

DOI: 10.13382/j.jemi.B2407351

基于复合骨干网络的漏磁小缺陷信号检测方法*

唐建华¹ 张鑫² 刘金海² 刘海超^{1,3,4} 卢进^{1,3,4}

(1. 中海油(天津)管道工程技术有限公司 天津 300452; 2. 东北大学信息科学与工程学院 沈阳 110819;
3. 天津市海底管道重点实验室 天津 300450; 4. 海油发展海底管道安全服役保障技术重点实验室 天津 300450)

摘要:漏磁内检测是管道内检测的核心技术,对保障管道的安全运输至关重要。管道长期处于地下或深海,复杂的环境导致管道表面存在许多小缺陷。由于小缺陷可利用信息有限,传统的深度学习缺陷检测方法识别小缺陷难以获得满意的检测结果。提出了一种基于复合骨干网络的漏磁小缺陷信号检测方法。首先,提出了一种名为背景压缩的数据增强方法,以压缩背景信号进而增强小缺陷关键特征。其次,设计一种自适应的正负样本分配策略,以改善小缺陷在区域候选网络中正负样本分配不均匀的问题。最后,提出了一种小缺陷多分支高分辨率特征提取网络,利用多分支复合结构获得高分辨率特征进行特征融合,以提高网络对小缺陷纹理信息的利用率。以试验场管道数据对所提方法进行验证,实验结果表明,设计的方法是有效的,检测精度达90.3%,与最好结果相比,mAP提升8.4%。

关键词:漏磁内检测;深度学习;缺陷检测;正负样本;特征融合

中图分类号: TP277; TN98 **文献标识码:** A **国家标准学科分类代码:** 440.55

Signal detection method for magnetic flux leakage small defects based on composite backbone network

Tang Jianhua¹ Zhang Xin² Liu Jinhai² Liu Haichao^{1,3,4} Lu Jin^{1,3,4}

(1. CNOOC (Tianjin) Pipeline Engineering Technology Co., Ltd., Tianjin 300452, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China; 3. Tianjin Key Laboratory of Subsea Pipeline, Tianjin 300450, China; 4. CNOOC Energy Technology & Services Limited Key Laboratory of Safety Guarantee Technology for Subsea Pipeline, Tianjin 300450, China)

Abstract: Magnetic flux leakage (MFL) internal detection is the core technology of pipeline internal detection, which is crucial to ensuring the safe transportation of pipelines. Due to the long-term underground or deep sea environment of pipelines, there are many small defects on the surface of pipelines. Due to the limited information available on small defects, traditional deep learning defect detection methods have difficulty achieving satisfactory detection results for small defects. A composite backbone network-based signal detection method for small magnetic leakage defects is proposed. First, a data enhancement method called background compression is proposed to compress background signals and thus enhance key features of small defects. Secondly, an adaptive positive and negative sample allocation strategy is designed to address the issue of uneven positive and negative sample allocation for small defects in the region proposal network. Finally, a multi-branch high-resolution feature extraction network for small defects is proposed, which uses a multi-branch composite structure to obtain high-resolution features for feature fusion, thereby improving the network's utilization of small defect texture information. The proposed method is validated using pipeline data from a test site, and the experimental results show that the proposed method is effective, achieving a detection accuracy of 90.3%, with an 8.4% mAP improvement compared to the best results.

Keywords: magnetic flux leakage; deep learning; defect detection; positive and negative sample; feature fusion

0 引言

管道运输由于其自身优点成为石油、天然气主流的运输方式。管道由于服役时间长且所处环境复杂,面临着不同程度的管壁腐蚀^[1-2]。从能源有效的利用、国家的经济发展、防止油气管道发生泄露等多角度分析,定期的对管道运行状况进行检测是十分必要的^[3]。

漏磁内检测技术是工业中常用的无损检测技术,因为可以通过漏磁信号的变化评估管道的健康状况,所以广泛应用于管道安全检测中^[4-5]。当管壁发生轻度腐蚀后,在管道表面极易产生小缺陷,引起漏磁信号微弱的变化。由于微弱的信号难以判断且对环境的影响较为敏感,所以小缺陷信号难以检测。同时,对小缺陷的维护不可小视,否则会在短时间内会加剧腐蚀速度,成为管道运输的安全隐患。因此,解决小缺陷检测具有很强的理论与实际意义^[6]。

近年来,许多学者致力于研究工业背景下的缺陷识别,可以分为传统机器学习方法与深度学习方法。在传统的机器学习方法中,文献[7]提出了二维主成分分析与卷积自动编码器相结合的方法识别半导体晶片图缺陷。文献[8]采用多尺度支持向量机与决策树的监督机器学习方法实现铝板裂纹缺陷检测。文献[9]提出了一种时空正则化方法来区分漏磁信号中的异常缺陷和背景。传统的机器学习方法可在简单背景中展现出不错的效果,但由于缺乏强大的特征提取能力,在复杂的管道环境下无法满足实际工业需求,针对小缺陷检测精度低。

目前,小目标检测是深度学习目标检测领域的一个难点,常见于遥感图像检测中,难点在于由于像素信息较少,深度学习计算目标的纹理和位置结果难以满足目标检测的精度^[10],文献[11]提出了一种精确且快速的遥感影像小目标检测方法,该方法融合多模态数据,通过利用辅助超分辨率学习,同时考虑检测精度和计算成本,对多尺度目标执行高分辨率目标检测。文献[12]提出了一种级联信道和空间注意力模块,以自适应地增强多级特征,该网络可以将小目标的上下文信息通过重复融合和增强进一步整合和充分利用。文献[13]提出了一种基于时空特征的检测框架,设计小 IOU 策略和帧间能量累积网络。除此以外,文献[14]采用级联网络、文献[15]使用对抗网络结合深度学习方法进行小目标识别。在漏磁检测背景下,小缺陷不仅仅是形状问题,还因为背景干扰大而导致小缺陷信号被淹没,检测精度不理想。通过以上文献中网络结构的调整无法降低背景信号的负面影响,在漏磁小缺陷信号上难以达到令人满意的检测精度。

在剩余部分,第一节主要介绍小缺陷判定条件与数据增强方法介绍。第二节介绍自适应正负样本分配策

略,第三节介绍多分支高分辨率特征提取网络内容。第四节强调实验的结论与分析。第五节进行总结。

综上所述,为了提高复杂信号情况下漏磁检测小缺陷的检测精度,本文提出了一种基于复合骨干网络的漏磁小缺陷检测方法。本文的主要贡献如下:

1) 提出了一种背景压缩方法,相对于之前的数据增强方法,所提出的方法能更有效地抑制背景信号的干扰,突出小缺陷信号的有效特征。

2) 提出了一种正负样本分配策略,与之前的方法相比,所提出方法能有效改善训练过程中小缺陷正负样本分配不均匀的问题。

3) 设计了一种小缺陷多分支高分辨率特征提取网络,所设计方法可以更加有效地利用小缺陷的高分辨率特征,并且提升了小缺陷浅层特征的利用率。

1 小缺陷判定条件与数据增强方法介绍

1.1 小缺陷判定方法

在复杂漏磁信号下,为了更清楚地描述小缺陷容易受到背景干扰的影响,导致与背景信号耦合的现象,图 1 分别对比小缺陷二维显示与三维显示。

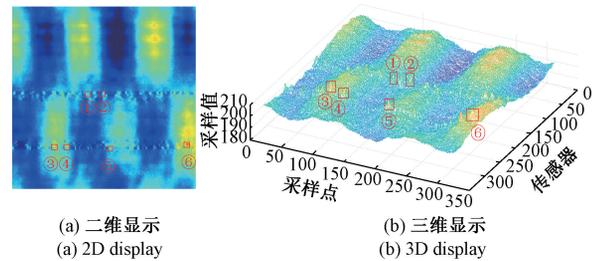


图 1 复杂漏磁信号小缺陷图示

Fig. 1 Examples of small defects in complex magnetic flux leakage signals

定义某一缺陷信号峰值最大值为 P_d , 背景信号峰值最大值为 P_b , 缺陷左波谷 δ_{c1} , 右波谷 δ_{c2} , 漏磁内检测器携带传感器数 K , 当满足式(1)时则定义其为小缺陷。

$$\left\{ \begin{array}{l} PSNR = 10 \cdot \lg\left(\frac{P_d}{P_b}\right) < 0 \\ \text{and} \\ |\delta_{c1} - \delta_{c2}|^2 < \left(\frac{1}{20} \cdot K\right)^2 \end{array} \right. \quad (1)$$

图 1(a) 和(b)中①~⑥为小缺陷的二维显示与三维显示,小缺陷通常是管道轻度腐蚀引起的,从全局角度比较小缺陷信号波动相比于非缺陷信号波动较弱,难以与非缺陷信号进行分离,使得小缺陷无法得到明显的特征,直接影响最后的检测效果。

1.2 小缺陷数据增强方法

通常使用多通道传感器对管道进行漏磁内检测,由于每个通道的传感器存在个体差异,不同的采样点会发生程度不一的基线漂移。为确保信号的连续性与有效性。首先对漏磁信号进行基质校正处理,平衡传感器因为个体差异所导致采集信号基质出现偏差的问题。具体的基质校正公式如式(2)和(3)所示。

$$B_{i-\text{median}} = \frac{V_{i-\text{median}} - V_{\text{ref}}}{P \cdot \text{sens}} \quad (2)$$

$$B_i(j)_{\text{ans}} = B_i(j) - B_{i-\text{median}} + \frac{1}{K} \cdot \sum_{i=1}^n B_i \quad (3)$$

式中: $V_{i-\text{median}}$ 为*i*通道传感器输出电压中值; V_{ref} 为传感器基值; P 为漏磁传感器电路的电压放大倍数, sens 为传感器输入磁场强度及输出电压的灵敏度的比值; $B_i(j)_{\text{ans}}$ 为*i*通道传感器在里程*j*处校正后的磁场强度; $B_i(j)$ 为*i*通道传感器在里程*j*处原始磁场强度; $B_{i-\text{median}}$ 为*i*通道传感器磁场强度中值; K 为传感器通道总数。

与文献[4]类似,在数据基值校正后,需要将缺失的数据通过数据插补的方式处理。

为了提高小缺陷信号与背景的对比度,增强小缺陷的关键特征,提出了一种名为背景抑制的小缺陷信号数据增强方法。该方法具体分为以下3步。

Step1)首先借助均值滤波的思想,剔除掉漏磁信号中存在的噪声,使用的公式如式(4)所示。

$$g(x, y) = \frac{1}{m \cdot m} \cdot \sum f(x, y) \quad (4)$$

式中: $g(x, y)$ 为滤波后(x, y)坐标的漏磁信号值; $f(x, y)$ 为滤波前(x, y)坐标的漏磁信号值; m 为选取滤波窗口大小。

Step2)在进行背景信号压缩时,不仅要保证小缺陷的信号与背景信号完全分离,还要保证缺陷信号的整体趋势不会发生太大改变。由此利用公式(5)即关注信号之间的空间相关性分布,又关注信号之间的相对大小,进而增强小缺陷的核心特征,避免其让非缺陷信号淹没。

$$h(x, y) = \frac{\sum_{k,l} [f(x, y) - g(x, y)] \cdot w(x, y, k, l)}{\sum_{k,l} w(x, y, k, l)} \quad (5)$$

式中: $f(x, y)$ 为漏磁原始信号; $g(x, y)$ 为经过均值滤波后的漏磁信号; $w(x, y, k, l)$ 为加权系数;其定义如式(6)~(8)所示。

$$w(x, y, k, l) = w_r(x, y, k, l) \cdot w_s(x, y, k, l) \quad (6)$$

$$w_r(x, y, k, l) = \exp\left[-\frac{|f(x, y) - f(k, l)|^2}{2\sigma_r^2}\right] \quad (7)$$

$$w_s(x, y, k, l) = \exp\left[-\frac{|(k-x)^2 - (l-y)^2|}{2\sigma_s^2}\right] \quad (8)$$

式中: w_r 为漏磁域加权系数; w_s 为空间距离域加权系数; σ_r 为漏磁域标准差; σ_s 为空间域标准差。

Step3)最后,需要将漏磁信号映射到*R*、*G*、*B*三维彩色空间,计算公式为:

$$[G_{R,x,y}, G_{G,x,y}, G_{B,x,y}] = \Gamma(h(x, y)) \quad (9)$$

式中: $G_{R,x,y}, G_{G,x,y}, G_{B,x,y}$ 分别为映射后对应*RGB*通道像素值;与文献[4]类似, Γ 为伪彩色映射关系。

2 自适应的正负样本分配策略

传统的两阶段检测算法是基于锚框(anchor)机制进行正负样本分配,在训练过程中需要通过区域建议网络(region proposal network)来生成锚框,每个位置可提供9种不同的锚框,常取面积尺度为 $\{128^2, 256^2, 512^2\}$,比例尺度为 $\{1:1, 1:2, 2:1\}$ 。然后通过锚框与真实目标边界框的*IOU*值 >0.7 则划分为正样本,*IOU*值 <0.3 则划分为负样本。

小缺陷通过1.2小节介绍的数据增强方法得到的伪彩色结果,其在图像中显示的大小尺寸小于 9×9 ,相对像素比 $<0.04\%$,直接通过上述所介绍的锚框尺寸与比例无法得到与正常目标相近的*IOU*值,直接影响后续正样本的数量。当正样本数量减少时,参与区域建议网络部分损失计算的正样本数量减少,导致损失值较小,在训练过程中会认为网络已经收敛。但是这样的收敛直接的原因是网络的正样本数量少,可称为网络的伪收敛。文献[13]使用更小的*IOU*策略,通过调整划分正负样本的阈值来增加正样本的数量,由于真实目标边界框与锚框的尺寸相差较大,通过直接调整阈值,虽然在一定程度上增加样本数量,但是会使正样本质量下降。

由此,为了提供足够数量且质量较高的正样本,正确的训练小目标,提出了一种自适应的正负样本分配策略。首先,提出适用于小目标的比例*IOU*,用于区域建议网络生成正样本。小缺陷真实目标边界框与锚框示意图如下图2所示。

在下图中,对于一个锚框,定义比例*IOU*计算公式如式(10)所示。

$$IOU_{\text{Ratio}} = \frac{\sqrt{d_3^2 + d_4^2}}{\sqrt{d_1^2 + d_2^2}} \cdot \frac{\text{area}(\text{anchor}) \cap \text{area}(GT)}{\text{area}(\text{anchor}) \cup \text{area}(GT)} \quad (10)$$

式中: IOU_{Ratio} 为比例*IOU*; d_1 为小缺陷真实目标边界框长; d_2 为小缺陷真实目标边界框宽; d_3 为anchor框长; d_4 为anchor框宽; $\text{area}(X)$ 表示*X*区域。

在比例*IOU*的基础上,设计了自适应的正负样本分配策略。

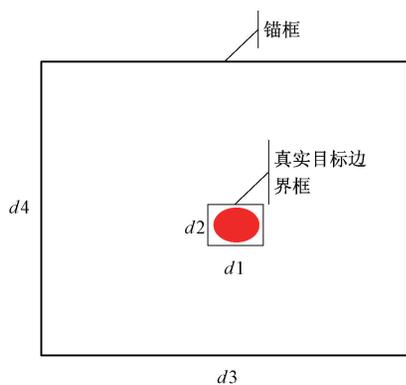


图 2 锚框与真实目标边界框示意图

Fig. 2 Illustration of anchor boxes and ground truth bounding boxes

$$\begin{cases} \text{if } IOU_{Ratio} \geq 0.7, \text{ 正样本} \\ \text{if } IOU_{Ratio} < 0.3, \text{ 负样本} \\ \text{if } 0.3 < IOU_{Ratio} < 0.7, \text{ 忽略} \end{cases} \quad (11)$$

训练阶段采用公式(11)的策略进行正负样本划分,可以将锚框与真实目标边界框的相对大小引入到 IOU 计算当中,并且设定使用锚框的面积尺度为 $\{8^2, 16^2, 32^2\}$,比例尺度为 $\{1:1, 1:2, 2:1\}$,动态的进行正负样本分配。为了评估算法的准确性,在后续缺陷检测部分以及计算平均精度(AP)等指标时,使用常规的 IOU。

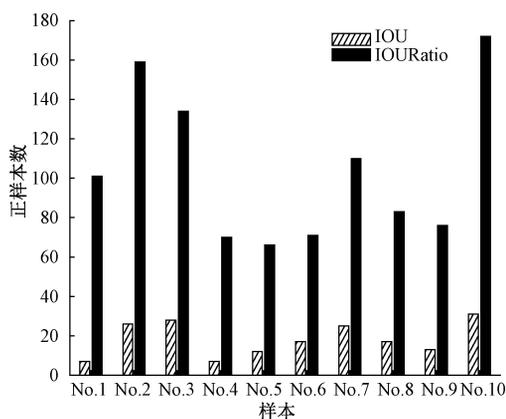


图 3 正负样本分配策略的有效性对比

Fig. 3 Comparison of the effectiveness of positive and negative sample allocation strategies

随机抽取了 10 张图像进行仿真,锚框面积选取为 $\{8^2, 16^2, 32^2\}$,比例选取为 $\{1:1, 1:2, 2:1\}$,正负样本总数为 256,通过对比使用常规 IOU 与使用比例 IOU 满足阈值条件下正样本数量来验证自适应正负样本分配策略的有效性。对比结果如图 3 所示。

3 多分支高分辨率特征提取网络

3.1 多分支复合骨干

整体流程图如图 4 所示,由 4 部分组成,其包含漏磁数据增强、多分支复合特征提取网络、高分辨率特征金字塔与缺陷检测。众所周知,在神经网络内部,浅层网络包含更多的纹理特征,深层网络包含更多的语义信息,由于小缺陷的像素信息相对较少,在浅层网络包含的信息要多于深层网络中的信息。虽然使用池化后可以减少参数量,但是考虑到直接在浅层网络中使用简单的池化操作会丢失小缺陷的纹理信息,直接影响后续缺陷检测的精度,由此设计了全卷积结构的辅助分支。所提出的多分支高分辨率特征提取网络如图 4 所示,其由多分支复合骨干结构与高分辨率特征金字塔结构组成。

多分支复合骨干结构是由 2 个不同的骨干复合而成,第 1 个骨干为与 resnet50 结构相同的主骨干 L_1 ,另 1 个为全卷积结构的辅助骨干 L_2 。由于辅助骨干缺少池化操作,其特征层 $\{D_2, D_3, D_4, D_5\}$ 均比主骨干特征层 $\{C_2, C_3, C_4, C_5\}$ 的分辨率大一倍,且对应特征层的深度相同。为了更好的利用辅助骨干的信息。按照式(12)进行像素级特征融合,由于结构限制,这里只进行主骨干 $\{C_2, C_3, C_4\}$ 与辅助骨干 $\{D_3, D_4, D_5\}$ 的特征融合。

$$\begin{cases} C_2 = C_2 + \text{ReLU}(\text{Conv}_{1 \times 1}(D_3) + b) \\ C_3 = C_3 + \text{ReLU}(\text{Conv}_{1 \times 1}(D_4) + b) \\ C_4 = C_4 + \text{ReLU}(\text{Conv}_{1 \times 1}(D_5) + b) \end{cases} \quad (12)$$

式中: C_2, C_3, C_4 表示主骨干相应特征层; D_3, D_4, D_5 表示辅助骨干相应特征层; ReLU 表示激活函数; $\text{Conv}_{1 \times 1}$ 表示 1×1 卷积操作;目的是调整辅助骨干特征层的通道; b 表示由 $\text{Conv}_{1 \times 1}$ 后产生的偏移量。

3.2 高分辨率特征金字塔结构

由于辅助骨干特征层 D_2 相比于主骨干特征层 $\{C_2, C_3, C_4, C_5\}$ 包含更多的纹理信息,为更加充分的利用高分辨率特征层 D_2 的纹理信息,设计了高分辨率特征金字塔结构 F 。在原特征金字塔网络的基础上,将特征层 D_2 的信息融合到特征金字塔结构中。具体融合步骤可分为以下几步,如图 5 所示。

Step1) 由于神经网络每一个通道所包含的信息不同,某个通道更加关注于目标的某一方面信息,在对于高分辨率 D_2 特征层,有些通道的信息是无关紧要的。可根据公式(13)将高分辨的信息进行通道方向的特征聚合。

$$D_{2i+1} = \partial(\text{ReLU}(\text{Conv}_{3 \times 3}(D_{2i}) + b)) \quad (13)$$

式中: $\text{Conv}_{3 \times 3}$ 表示使用卷积操作对通道进行聚合; ∂ 表示 Reshape 操作;通过该操作,在不丢失当前信息的前提下,即可保证高分辨率特征 D_{2i} 变为相对于较低分辨率特

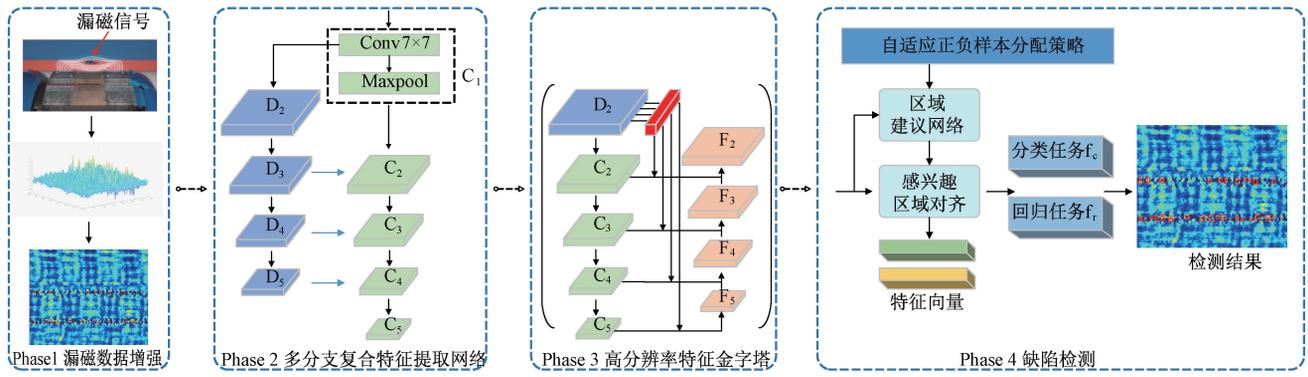


图 4 基于复合骨干网络的小缺陷检测方法

Fig. 4 Small defect detection method based on composite backbone network

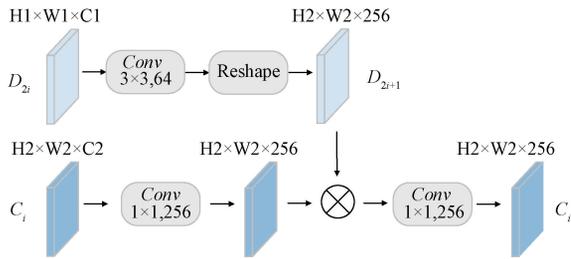


图 5 高分辨率特征金字塔融合

Fig. 5 High-resolution feature pyramid network

征层 D_{2i+1} 。

Step2) 按照式(14)融合低分辨率特征 C_i 与 step1 获得 D_{2i+1} 的信息,间接达到高分辨率特征与地分辨率特征融合的目的。

$$F_{output} = ReLU(Conv_{1 \times 1}(C(\Theta(Conv_{1 \times 1}(C_i) + b), D_{2i+1}))) + b) \quad (14)$$

式中: $C()$ 表示按元素进行拼接; Θ 表示 $ReLU$ 激活函数。

4 实验结果与分析

实验数据来自于图 6(a) 所示的天然气管道,其中包括图 6(b) 和 (c) 中所示的由于天然腐蚀导致的腐蚀缺陷。使用的数据均通过如图 7 所示漏磁内检测器采集。为了验证所提出的方法的有效性,随机选取 2 026 个样本做训练集,1 956 个样本做测试集,训练和测试均来自 32 寸实际使用管道。分别使用 6 种最先进(SOTA)的方法与所提出的方法进行对比实验与鲁棒性实验,包括:YOLO V7^[16]、Cascade RCNN^[17]、Libra RCNN^[18]、Detectors^[19]、Dynamic RCNN^[20] 和 Cbnet^[21]。与文献[22]类似,采用一些常用的评价指标来评价所提出方法的性能。包括“Accuracy”、“Precision (P)”、“Recall (R)”、“F-score (F)”、“Macro Precision (mAP)”、“Macro Recall (mAR)”。



(a) Pipeline test site (b) Actual defect (c) Actual defect

图 6 管道环路实验平台图片

Fig. 6 Picture of pipeline loop test platform

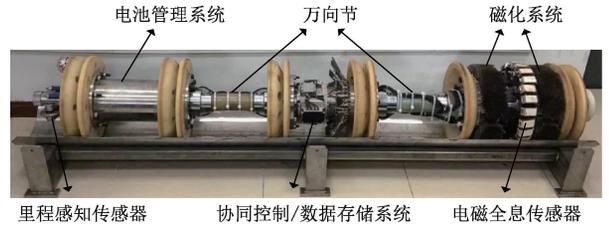


图 7 漏磁内检测器

Fig. 7 Magnetic flux leakage internal detector

4.1 实验环境与参数设置

实验平台硬件环境为:CPU AMD EPYC 7601 32-Core Processor,GPU 2 棵 GeForce RTX 3090 48 G,软件环境 LINUX64 Ubuntu18.04。实验均基于 PyTorch 框架实现。

实验参数设置如下:批大小 batch size = 8,网络使用优化器为随机梯度下降(SGD),学习率是 0.005,动量参数 0.9,权值衰减参数 0.000 1,训练周期 200。

4.2 实验评价指标

模型精度结果分析:通过召回率和精确率来评价所提出方法的性能,召回率可以反应小缺陷检测的检出率,精确率可以反应小缺陷检测的准确性。并通过 F-score 综合平衡召回率和精确率来评判模型的检测性能,其计算公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\% \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \cdot 100\% \quad (16)$$

$$Recall = \frac{TP}{TP + FN} \cdot 100\% \quad (17)$$

$$mAP = \frac{1}{n} \cdot \sum_{i=1}^n AP_i \quad (18)$$

$$mAR = \frac{1}{n} \cdot \sum_{i=1}^n AR_i \quad (19)$$

$$F - score = (1 + \beta^2) \frac{Precision \cdot Recall}{\beta^2 \cdot Precision + Recall} \quad (20)$$

其中,预测为小缺陷并实际为小缺陷,其为真阳

性(TP);实际为非小缺陷,其为假阳性(FP);预测为非小缺陷并实际为小缺陷,其为假阴性(FN);实际为非小缺陷,其为真阴性(TN)。由于缺陷检测既需要考量精确率又要关注召回率,为综合考率二者的调和值,在 F-score 计算时, β 取值为 1。

4.3 实验一:模型检测精度分析

在数据预处理阶段,所提出的方法与其他方式使用相同的手段进行数据预处理,包括图像水平翻转和垂直翻转,检测精度对比如表 1 所示。

表 1 不同算法在相同实验环境下的比较

Table 1 Comparison of different algorithms in the same experimental environment

方法	IOU0.5 : 0.95			IOU0.5		
	P	R	F	P	R	F
YOLOv7[16]	23.0	32.4	26.8	70.7	83.0	76.3
Cascade RCNN[17]	22.1	34.0	26.8	69.3	87.9	77.5
Libra RCNN[18]	18.9	32.5	23.9	64.5	86.2	73.8
Detectors[19]	20.6	34.5	25.8	67.8	88.4	76.7
Dynamic RCNN[20]	20.9	32.6	25.5	69.2	85.0	76.2
Cbnet[21]	20.4	33.3	25.3	69.5	87.7	77.5
Ours	28.2	41.4	33.5	79.1	93.5	85.7

由于制作的数据集只包含小缺陷目标,表中 P 、 R 、 F 均为小缺陷的精确率、召回率、 $F1$ 分数,如表 1 所示,提出的方法与其他方法相比,精确率和召回率都有提升。当 IOU 为 0.5 时,与性能最好的检测算法相比,提出的方法精确率提升约 8.4%,召回率提升约 5.6%, $F1$ 分数提升约 8.2%。当 IOU 为 0.5 : 0.95 时,与最好的检测性能相比,所提出的方法精确率提升约 5.2%,召回率提升约 6.9%, $F1$ 分数提升约 6.7%。证明所提出的方法可以解决漏磁小缺陷检测效果差的问题。

值得注意的,这里由于小缺陷目标像素信息较少,样本的真实目标边界框较小,在 IOU 计算时,对于生成的目标边界框尺度变化较为敏感。当模型预测的结果发生微小的变化时,会导致 IOU 发生较大的波动,该问题也直接会导致很难获得较大 IOU 的预测边界框,从而导致 IOU 为 0.5 : 0.95 的精确率与召回率较低,以上分析与实验结果也一致。

为满足实际工业需求,结合小缺陷检测特殊性,选取 IOU>0.5 且置信度>0.5 的目标为缺陷被检测,取 IOU<0.3 且置信度>0.5 的目标为缺陷被误检。检测准确率如图 8 所示。

在图 8 中,当选取置信度>0.5 时,所提出的方法检测准确率为 90.3%。满足工业需求,其他对比方法检测准确率均在 80%左右,其无法得到满足工业应用的准确率。

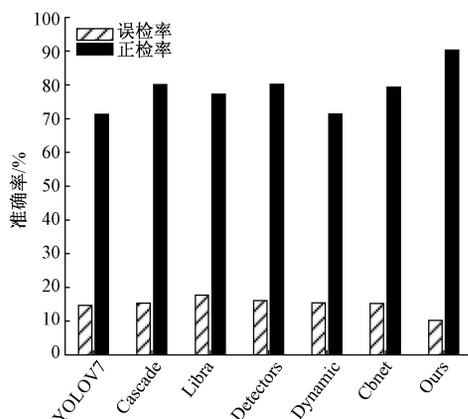


图 8 小缺陷检测准确率对比

Fig. 8 Comparison of accuracy for small defect detection

同时,所提出的方法误检率相比于其他对比方法误检率更低。可证明所提出的方法可以获得检测质量更高、检测准确率更高的模型,满足实际应用需求。

4.4 实验二:消融实验

在本节,分别进行了 4 组不同的消融实验,进而验证所提出每一部分的有效性,本节实验设置与实验一相同。首先,对数据增强进行对比,对比结果如图 9 所示,未使用数据增强的伪彩色结果如图 9(a) 所示,由于背景信噪比大于缺陷信噪比,使小缺陷与背景发生耦合,无法得到

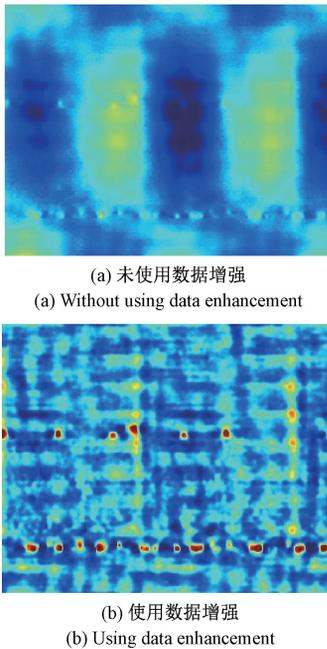


图 9 数据增强方法比较

Fig. 9 Comparison of data enhancement methods

特征明显的伪彩色结果。

使用数据增强方法的伪彩色结果如图 9(b) 所示, 通过有效的数据增强方法, 将背景信号压缩, 使小缺陷的核心特征更加清晰。

实验结果如表 2 所示, 使用 IOU 为 0.5 时的精确率与召回率来综合评判每一部分的性能。

表 2 消融实验结果比较

Table 2 Comparison of ablation experiment results

数据增强	分配策略	特征融合	P/%	R/%
			65.5	83.9
✓			70.2	85.9
✓	✓		73.0	89.9
✓	✓	✓	79.1	93.5

1) 为验证数据增强方法的有效性, 本实验将未进行数据增强的数据与进行增强的数据分别制作相应的训练集与测试集, 使用相同的标签, 从表 2 可以看到, 提出的数据增强方法精确率值提高约 4.7%, 召回率提高约 2%。同时对比图 10 的结果, 也可以发现使用数据增强后的小缺陷更加清晰, 特征更加突出。

2) 为验证自适应正负样本分配策略的有效性, 首先随机抽取 10 个样本, 分别使用传统 IOU 与设计的比例 IOU 进行正负样本分配, 其结果如图 3 所示。其次, 在数据增强的基础上, 进行分配策略的应用, 由表 2 可知, 精确率值提高约 2.9%, 召回率提高约 4%, 这是因为使用自

适应的分配策略可以在区域生成网络中提供更好的正样本, 对后续该环节损失计算、分类和回归都产生积极影响。因此可以改善小目标检测效果。

3) 为验证多分支高分辨率特征提取网络的有效性, 在上述实验的基础上将原始 Resnet50 网络替换为多分支复合骨干进行特征提取, 将普通的特征金字塔结构替换为高分辨率特征金字塔结构。在采用原始网络进行特征提取时, 检测精确率为 73.0%, 召回率为 89.9%, 在替换为设计的结构时, 检测精确率为 79.1%, 召回率为 93.5%。多分支高分辨率特征提取网络相比于原始结构, 网络中对应特征的分辨率更大, 目标的纹理信息更多, 将小缺陷的信息充分利用, 因此相比原始结构有较大的提升。

5 结 论

针对复杂漏磁信号下的小缺陷检测问题, 提出了基于复合骨干网络的漏磁小缺陷信号检测方法。通过背景抑制的小缺陷数据增强方法, 将背景信号压缩、突出小缺陷信号核心特征, 为网络提供缺陷特征明显的训练样本。通过自适应的正负样本分配策略, 将小缺陷的相对大小考虑到正负样本分配中, 改善小缺陷训练过程中正负样本分配不平衡问题。设计了多分支高分辨率特征提取网络, 利用全卷积的辅助分支, 充分保留小缺陷的纹理信息并为网络增加高分辨率特征, 提高网络对浅层特征的利用率。提出的方法检测精确率提升了约 9.6%, 召回率提升了约 7.8%, 为复杂漏磁信号下的小缺陷检测提供新的解决思路和方法。

参考文献

- [1] 刘金海, 赵真, 付明芮, 等. 基于主动小样本学习的管道焊缝缺陷检测方法 [J]. 仪器仪表学报, 2022, 43(11): 252-261.
LIU J H, ZHAO ZH, FU M R, et al. Pipeline weld defect detection method based on active small sample learning [J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 252-261.
- [2] 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 for long oil and gas pipelines [J]. Chinese Journal of Scientific Instrument, 2016, 37(8): 1736-1746.
- [3] 卢森壤, 神祥凯, 张俊楠, 等. 基于三轴融合的漏磁内检测数据缺陷反演方法研究 [J]. 仪器仪表学报, 2021, 42(12): 245-253.
LU S X, SHEN X K, ZHANG J N, et al. Research on

- defect inversion method for magnetic flux leakage internal testing data based on three-axis fusion [J]. Chinese Journal of Scientific Instrument, 2021, 42 (12): 245-253.
- [4] 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.
- LIU J H, ZHAO H, SHEN X K, et al. Self supervised defect detection method based on magnetic flux leakage internal testing [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 180-187.
- [5] 刘桐,刘斌,冯刚,等. 载荷作用下管道漏磁内检测信号量化研究[J]. 仪器仪表学报, 2022, 43(1): 262-273.
- LIU T, LIU B, FENG G, et al. Quantitative study of magnetic flux leakage internal detection signals in pipelines under load [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 262-273.
- [6] JIANG L, ZHANG H G, LIU J H, et al. THMS-Net: A two-stage heterogeneous signals mutual supervision network for MFL weak defect detection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-9.
- [7] 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.
- [8] 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.
- [9] FU M R, LIU J H, ZANG D, et al. Anomaly detection of complex MFL measurements using low-rank recovery in pipeline transportation inspection [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 1-1.
- [10] 童小钟,魏俊宇,苏绍璟,等. 融合注意力和多尺度特征的典型水面小目标检测[J]. 仪器仪表学报, 2023, 44(1): 212-222.
- TONG X ZH, WEI J Y, SU SH J, et al. Typical water surface small target detection by integrating attention and multi-scale features [J]. Journal of Instrumentation, 2023, 44(1): 212-222.
- [11] ZHANG J Q, LEI J, XIE W Y, et al. SuperYOLO: Super resolution assisted object detection in multimodal remote sensing imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023.
- [12] LI B Y, XIAO CH, WANG L G, et al. Dense nested attention network for infrared small target detection [J]. IEEE Transactions on Image Processing, 2023, 32: 1745-1758.
- [13] DU J M, LU H ZH, ZHANG L P, et al. A Spatial-temporal feature-based detection framework for infrared dim small target [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-12.
- [14] 石欣,卢灏,秦鹏杰,等. 一种远距离行人小目标检测方法[J]. 仪器仪表学报, 2022, 43(5): 136-146.
- SHI X, LU H, QIN P J, et al. A remote pedestrian small target detection method [J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 136-146.
- [15] ZHAO B, WANG CH P, FU Q, et al. A novel pattern for infrared small target detection with generative adversarial network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(5): 4481-4492.
- [16] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [17] 杨珂,方诚,段黎明. 基于深度学习模型融合的铸件缺陷自动检测 [J]. 仪器仪表学报, 2021, 42(11): 150-159.
- YANG K, FANG CH, DUAN L M. Automatic detection of casting defects based on deep learning model fusion [J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 150-159.
- [18] PANG J M, CHEN K, SHI J P, et al. R-CNN: Towards balanced learning for object detection [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 821-830.
- [19] QIAO S Y, CHEN L C, YUILLE A. Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10208-10219.
- [20] ZHANG H K, CHANG H, MA B P, et al. Dynamic R-CNN: Towards high quality object detection via dynamic training [C]. 2020 European Conference on Computer Vision, 2020: 260-275.
- [21] LIANG T T, CHU X J, LIU Y D, et al. CBNNet: A composite backbone network architecture for object detection [J]. IEEE Transactions on Image Processing, 2022, 31: 6893-6906.
- [22] LIU X Y, LIU J H, WANG Z, et al. Basic-class and cross-class hybrid feature learning for class-imbalanced weld defect recognition [J]. IEEE Transactions on Industrial Informatics, 2022: 1-11.

作者简介



唐建华, 2008 年于哈尔滨工业大学获得学士学位, 现为中海油(天津)管道工程技术有限公司高级工程师, 中国石油大学(北京)博士研究生, 主要研究方向为油气田设备设施完整性和海底管道完整性管理。

E-mail: tangjh3@cnooc.com.cn

Tang Jianhua received his B. Sc. degree from Harbin Institute of Technology in 2008. He is currently a senior engineer at CNOOC (Tianjin) Pipeline Engineering Technology Co., Ltd. and a doctoral student at China University of Petroleum (Beijing). His main research interests include the integrity of oil and gas field equipment and facilities, as well as the management of submarine pipeline integrity.



刘金海(通信作者), 2002 年于哈尔滨工业大学获得学士学位, 2005 年于东北大学获得硕士学位, 2009 年于东北大学获得博士学位。现为东北大学教授、博士生导师。他目前的研究方向包括工业人工智能和数据驱动故障诊断。

E-mail: liujinhai@mail.neu.edu.cn

Liu Jinhai (Corresponding author) received a B. Sc. degree from Harbin Institute of Technology in 2002, a M. Sc. degree from Northeastern University in 2005, and a Ph. D. degree from Northeastern University in 2009. He is currently a professor and doctoral supervisor at Northeastern University. His main research interests include industrial artificial intelligence and data-driven fault diagnosis.