

◇ 研究报告 ◇

改进的 Faster-RCNN 算法在聚乙烯管接头内部缺陷检测中的应用

彭伊娟¹ 王振超^{1,2} 张秋菊^{1†}

(1 江南大学机械工程学院 无锡 214122)

(2 罗森博格(无锡)管道技术有限公司 无锡 214161)

摘要: 超声相控阵技术是目前聚乙烯管道热熔接头内部缺陷检测的一种主流方法。提出了基于注意力机制的改进 Faster-RCNN 目标检测网络用于超声相控阵 D 扫图聚乙烯管接头内部缺陷检测。针对聚乙烯管道热熔接头内部超声相控阵 D 扫图小缺陷较多、特征信息容易丢失的问题,将残差网络(ResNet50)与特征金字塔网络(FPN)相结合作为骨干网络,并引入卷积注意力模块(CBAM)自适应细化特征。将 SSD 网络框架和 Faster-RCNN 网络框架用于模型训练和测试,使用 VGG16、ResNet50、ResNet50+FPN、ACBM+ResNet50+FPN 作为骨干网络依次对超声相控阵聚乙烯管道热熔对接接头内部缺陷样本进行训练对比。结果表明,改进的 Faster-RCNN 网络模型在聚乙烯管接头内部缺陷检测和分类方面有明显改进,对小缺陷的检测性能有了显著的提高。

关键词: 缺陷检测;超声相控阵;卷积注意力模块;残差网络;特征金字塔

中图法分类号: TP183; O429

文献标识码: A

文章编号: 1000-310X(2023)05-0984-09

DOI: 10.11684/j.issn.1000-310X.2023.05.011

Application of improved Faster-RCNN algorithm in internal defect detection of polyethylene pipe joint

PENG Yijuan¹ WANG Zhenchao^{1,2} ZHANG Qiuju¹

(1 School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China)

(2 Rothenberger Wuxi Pipe Technologies Co., Ltd., Wuxi 214161, China)

Abstract: Ultrasonic phased array technology is a mainstream method to detect the internal defects of polyethylene (PE) pipe hot melt joint. In this paper, an improved Faster-RCNN target detection network based on attention mechanism is proposed for ultrasonic phased array D-sweep PE pipe joint internal defect detection. To solve the problem that there are many small defects in ultrasonic phased array D-sweep pattern inside hot melt joint of PE pipeline and feature information is easy to be lost, residual network (ResNet50) is combined with feature pyramid network (FPN) as the backbone network, and convolution block attention module (CBAM) is introduced to self-refine feature. SSD network framework and Faster-RCNN network framework were used for model training and testing. VGG16, ResNet50, ResNet50+FPN and ACBM+ResNet50+FPN backbone networks were used as backbone networks to train and compare the internal defect samples of ultrasonic phased array PE pipeline hot melt butt joint. The results show that the improved Faster-RCNN network model has obvious improvement in the detection and classification of internal defects of PE pipe joints, and the detection performance of small defects is significantly improved.

2022-06-13 收稿; 2022-08-02 定稿

作者简介: 彭伊娟(1998-), 女, 江苏南通人, 硕士研究生, 研究方向: 缺陷检测。

† 通信作者 E-mail: qjzhang123@qq.com

Keywords: Defect detecting; Ultrasonic phased array; Convolutional block attention module; Residual network; Feature pyramid

0 引言

管道运输多用于液体和气体物资的长距离输送,在聚乙烯(Polyethylene, PE)管道的热熔对接过程中,受到工艺、设备、环境等因素的不良影响,易在热熔接头处产生各种各样的缺陷(如气孔、夹杂、裂纹等)。这些缺陷容易导致熔接接头质量不佳而发生泄漏和破坏,是整个PE管道中最薄弱的地方,极大地影响着PE管道的安全使用。这就需要对管道接头内部缺陷进行有效的检测,及时发现存在的安全隐患。目前,PE管道热熔接头的无损检测方法主要有X射线检测^[1]、红外热成像检测和超声检测(衍射时差法和超声相控阵)等^[2]。超声检测是近年来较为有效的无损检测方法。传统的超声波检测受到PE管表面多次反射回波信号的干扰,并且由于PE材料具有声波衰减性,PE热熔接头缺陷识别很难实现,而超声相控阵检测技术能够实现声束偏转以及声束集中,所以能够很好地克服这一困难^[3]。

不同种类的缺陷具有不同的失效形式,因此在对PE管道热熔接头进行超声相控阵检测时,需要根据超声相控阵图谱识别出缺陷的种类。采用人工形式对超声相控阵检测图像中的缺陷评定往往存在误差且效率不高,随着计算机技术的发展,传统的图像处理方法被广泛使用。费学智等^[4]通过分析目标缺陷轨迹和缺陷自身的面积来综合判断是否为真实缺陷。Rostami等^[5]对PE管电熔接头超声图谱的数字格式采用形态学技术重新构建图像来补充缺失信息,从而实现目标特征分区,但未能实现特征缺陷的识别。然而上述采用图像处理的方法对含有多种缺陷的PE管道热熔接头未能进行有效识别。

近年来随着深度学习的迅速发展,基于深度学习的目标检测方法在效率和精度上相较于传统的图像检测方法都有很大提升,逐渐成为国内外学者的研究热点。这部分研究主要集中在两个方面,一方面是采用特征提取加浅层神经网络的方法对检测数据进行分类,另一方面是采用深度学习方法,输入数据主要是人工提取的特征值,近年逐渐发展到自动提取特征^[6]。

在浅层神经网络方面,盛雄^[7]采用BP神经网络实现对PE管电熔接头缺陷图像检测特征区域的准确分类以及缺陷识别。Sambath等^[8]对检测到的回波离散小波变换表示缺陷特征向量,并利用BP神经网络进行分类。在深度学习方面,要追溯到2014年, Girshick等^[9]将卷积神经网络(Convolutional neural networks, CNN)^[10]与目标检测结合,提出R-CNN算法。2015年, Song等^[11]将R-CNN和SPPNet进一步提高,提出Fast-RCNN算法,在相同的网络配置下同时实现区域的特征提取、分类和边界框回归。2017年, Ren等^[12]将Fast-RCNN与区域候选网络(Region proposal network, RPN)相结合,提出Faster-RCNN算法,实现端到端的接近实时的检测,提高检测速度与精度。

在超声缺陷检测领域也有不少学者采用深度学习方法进行缺陷识别。Meng等^[13]用小波变换系数来学习每个信号的有效表示,使用深度神经网络进行碳纤维缺陷检测。万陶磊等^[14]提取超声信号的无量纲参数和小波包能量系数组成多维特征向量,然后利用BP神经网络进行缺陷检测。张重远等^[15]采用基于相似矩阵的盲源分离方法对超声检测信号进行预处理,使用CNN进行信号识别。

目前为止,多数研究者都是采用信号处理方法来提取特征从而提高缺陷识别准确率,然后采用BP神经网络来进行缺陷分类。本文直接将超声相控阵采集的超声D扫图作为输入,针对超声D扫视图中缺陷小且密集的状况,以Faster-RCNN网络为基础,采用不同的骨干网络结构对缺陷进行检测,并对Faster-RCNN网络进行优化,实现检测能力的提升。

1 Faster-RCNN网络介绍

Faster-RCNN目标检测模型提出了与RCNN、SPPNet、Fast-RCNN不一样的RPN网络模型,该模型突破了Fast-RCNN在时间上的性能瓶颈。其网络结构图如图1所示。

由图1可知, Faster-RCNN可以分为4个主要内容:




图1 Faster-RCNN 网络结构图

Fig. 1 Structure diagram of Faster-RCNN network

(1) 骨干网络 (Backbone)。Faster-RCNN 首先使用一组基础的卷积、激活、池化层用来提取图像的特征图。

(2) 区域候选网络 (RPN)。输入特征图, 使用 RPN 层生成候选框, 进行是否含有物体的二分类。

(3) 感兴趣区域池化 (ROI pooling)。将各个不同尺寸的特征图通过 ROI pooling 层缩放到同样大小的特征图。

(4) 分类以及回归 (Classification and regression)。将大小一致的特征图送到全连接层, 进行目标的分类并且完成边界框回归, 获得检测框最终的精确位置。

Faster-RCNN 加入了 RPN 层来产生候选框, PRN 层可以和检测网络共享卷积层, 并且可以在每个位置同时预测目标边界和 objectness 得分, 实现了端到端的检测, 提升了模型精度。然而 Faster-RCNN 也存在着一些问题: Faster-RCNN 网络具有大量的参数, 需要花费大量的时间, 容易出现过拟合, 此外在卷积过程中小目标容易丢失, 导致对小缺陷的识别效果不佳。

2 改进的 Faster-RCNN 网络

超声相控阵检测出的热熔接头内部 D 扫视图缺陷相较于寻常目标识别对象, 面积小且密集。本文提出了一种基于轻量级卷积注意力模块 (Convolutional block attention module, CBAM) 的

Faster-RCNN 算法应用于超声相控阵 PE 管道热熔接头内部缺陷检测, 将深度残差网络 (ResNet50) 与特征金字塔 (Feature pyramid network, FPN) 集成形成骨干网络, 引入通道注意力模块和空间注意力模块提高网络对超声相控阵 D 扫图小缺陷的学习能力。

2.1 CBAM

CBAM 是一个作用于前馈 CNN 的注意力模块, 它结合了通道和空间两种注意力模块, 相比于只关注通道的 SE 注意力机制有更好的效果。CBAM 以一个中间特征映射 $F \in \mathbf{R}^{C \times H \times W}$ 作为输入, 该模块将根据通道维数 $\omega_c \in \mathbf{R}^{1 \times 1 \times C}$ 和空间维数 $M_S \in \mathbf{R}^{1 \times H \times W}$ 来推断注意力图, 然后将注意力图与输入特征图相乘, 自适应细化特征^[16], 计算公式见式(1):

$$F' = \omega_c(F) \otimes F, \quad F'' = M_S(F') \otimes F', \quad (1)$$

式(1)中: $\otimes$ 表示元素级乘法, F'' 是最终特征输出。图2显示了每个注意力模块的计算进度。

通道注意力模块关注输入图片中有意义的特征信息^[17], 如图2(a)所示。首先将输入的特征图经过两个并行的最大池化层和平均池化层, 将特征图从 $C \times H \times W$ 变为 $C \times 1 \times 1$ 的大小。然后经过两层的神经网络共享全连接层, 第一层神经元个数为 C/r (r 为减少率), 第二层神经元个数为 C , 激活




图2 CBAM模块的结构

Fig. 2 Structure of CBAM model

函数为ReLU。将MLP输出特征进行element-wise加和操作,再通过一个sigmoid激活函数生成最终的通道注意力特征图,即 M_C ,计算公式见式(2)。最后,将 M_C 和输入特征图 F 相乘生成空间注意力模块的输入特征 F' ,见式(1)。

$$\begin{aligned} M_C(F) &= \sigma(\text{MLP}(\text{avgpool}(F))) + (\text{MLP}(\text{maxpool}(F))) \\ &= \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))), \end{aligned} \quad (2)$$

式(2)中, $W_0 \in \mathbf{R}^{C/r \times C}$, $W_1 \in \mathbf{R}^{C \times C/r}$, σ 表示sigmoid激活函数。

空间注意图是根据特征间的空间关系生成的,空间注意模块主要关注特征信息的位置^[18],是对通道注意力的补充,如图2(b)所示。首先,在通道轴上应用平均池化与最大池化来生成两个特征图, F_{avg}^S 和 F_{max}^S ,将两个特征图进行通道拼接,生成有效的特征描述符,通过卷积层将描述符简化为一个通道。然后使用sigmoid函数将其激活,生成空间注意力图,计算公式见式(3)。最后空间注意力图乘以输入特征图,得到最终的注意力特征图 F'' ,见式(1)。

$$\begin{aligned} M_S(F') &= \sigma(f^{7 \times 7}(\text{avgpool}(F'); \text{maxpool}(F'))) \\ &= \sigma(f^{7 \times 7}(F_{\text{avg}}^S; F_{\text{max}}^S)), \end{aligned} \quad (3)$$

式(3)中: σ 表示sigmoid激活函数, $f^{7 \times 7}$ 表示卷积核为 7×7 的卷积。

CBAM补充了由通道注意力聚焦的语义信息和由空间注意力聚焦的位置信息,本文将CBAM加

入到骨干网络中,来关注深层网络中PE管接头超声相控阵D扫图小缺陷的特征信息,提升对小缺陷的检测性能。

2.2 骨干网络

本文将ResNet50与FPN相融合形成骨干网络。ResNet50通过构建残差块可以解决深度网络退化问题。如图3所示,其中 x 表示残差模块的输入,当特征图输入到特征提取网络中,通过 1×1 的卷积核进行降维、 3×3 的卷积核进行特征提取、 1×1 的卷积核进行升维,最后得到256维度的特征图。而残差模块在输入和输出之间建立了直接连接,




图3 ResNet50残差结构

Fig. 3 Residual structure of ResNet50

$F(x)$ 表示残差模块的拟合功能, 输出结果为 $H(x) = F(x) + x$ 。如果某一层的梯度消失, 则该层的输出等于该层的输入, 从而形成一个恒等映射, 不会影响后续网络的学习, 这样在加深网络的同时准确率也不会降低。

原始 Faster-RCNN 是自底向上卷积, 使用最后一层特征图进行预测, 这是因为最高层的特征具有最丰富的语义信息。这对于大目标的检测很有效, 但是对于小缺陷来说, 当进行卷积、激活、池化到最后一层, 实际上语义信息已经没有了, 导致小缺

陷容易检测不到或者效果不佳。由于 PE 管热熔接头内部超声相控阵 D 扫视图缺陷特征都比较小, 加入低层特征图信息能更好地识别出小缺陷, 本研究在残差网络中加入 FPN^[19]。FPN 模型通过将低分辨率、高语义信息的高层特征和低级语义信息的特征进行自上而下的侧边连接, 使得所有尺度下的特征都有丰富的语义信息, 且每一层都独立预测, 从而提升对小缺陷的检测效果。其核心思想包括 3 部分: 一个自底向上的线路、一个自顶向下的线路、横向连接。ResNet50+FPN 网络模型如图 4 所示。




图4 FPN 与 ResNet50 网络结构图

Fig. 4 Structure diagram of FPN and ResNet50 network

由 ResNet50+FPN 网络结构图可知, FPN 取 ResNet50 的输出特征图作为输入, 对 C5 使用 1×1 的卷积进行降维处理, 再经过 3×3 的卷积处理输出 P5, C5 上采样后与经过降维处理过的 C4 相加, 再经 3×3 卷积处理, 得到 P4, 以此类推, 从而生成了不同尺度的特征图, 这样用于检测的特征图就包含了多个阶段的特征。然后将 FPN 生成的多层特征图 P2–P5 传入 RPN 层生成候选框, 此时需要将候选框映射到相应的特征图从而进行接下来的 ROI pooling 操作^[20], 具体映射方式见式 (4)。

$$k = k_0 + \log_2 \left(\sqrt{wh}/224 \right), \quad (4)$$

式 (4) 中: k_0 是映射到 $w \times h = 224 \times 224$ 的 ROI 目标级别, 设置为 4, w 和 h 是 ROI 区域的长和宽, 224

是 ImageNet 数据集的预训练图像大小, k 值应该做取整处理, 即所使用的特征层。

本文将 CBAM 和 ResNet50+FPN 组合在一起, 形成了一种改进的骨干网络模型。考虑到随着 CNN 的加深, PE 管接头内部超声相控阵 D 扫图小缺陷信息出现丢失的现象, 在 ResNet50 和 FPN 之间设置了两个注意模块, 来关注深层网络中 PE 管接头超声相控阵小缺陷的特征信息, 实现更优的检测性能。然后, 将特征信息输入到 FPN 中, 进一步融合深层和浅层的特征信息, 使它们得到充分研究。最后将 FPN 生成的多层特征图输入到 RPN 层完成是否包含目标的二分类问题, 本文使用的骨干网络结构如图 5 所示, 其中 C 表示高效通道注意模块, S 表示空间注意模块。




图5 CBAM+ResNet50+FPN网络结构

Fig. 5 Structure diagram of CBAM+ResNet50+FPN network

3 实验与结果分析

3.1 实验环境与实验数据

由于目前国内在超声相控阵热熔接头焊缝缺陷领域没有公开响应的权威大型数据集,本研究采用友联公司 MagicScan-UX 超声相控阵模块,并搭配 5L32-0.6 × 10 超声相控阵探头以及横波楔块 (N55S) 作为超声相控阵无损检测设备,进行 PE 管道热熔对接接头内部进行图像采集。根据上海市 2017 年颁布的 DB31/T1058-2017《燃气用聚乙烯 (PE) 管道焊接接头相控阵超声检测》^[21], PE 管道热熔接头内部缺陷系统地分为孔洞、裂纹、熔合面夹杂 3 种,本文采集了含有孔洞缺陷、裂纹缺陷、熔合面夹杂缺陷的超声相控阵 D 扫检测图并对数据集进行扩充,共 2450 张,这些缺陷均采用人工预制,如图 6 所示,可以看出 PE 管接头内部缺陷特征图都比较小。孔洞缺陷检测图如图 6(a) 所示,接头检测区域中存在一个明显的反射信号且边缘较为圆润呈圆形或者椭圆状,热熔对接接头可能存在孔洞缺陷。裂纹的检测图如图 6(b) 所示,接头检测区域中

存在两个明显的反射信号且在同一垂直线上,接头局部区域可能存在缝隙。熔合面夹杂缺陷如图 6(c) 所示,接头检测区域内反射信号较弱,并且边缘比较模糊,接头疑似存在外来夹杂物^[22]。此外使用 Labelimg 对图像进行标记,以遵循 PASCAL VOC 数据集的格式,训练集、验证集和测试集的数量比为 7 : 1 : 2。

试验平台 windows10, CUDA11.3, 处理器为 Intel i9-10900X, 显卡为 NVIDIA GeForce RTX 2080Ti, 使用 python 语言与 pytorch 深度学习框架作为开发环境。

3.2 改进网络的目标检测结果

本文采用了目标检测中常用的 COCO 数据集的评价指标,如式 (5)~(7) 所示:

$$P = \frac{TP}{TP + FP} \times 100\%, \quad (5)$$

$$R = \frac{TP}{TP + FN} \times 100\%, \quad (6)$$

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

其中:精确度 P 指模型预测为正的样本中实际也为正的 PE 管接头内部缺陷样本占被预测为正的缺陷样本的比例,用来衡量检测系统的查准率;召回率 R 指实际为正的 PE 管接头内部缺陷样本中被预测为正的样本所占实际为正的缺陷样本的比例,用来衡量检测系统的查全率;AP 是 P - R 曲线下的面积,AP 值越大,检测性能越好, mAP 是多个类别 AP 的平均值;TP 代表被模型预测为正的超声相控阵 PE 管接头内部缺陷正样本的数量;FP 代表被模型预测为正的超声相控阵 PE 管接头内部缺陷负样本的数量;FN 代表被模型预测为负的超声相控阵 PE 管接头内部缺陷负样本的数量。COCO 评价指标及其意义如表 1 所示。




图6 不同种类焊缝缺陷图

Fig. 6 Different types of weld defects

表1 COCO 目标检测评价指标及其意义

Table 1 Evaluation indexes of COCO target detection and its meaning

评价指标	意义	评价指标	意义
AP	IOU= 0.5 : 0.95 时的 AP 值	AP ⁵⁰	IOU = 0.5 时的 AP 值
AP ⁷⁵	IOU = 0.75 时的 AP 值	AP ^S	小目标的 AP 值
AP ^M	中等目标的 AP 值	AP ^L	大目标的 AP 值
mAP	各类别 AP 的平均值		

本文将 SSD 网络框架和 Faster-RCNN 网络框架用于模型训练和测试,使用 VGG16、ResNet50、ResNet50+FPN、ACBM+ResNet50+FPN 作为骨干网络模型,依次对超声相控阵 D 扫图 PE 管道热熔对接接头内部缺陷样本进行训练对比。初始学习率设为 0.01,动量值为 0.9,训练轮数(epochs)设为 50。实验结果和比较如表 2 所示,AP 值的变化曲线如图 7 所示。

表2 不同网络模型的实验结果比较

Table 2 Comparison of experimental results of different network models

网络模型	AP ⁵⁰	AP ⁷⁵	AP ^S	AP ^M	AP	mAP
SSD	70.3	68.5	49.2	57.2	51.5	70.3
VGG16	77.2	74.9	56.1	64.3	59.3	77.5
ResNet50	79.5	77.2	58.3	66.1	61.5	79.9
ResNet50+FPN	85.3	79.5	61.5	68.2	63.1	85.6
ACBM+ResNet50+FPN	90.1	82.5	65.7	71.1	67.0	90.5




图7 AP 值变化曲线

Fig. 7 Change curves of AP value

由表 2 可知,对于超声相控阵 PE 管热熔接头缺陷检测,SSD 网络中缺陷数据集的 mAP 为 70.3%,而对于小缺陷检测, AP^S 仅为 49.2%。相比之下,使用 VGG16 骨干网络的传统 Faster-RCNN, mAP 为 77.5%, AP^S 达到 56.1%。与 SSD 网络的结果相比,传统 Faster-RCNN 网络的 mAP 和 AP^S 分别增长 7.3% 和 6.9%,证明 Faster-RCNN 网络比 SSD 网络更适合超声相控阵 D 扫图 PE 管接头缺陷检测。ResNet50 的 mAP 值为 79.9%,略高于 VGG16 网络。ResNet50+FPN 作为骨干网络具有更强的特征学习能力, mAP 为 85.6%,比单独使用 ResNet50 骨干网络提高了 5.7%,对于小缺陷, AP^S 增加了 3.2%,检测能力明显提高。改进后的 Faster-RCNN 算法是将 CBAM 和 ResNet+FPN 相结合组成的最终骨干网络, mAP 达到 90.5%,相比 ResNet+FPN 骨干网络提高了 4.9%,同时小缺陷的检测性能提升了 4.2%。实验结果表明,改进后的 Faster-RCNN 网络对小缺陷的关注度更高,检测能力更强,整体检测性能较好。

图 8 显示了超声相控阵 D 扫图 PE 管热熔接头缺陷检测结果的 $P-R$ 曲线,召回率 R 为横坐标,精确度 P 为纵坐标,曲线和轴包围的区域为 AP 值,区域越大,检测性能越好,图中红色曲线表示 CBAM 和 ResNet+FPN 相结合骨干网络的 $P-R$ 曲线。从图 8 中可以看出,改进的 Faster-RCNN 网络模型在检测方面取得了较好的效果。图 9 显示了 4 种骨干网络的训练损失比较曲线。可以看出改进的 Faster-RCNN 网络具有更快的训练收敛速度和更少的损失。




图8 P-R 曲线图

Fig. 8 P-R curves




图 9 不同网络模型训练损失曲线图

Fig. 9 Training loss value of different network model

VGG16、ResNet50、ResNet50+FPN、ACBM+ResNet50+FPN 骨干网络识别效果如图 10 ~ 13 所示。可以看出,VGG16 作为骨干网络时,裂纹缺陷未能有效提取,出现了漏检和误判现象; ResNet50 相较于 VGG16 骨干网络效果有所提升,但仍然出现了漏检和误判现象; ResNet50+ FPN 相较于 ResNet50 网络漏检现象减少,但是对平面状缺陷如裂纹出现了误判现象; ACBM+ResNet50+FPN 作为骨干网络,相比 VGG16、ResNet50 和 ResNet50+FPN 对各种缺陷的提取效果都有提升,预测框的位置更加准确,且误判和漏检现象较少。




图 10 VGG16 识别效果图

Fig. 10 Recognition renderings of VGG16




图 11 ResNet50 识别效果图

Fig. 11 Recognition renderings of ResNet50




图 12 ResNet50+FPN 识别效果图

Fig. 12 Recognition renderings of ResNet50+FPN




图 13 ACBM+ResNet50+FPN 识别效果图

Fig. 13 Recognition renderings of ACBM+ResNet50+FPN

4 结论

本文将基于注意力机制的Faster-RCNN网络应用于超声相控阵D扫图PE管热熔对接接头缺陷检测。以ResNet50+FPN为骨干网络,通过应用轻量级通道注意力机制和空间注意力机制,显著增强了神经网络对小缺陷的学习能力。试验结果表明,改进的Faster-RCNN网络框架相较于SSD网络框架更适合应用于超声相控阵D扫图PE管接头内部缺陷检测。与现有的目标检测模型相比,改进的Faster-RCNN网络具有更好的检测能力和更少的训练损失,同时对小缺陷的检测能力有了显著提高。在后续的研究中,将收集更多的PE管接头内部缺陷超声相控阵数据图,并使用更多不同的网络方法,提高对超声相控阵PE管道接头内部缺陷的识别。

参考文献

- [1] 秦胤康. 核电站高密度聚乙烯管道热熔接头的超声相控阵检测研究[D]. 杭州: 浙江大学, 2019.
- [2] 王鹏. 正交异性钢桥面板疲劳裂纹的超声导波检测方法[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- [3] 黄跃鑫, 钟舜聪, 伏喜斌. 聚乙烯管道电熔接头的超声相控阵成像及缺陷特征[J]. 焊接学报, 2018, 39(2): 119-123, 134. Huang Yuexin, Zhong Shuncong, Fu Xibin. Ultrasonic phased array imaging and automatic identification of defects in polyethylene pipe electrofusion joints[J]. Transactions of the China Welding Institution, 2018, 39(2): 119-123, 134.
- [4] 费学智, 吴芳芳, 柳铭哲, 等. 超声相控阵图像中的缺陷识别算法[J]. 无损检测, 2018, 40(8): 61-66. Fei Xuezhi, Wu Junfang, Liu Mingzhe, et al. Defect recognition algorithm in ultrasonic phased array image[J]. Non-destructive Testing, 2018, 40(8): 61-66.
- [5] Rostami B, Razavi B S. Application of digital image processing on nondestructive testing of fusion joints of polyethylene piping by ultrasonic technique[C]. International Conference on Wireless Communications and Signal Processing, 2011.
- [6] 高子洋, 师芳芳, 张碧星, 等. 卷积神经网络的缺陷类型识别分析[J]. 应用声学, 2022, 41(2): 301-309. Gao Ziyang, Shi Fangfang, Zhang Bixing, et al. Recognition and analysis of defect types by convolutional neural network[J]. Journal of Applied Acoustics, 2022, 41(2): 301-309.
- [7] 盛雄. 聚乙烯管道电熔接头超声检测缺陷自动识别系统研发[D]. 杭州: 浙江大学, 2018.
- [8] Sambath S, Nagaraj P, Selvakumar N. Automatic defect classification in ultrasonic NDT using artificial intelligence[J]. Journal of Nondestructive Evaluation, 2011, 30(1): 20-28.
- [9] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[J]. Computer Vision and Pattern Recognition. USA: IEEE, 2014: 580-587.
- [10] 龚禧, 曹长荣. 基于卷积神经网络的植物叶片分类[J]. 计算机与现代化, 2014(4): 12-15, 19. Gong Dingxi, Cao Changrong. Plant leaf classification based on CNN[J]. Computer and Modernization, 2014(4): 12-15, 19.
- [11] Song H O, Girshick R, Zickler S, et al. Generalized sparselet models for real-time multiclass object recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(5): 1001-1012.
- [12] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] Meng M, Chua Y J, Wouterson E, et al. Ultrasonic signal classification and imaging system for composite materials via deep convolutional neural networks[J]. Neurocomputing, 2017, 257: 128-135.
- [14] 万陶磊, 常俊杰, 曾雪峰, 等. 一种基于小波包和PCA的超声缺陷识别方法[J]. 失效分析与预防, 2019, 14(3): 141-146. Wang Taolei, Chang Junjie, Zeng Xuefeng, et al. An ultrasonic defect identification method based on wavelet packet and PCA[J]. Failure Analysis and Prevention, 2019, 14(3): 141-146.
- [15] 张重远, 岳浩天, 王博闻, 等. 基于相似矩阵盲源分离与卷积神经网络的局部放电超声信号深度学习模式识别方法[J]. 电网技术, 2019, 43(6): 1900-1907. Zhang Chongyuan, Yue Haotian, Wang Bowen, et al. Pattern recognition of partial discharge ultrasonic signal based on similar matrix BSS and deep learning CNN[J]. Power System Technology, 2019, 43(6): 1900-1907.
- [16] 刘卫朋, 山圣旗, 王睿, 等. 一种基于卷积神经网络X射线焊缝缺陷检测方法: 天津, CN113674247A[P]. 2021-11-19.
- [17] 刘超杰. 基于注意力机制的图像区域风格迁移方法研究[D]. 广州: 广东工业大学, 2021.
- [18] 赵晓芳, 陈雪芳, 林盛鑫, 等. 一种基于深度学习的视网膜血管图像分割方法: 东莞, CN111862056A[P]. 2020-10-30.
- [19] 张越, 张守京, 冯中强. 面向棉花异纤的改进Faster RCNN目标检测方法[J]. 棉纺织技术, 2022, 50(5): 37-41. Zhang Yue, Zhang Shoujing, Feng Zhongqiang. Improved faster RCNN target detection method for foreign fiber in cotton[J]. Cotton Textile Technology, 2022, 50(5): 37-41.
- [20] 李东洁, 李若昊. 基于改进Faster RCNN的马克杯缺陷检测方法[J]. 激光与光电子学进展, 2020, 57(4): 353-360. Li Dongjie, Li Ruohao. Mug defect detection method based on improved Faster RCNN[J]. Laser & Optoelectronics Progress, 2020, 57(4): 353-360.
- [21] 陶杨吉. 聚乙烯管道热熔接头的相控阵超声检测中孔洞缺陷的表征和重构[D]. 杭州: 浙江大学, 2021.
- [22] 施建峰, 陶杨吉, 安成名, 等. 聚乙烯燃气管道超声相控阵检测工程应用案例分析[J]. 压力容器, 2020, 37(12): 54-62. Shi Jianfeng, Tao Yangji, An Chengming, et al. On-site phased array ultrasonic testing of polyethylene gas pipeline[J]. Editorial Office of Pressure Vessel Technology, 2020, 37(12): 54-62.