测器的通过性能和检测要求, 磁化单元采用浮块式结构, 两端附弹性装置可根据管道位置发生自适应径向扩张和收缩。

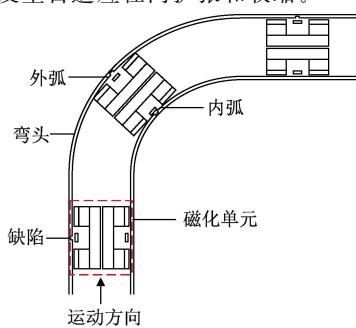


图 1 弯头漏磁内检测几何模型

建立的小管径管道弯头磁化单元结构如图 2 所示, 主要由永磁体、衔铁和钢刷等组成。8 个传感器盒沿管道环向方向均匀布置。每个传感器盒内布置多套三轴霍尔传感器和涡流传感器, 用于测量和区分管道内外壁缺陷引起的磁场信号。

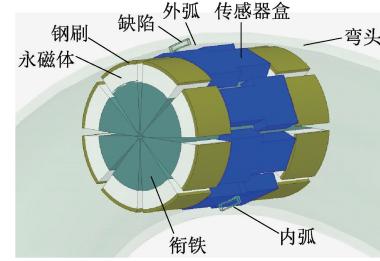


图 2 磁化单元结构

模型网格划分方式为自由划分, 缺陷处网格进行加密处理以获取精确的缺陷漏磁信号。模型整体被相对磁导率为 1.0 的空气域包围, 模型结构材料参数如表 1 所示。

表 1 模型材料及尺寸

部件	长度/mm	高度/mm	材料
管道	200	8	Q235
永磁体	30	10	N52
衔铁	120	30	10# 钢
钢刷	30	5	20# 钢

1.2 弯头畸变漏磁缺陷图像对比

为探究弯头缺陷漏磁信号在图像上的变化规律, 对同一缺陷在直管段和弯头段进行分析。图 3 和 4 分别为直管和弯头中相同缺陷的轴向漏磁信号图像。由图 3 可以观察到, 直管缺陷图像具有清晰的轮廓和色彩, 能够清晰地分辨出两种缺陷的类型。对比图 4 弯头内、外弧缺陷图像, 可以发现弯头内弧缺陷图像对比度更好, 能较清晰地观察到缺陷的轮廓细节。相反, 外弧缺陷图像轮廓不清晰, 图像对比度和饱和度不足。同时可以发现, 与直管同一缺陷相比, 由于弯头不饱和磁化的原因, 弯头内外弧处缺陷图像的漏磁信号强度均降低, 缺陷轮廓较为模糊, 发生了畸变现象。若直接对弯头畸变漏磁缺陷图像进行识别, 将无法有效识别其缺陷类型, 容易造成较大的误判。

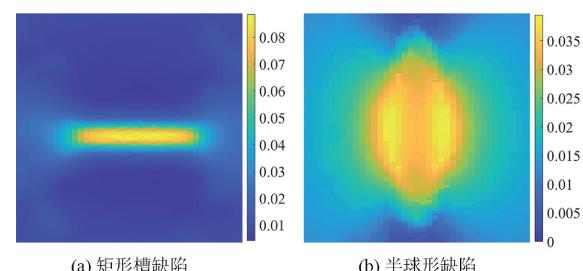


图 3 直管缺陷漏磁信号图像

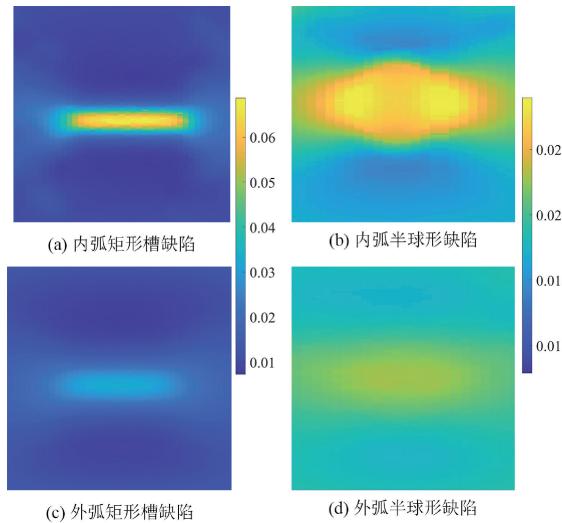


图4 弯头缺陷漏磁信号图像

1.3 弯头漏磁缺陷数据集

弯头缺陷的漏磁信号在图像上发生了畸变现象可以归因于两点。其一,由于漏磁检测装置在经过弯头时,受到弯头结构空间的限制,造成浮块式的磁化单元对弯头处缺陷的检测能力不足,出现不饱和磁化现象;其二,由于弯头结构的特殊性,在弯头不同位置和曲率的情况下,缺陷的漏磁信号在图像上亦会呈现处不同程度的畸变。因此,为了对

弯头畸变漏磁缺陷图像进行研究分析,利用建立的小管径弯头漏磁内检测仿真模型构建了弯头漏磁缺陷数据集。

数据集的缺陷类型包含矩形槽和半球形两种缺陷。针对影响弯头缺陷畸变的因素,并考虑到缺陷数据的多样性,仿真建立了3种弯头模型:1.5 D、3 D和4 D弯头。如图5所示,因为弯头的结构具有对称性,因此选择在弯头的多个位置建立缺陷,包括弯头的环向(即a路径)和轴向(即b路径)方向。其中,a路径上选取了5个缺陷位置,分别沿弯头环向的0°、45°、90°、135°和180°;b路径上选取了3个缺陷位置,分别沿弯头轴向的15°、30°和45°。同时,仿真缺陷的大小考虑了多种尺寸,并进行组合模拟。其中,矩形槽缺陷的长度范围设置在4~20 mm,宽度范围设置为2~10 mm;半球形缺陷的半径范围设置为2~10 mm。两类缺陷的深度范围均设置为10%~80% t(t为管道壁厚)。仿真模拟获得矩形槽缺陷和半球形缺陷共600个样本图像,仿真缺陷数据集的具体参数如表2所示。

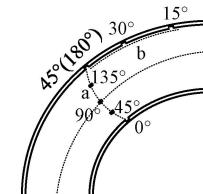


图5 弯头缺陷位置

表2 仿真缺陷数据集

缺陷	长度范围/mm	宽度范围/mm	半径范围/mm	深度范围/mm	缺陷数量	缺陷位置
矩形槽	4~20	2~10		10%~80% t	300	0°, 45°, 90°, 135°, 180° 15°, 30°, 45°
半球形			2~10	10%~80% t	300	0°, 45°, 90°, 135°, 180° 15°, 30°, 45°

2 弯头畸变漏磁缺陷智能识别方法

图像处理算法和目标检测算法被广泛应用于各类缺陷图像研究中,用于提升图像质量和识别分类工作。为了解决弯头漏磁缺陷图像畸变问题,并有效识别弯头漏磁缺陷,建立了一种小管径弯头畸变漏磁缺陷识别方法,识别流程如图6所示。主要步骤包括:首先,建立小管径弯头漏磁内检测仿真模型获取缺陷漏磁信号;其次,利用图像增强算法对弯头缺陷畸变图像做增强处理,建立缺陷数据集;最后,通过基于深度学习的目标检测算法建立弯头畸变漏磁缺陷识别模型,输出弯头畸变漏磁缺陷类别。

2.1 MSRCR-HF 图像增强方法

图像增强技术可以解决图像的畸变现象,还原其真实面貌^[14]。为了解决弯头漏磁缺陷图像的畸变问题,提出一种MSRCR-HF图像增强方法。首先,对弯头畸变漏磁缺陷图像做颜色恢复处理,还原缺陷区域的真实色彩;其次,对上一步处理后的图像做滤波处理,消除缺陷边缘区域模糊信号的干扰;最后,输出图像增强后的缺陷图像。

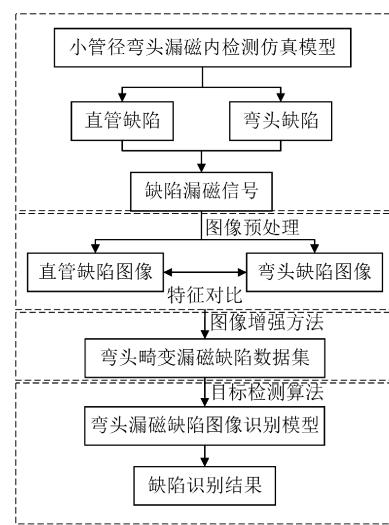


图6 弯头畸变漏磁缺陷识别流程

Retinex算法是一种用于解释人类色彩感知的色彩视觉理论^[15],其认为人眼识别物体颜色信息主要受物体表面

反射光的作用,而外界光照干预较小。在这个理论中,图像可以被描述为任何点或像素值的光反射率和照度分量的乘积。图像 $I(x, y)$ 的公式如下:

$$I(x, y) = R(x, y) \cdot L(x, y) \quad (1)$$

式中: (x, y) 为图像像素; $R(x, y)$ 和 $L(x, y)$ 分别为光反射和光照度分量。

经典的 Retinex 算法包括单尺度 Retinex(SSR), 多尺度 Retinex(MSR)和多尺度色彩恢复 Retinex (MSRCR) 算法。为了解决图像局部失真问题, 在 MSR 算法的基础上, MSRCR 算法中引入了颜色恢复因子, 如下:

$$R_{MSRCR}(x, y) = C_j(x, y) \cdot R_{MSR}(x, y) \quad (2)$$

$$C_j(x, y) = \mu \cdot \log \left[\eta \cdot \frac{I(x, y)}{\sum_{n=1}^N I_n(X, Y)} \right] \quad (3)$$

式中: $C_j(x, y)$ 表示颜色恢复因子; μ 和 η 分别表示图像颜色恢复的增益因子和偏移量。

同态滤波(homomorphic filtering, HF)是一种频域技术^[16], 主要用于测量动态范围压缩和对比度增加。采用频域滤波和灰度变换结合的方式, 通过对数运算将乘法运算转换为加法运算, 从而分离高、低频分量, 利用线性滤波再将频率域变换回空间域, 最后做指数运算。最后, 设置一个合适的滤波器 $H(u, v)$ 来消除低频或高频分量。最后, 进行指数运算以获得增强图像。公式如下:

$$H(u, v) = (r_h - r_l) [1 - e^{-\frac{D^2(u, v)}{D_0^2}}] + r_l \quad (4)$$

式中: D_0 表示截止频率; r_l 和 r_h 是影响滤波器低频和高频分量的决定因素; c 用于控制滤波函数斜角的锐化程度。

图 7 为 MSRCR-HF 算法处理弯头畸变缺陷漏磁图像的流程框图, 处理的结果如图 8 所示。

原始图像

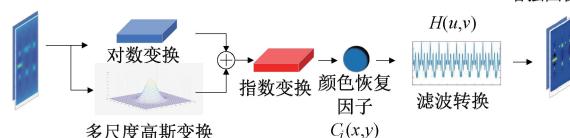


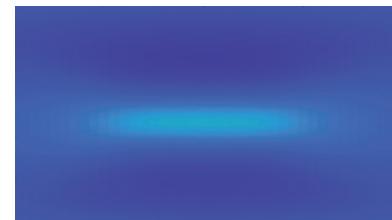
图 7 MSRCR-HF 算法框架

由图 8 可知, 提出的 MSRCR-HF 算法有效地解决弯头漏磁缺陷图像的畸变问题。经过图像增强处理后, 缺陷图像具有更明显的轮廓特征, 可有效识别缺陷类型, 利于后续的缺陷识别分析工作。

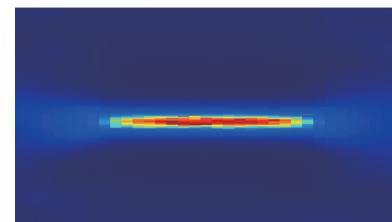
2.2 改进 YOLOv5 网络

YOLOv5 作为 YOLO 系列中使用最多的模型, 已广泛应用于缺陷检测领域。根据网络的深度和特征图的宽度, YOLOv5 可分为 4 种模型: YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x。这 4 种模型均由输入端、Backbone、Neck 和 Head 组成^[17]。

网络的输入端包括 Mosaic 数据增强、自适应初始锚框计算和图片缩放等操作对输入图像进行预处理; Backbone



(a) 原始缺陷图像



(b) 增强缺陷图像

图 8 缺陷图像增强结果

采用 Focus 下采样、CSP 结构和 SPP 池化金字塔结构来获取输入图像的特征信息; Neck 层通过 FPN+PAN 的特征金字塔结构来传递和融合多尺度目标特征信息; Head 采用 3 种损失函数分别计算分类、定位和置信度损失, 并通过 NMS 提高网络预测的准确度。

由于 YOLOv5 对小目标的检测能力不足, 因此, 为了提高网络对小管径弯头畸变漏磁缺陷的识别能力, 引入 SPD-Conv^[18] 和 CBAM^[19] 模块对网络结构进行优化, 解决多尺度问题, 并增强对缺陷的特征提取能力。同时, 为了保证模型检测的速度, 选用 YOLOv5s 网络作为基准模型。

SPD-Conv 模块是由一个空间-深度(SPD)层和一个非跨步卷积(Conv)层组成, 替换原跨步卷积层和池化层而成为新的卷积(convolutional neural networks, CNN)模块, 从而提高网络对小缺陷和低分辨率图像的检测性能。SPD 组件利用图像转换技术在 CNN 内部和整个 CNN 中进行特征图下采样, 对任意 $S \times S \times C_1$ 大小的中间特征图 X, 切出的一系列子特征图为 $f_{0,0}, f_{1,0}, \dots, f_{scale-1,0}; f_{0,1}, f_{1,1}, \dots, f_{scale-1,1}; \dots f_{0,scale-1}, f_{1,scale-1}, \dots, f_{scale-1,scale-1}$ 。每个子图按比例因子进行下采样。scale = 2 时, SPD-Conv 模块结构如图 9 所示。

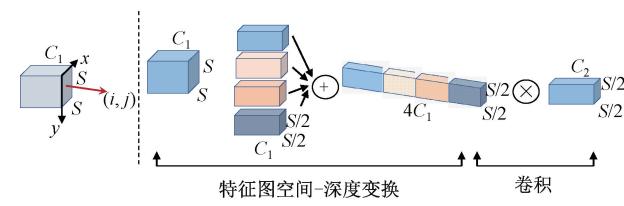


图 9 SPD-Conv 结构

沿通道维度连接子特征图可获得空间维度减少一个比例因子、通道维度增加一个比例因子的特征图 X', 即 SPD 将特征图 X 转换为中间特征图 X'。为了尽可能的保留输入图像的所有特征判别信息, 在 SPD 特征变换层后添

加了一个带有 C2 滤波器的非跨步卷积层。

CBAM 模块包含了通道注意力和空间注意力两个不同机制,通过把输入网络的特征信息从通道和空间两种相对独立的层面上加以压缩,从而对其进行加权。从而提高网络对重要特征信号的关注度,同时达到抑制背景信息干扰的作用。对于任意一个输入 CNN 中的中间特征图,CBAM 先按通道维度进行全局特征提取,生成通道注意力特征图;然后,再将生成的通道注意力特征图进一步输入到空间注意力机制中生成融合域特征图。从而能够实现识别模型检测精度和速度的提升。CBAM 注意力模块结构如图 10 所示。

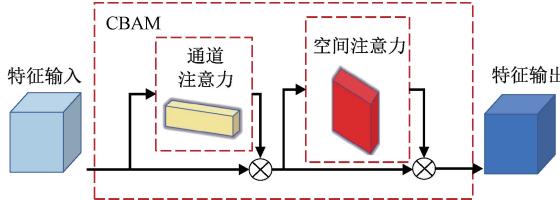


图 10 CBAM 模块结构

改进后的 YOLOv5 模型结构如图 11 所示。

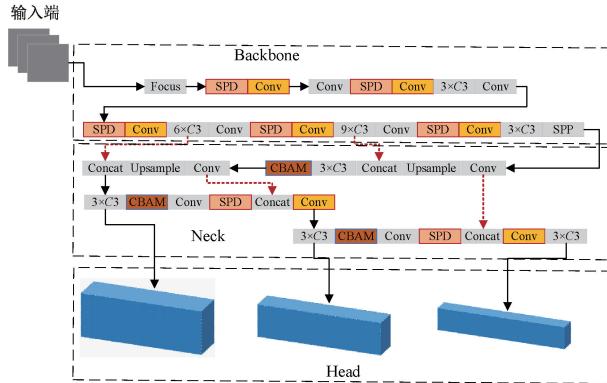


图 11 改进 YOLOv5 结构

3 模型训练和结果分析

3.1 实验环境

实验环境选择:操作系统为 Windows 11 64 位,CPU 为 11th Gen Intel(R) Core(TM) i7-11700F, GPU 为 RTX-3060, 开发语言为 Python 3.8 版本, 深度学习框架为 Pytorch 1.8、CUDA 11.2, Batch Size 为 16, 迭代周期 epoch 为 100。

为了扩展和保证数据集训练的有效性,对表 2 仿真缺陷数据集做图像增强处理后,再采用随机平移、加噪和翻转数据增强技术,扩展缺陷数据集为 2 000 个缺陷样本。使用 LabelImg 标注工具标记缺陷类别,将矩形槽缺陷标记为 defect1,半球形缺陷标记为 defect2。最后,将缺陷数据集划分成训练集、验证集和测试集 3 部分,其中训练和集 1 200 个缺陷样本,验证集和测试集各 400 个样本。

3.2 模型训练

模型的评价指标选用平均精度 (average precision, AP) 和平均精度均值 (mean average precision, mAP)。AP 与 mAP 的数值通过对模型训练样本的精度 Precision 和召回率 Recall 来运算,其表达式为:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

式中:TP 为正确检测出的缺陷数量;FP 为将非缺陷检测为缺陷的数量;FN 为将缺陷检测为非缺陷的数量。每种缺陷类别的 AP 即为 P-R 曲线下方面积,表达式如下:

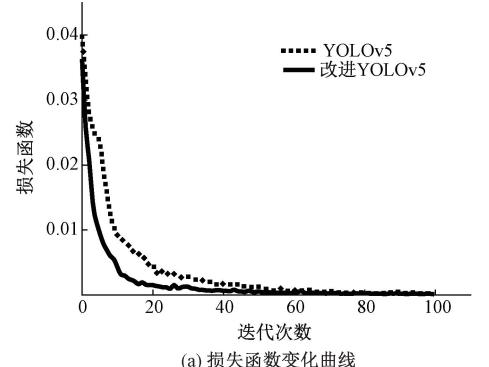
$$AP = \int_0^1 P dR \quad (7)$$

式中:P 为 P-R 曲线的纵坐标 Precision;R 为 P-R 曲线上的横坐标 Recall。mAP 即为所有缺陷类别的 AP 之和除以缺陷类别数,其计算公式如下:

$$mAP = \frac{1}{n} \sum_{i=0}^n AP_i \quad (8)$$

式中:n 为缺陷类别总数;i 为当前缺陷类别的编号。

为了验证所提网络模型的先进性,分别对基准模型和改进模型在数据集上进行了训练验证,图 12 为模型训练的损失函数和 PR 曲线对比结果。由图 12 可知,在相同的训练参数下,随着迭代次数的增加,改进后的 YOLOv5 网络具有更快的收敛速度,且更加稳定。且改进后的 YOLOv5 网络的 PR 曲线完全包围了原始 YOLOv5 网络



(a) 损失函数变化曲线

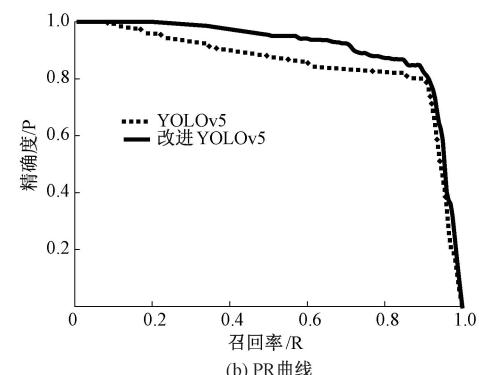


图 12 训练结果曲线

的 PR 曲线,说明改进后的网络对两类缺陷的识别具有更优的性能。

为了进一步检验所提模型对缺陷的识别效率,将改进的 YOLOv5 网络与 SSD 和 Faster R-CNN 分别在数据集上进行缺陷识别效果比对。表 3 为不同算法模型对缺陷的识别结果。

表 3 缺陷识别结果

算法	AP/%		mAP@0.5%	FPS
	defect1	defect2		
SSD	68.9	62.6	65.8	30.3
Faster R-CNN	73.8	70.2	72.0	10.1
YOLOv5	86.3	88.0	87.2	51.5
改进 YOLOv5	94.5	91.8	93.2	53.2

表 4 模型测试结果

算法	缺陷	缺陷数量	准确识别数量	准确率/%	误判数量	误判率/%
YOLOv5	defect1	200	175	87.5	25	12.5
	defect2	200	183	91.5	17	8.5
改进 YOLOv5	defect1	200	194	97.0	6	3.0
	defect2	200	195	97.5	5	2.5

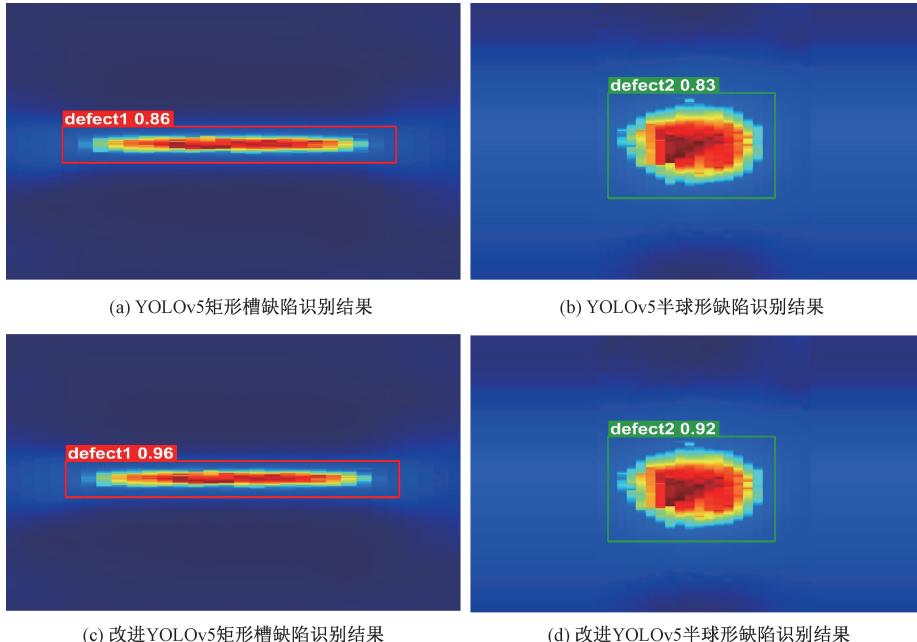


图 13 模型测试结果

由表 4 可知,改进后的 YOLOv5 算法模型对两类缺陷的准确识别数量均高于原始的 YOLOv5 模型,且平均识别准确率达到 97.25%,平均误判率为 2.75%。与原始 YOLOv5 网络相比,改进后的模型对矩形槽和半球形两类缺陷的测试准确率分别提升了 9.5% 和 6.0%,拥有更好的缺陷检测性能。

如图 13 所示,两个模型均准确识别了两类缺陷。然

由表 3 可知,改进的 YOLOv5 算法模型的检测性能均优于其他模型,在 2 类缺陷中的 AP 值均高于 SSD、Faster R-CNN 和 YOLOv5 算法的 AP 值,且获得的 mAP@0.5 值最高。与 YOLOv5 算法相比,改进的 YOLOv5 算法的 mAP@0.5 提高了 6.0%,且具有更快的缺陷检测速度。可见 CBAM 模块和 SPD-Conv 模块显著提高了模型对缺陷的检测性能。

3.3 测试结果

为了测试改进的 YOLOv5 算法的缺陷检测能力,对基准模型和改进的 YOLOv5 模型在数据集上进行了缺陷检测效果的定性评价。将测试集缺陷图像分别输入两个网络模型中,测试结果如表 4 所示,图 13 显示了 YOLOv5 和改进 YOLOv5 模型的部分测试结果。

表 4 模型测试结果

算法	缺陷	缺陷数量	准确识别数量	准确率/%	误判数量	误判率/%
YOLOv5	defect1	200	175	87.5	25	12.5
	defect2	200	183	91.5	17	8.5
改进 YOLOv5	defect1	200	194	97.0	6	3.0
	defect2	200	195	97.5	5	2.5

而,与 YOLOv5 相比,改进的 YOLOv5 模型具有更强的缺陷检测能力,对缺陷的识别拥有更高的置信度。综上可知,改进后的 YOLOv5 网络模型更适合小管径弯头畸变漏磁缺陷图像的智能识别任务。

3.4 实验验证

为了检验所提缺陷识别模型的应用性能,通过图 14 所示的牵拉实验获取了缺陷漏磁信号数据。实验管道材

料为Q235,管道尺寸为 $\Phi 114\text{ mm} \times 8\text{ mm}$,在检测管路上人工开凿了4个不同尺寸的矩形槽和半球形缺陷。将检测获得的缺陷漏磁信号图像经过图像增强处理后,输入改进的YOLOv5模型中,输出的测试结果如图15所示。

由图15可知,提出的改进YOLOv5模型准确识别了两类缺陷形状,对矩形槽和半球形缺陷的平均识别精度分别为95.5%和93.0%,实验数据测试结果与仿真结果平均误差为3.0%。因此,本文提出的改进YOLOv5模型的检测性能可以满足管道漏磁缺陷识别的需求。



图14 奎拉实验

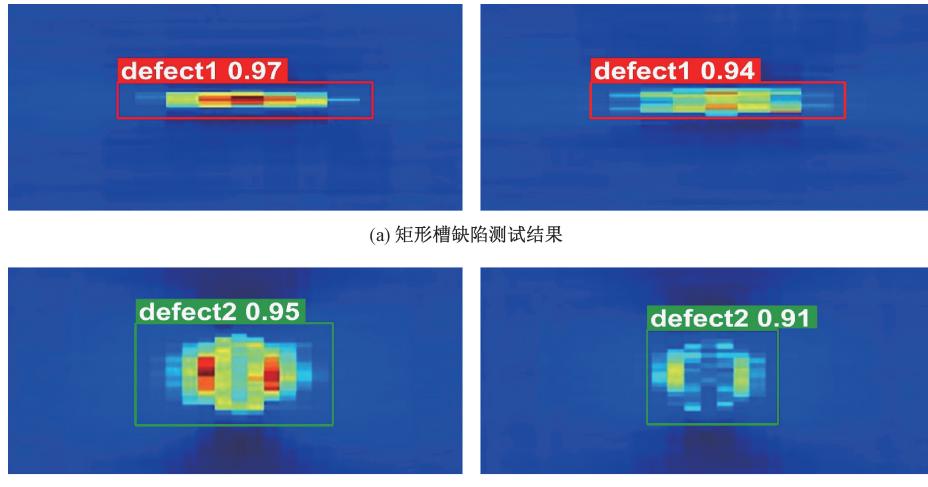


图15 实验测试结果

4 结论

提出了一种小管径弯头畸变漏磁缺陷图像智能识别方法,通过图像增强处理和网络优化,对弯头畸变缺陷数据集训练和测试,得出的主要结论如下:1)采用MSRCR-HF方法解决了弯头缺陷图像的畸变问题,有效促进了弯头畸变漏磁缺陷图像的智能识别。2)改进的YOLOv5网络模型可有效提高对弯头畸变漏磁缺陷的检测精度。与基准模型相比,改进后模型的平均检测精度提高了5.7%。对矩形槽和半球形缺陷的实验测试准确率分别为95.5%和93.0%,能够满足小管径弯头畸变漏磁缺陷智能识别的需求。

参考文献

- [1] 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.
- [2] 刘艳军,吴冰,王鲜,等.集输管道腐蚀缺陷非开挖评价方法研究[J].安全与环境学报,2022,22(4):1743-1750.
- [3] 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.

- [4] 杨志军,刘玉琢,吴忠义,等.管道外漏磁检测技术研究[J].压力容器,2018,35(3):56-62.
- [5] 崔国宁,杨理践,耿浩,等.基于卷积神经网络的管道缺陷量化识别方法[J].仪表技术与传感器,2022,(10):99-103.
- [6] EGE Y, CORAMIK M. A new measurement system using magnetic flux leakage method in pipeline inspection[J]. Measurement, 2018, 123: 163-174.
- [7] TZELEPI M, TEFAS A. Deep convolutional learning for content based image retrieval[J]. Neurocomputing, 2018, 275: 2467-2478.
- [8] 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.
- [9] PAN J H, GAO L. A novel method for defects marking

- and classifying in MFL inspection of pipeline [J]. International Journal of Pressure Vessels and Piping, 2023, 202: 104892.
- [10] 刘金海,赵贺,神祥凯,等.基于漏磁内检测的自监督缺陷检测方法[J].仪器仪表学报,2020,41(9):180-187.
- [11] 陈俊杰.油气管道漏磁检测缺陷区域的分段识别方法[J].中国测试,2017,43(11): 1-7.
- [12] 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.
- [13] 卢森骥,徐行,张润江,等.基于多维度选择性搜索的小样本缺陷识别方法[J].仪器仪表学报,2022,43(1):220-228.
- [14] 丁洁,陆安江,彭熙舜,等.基于颜色校正和加权融合的水下图像增强[J].国外电子测量技术,2023,42(3):167-174.
- [15] 郝蕊洁,万小红.改进多尺度 Retinex 的激光图像超分辨率增强[J].激光杂志,2022,43(9): 124-128.
- [16] 陈正伟,张方,周扬,等.光谱信号乘性加性混合随机噪声去除方法[J].光学学报,2017,37(7): 342-349.
- [17] 邱天衡,王玲,王鹏,等.基于改进 YOLOv5 的目标检测算法研究[J].计算机工程与应用,2022,58(13):63-73.
- [18] SUNKARA R, LUO T. No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects [J]. ArXiv Preprint, 2022, ArXiv: 2208:03641.
- [19] 黄昌顺,张金萍.基于 CBAM-CNN 的滚动轴承故障诊断方法[J].现代制造工程,2022,(11): 137-143.

作者简介

赵鹏程,博士,讲师,主要研究方向为油气装备失效分析与完整性管理。

E-mail: zhaopengcheng0822@126.com