

柴万昊, 杨弘道, 朱康, 等. 基于YOLOv5的轻量化管道漏磁信号检测[J]. 智能计算机与应用, 2025, 15(1): 211-217. DOI: 10.20169/j.issn.2095-2163.250131

基于YOLOv5的轻量化管道漏磁信号检测

柴万昊¹, 杨弘道², 朱康¹, 梁君华², 卿粼波¹, 吴晓红¹

(1 四川大学电子信息学院, 成都 610065; 2 达州帝泰克检测设备有限公司, 四川 达州 635000)

摘要: 石油天然气主要通过管道的方式进行运输, 而油气管道会因各种内外因素导致缺陷的产生。为了实现管道缺陷分布的精确定位, 并且易于在边缘端进行部署, 本文改进了YOLOv5网络。为了降低网络参数量, 将YOLOv5的主干网络替换成更加轻量化的MobileNetv3, 并且优化了部分卷积的通道数; 为了充分利用到真实框和预测框之间向量角度等信息, 将SIOU作为YOLOv5的损失函数; 最后将CARAFE上采样算子引入网络中, 来获取较大的感受野。结果表明, 改进后的算法相较于原始算法, 参数量减少了79.8%, 模型大小减少了77.4%, mAP 提高了0.8%, 在轻量化的同时提升了检测精度。

关键词: 油气管道; 漏磁信号; YOLOv5; 轻量化

中图分类号: TP391.4

文献标志码: A

文章编号: 2095-2163(2025)01-0211-07

Lightweight magnetic leakage signal detection of pipelines based on YOLOv5

CHAI Wanhao¹, YANG Hongdao², ZHU Kang¹, LIANG Junhua², QING Linbo¹, WU Xiaohong¹

(1 College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China; 2 Dazhou Dtaic Inspection Equipment Co., Ltd., Dazhou 635000, Sichuan, China)

Abstract: Oil and gas are mainly transported through pipelines, while oil and gas pipelines may cause defects due to various internal and external factors. In order to accurately locate the distribution of pipeline defects and facilitate deployment at the edge, the YOLOv5 network was improved in this paper. Firstly, in order to reduce the number of network parameters, the backbone network of YOLOv5 is replaced by the more lightweight MobileNetv3, and the number of channels of partial convolution is optimized. Then, in order to make full use of information such as vector Angle between the real box and the predicted box, SIOU is used as the loss function of YOLOv5. Finally, the CARAFE up-sampling operator is introduced into the network to obtain a large receptive field. The results show that compared with the original algorithm, the parameters of the improved algorithm are reduced by 79.8%, the model size is reduced by 77.4%, and the mAP is increased by 0.8%, which improves the detection accuracy as well as the lightweight.

Key words: oil and gas pipelines; magnetic leakage signal; YOLOv5; Lightweight

0 引言

作为一种适用于长距离运输石油天然气的运输工具, 油气管道在中国的运输网络中发挥着重要的作用。然而, 由于各种内外因素(如金属腐蚀、人为破坏等), 经常会导致管道缺陷的出现, 因此对管道安全进行检测和维护显得至关重要。漏磁检测作为近年来比较流行的检测方法, 可以有效地实现对于

管道安全问题的检测, 能够无损的检测出缺陷的面积、位置、程度等信息^[1], 为石油天然气的安全运输提供有力的保障。其工作原理是, 在管壁周围形成闭合的磁场回路后, 强磁性的永磁体会使管壁达到磁饱和, 此时如果管壁内外存在缺陷就会产生漏磁场, 从而检测出其中的缺陷^[2]。图1是帝泰克检测设备有限公司研发制造的用于油气管道内部检测的漏磁检测器, 在油气管道被磁化以后, 可以通过缺陷

基金项目: 中央高校基本科研业务费专项资金(2021CDDZ-08-SCU)。

作者简介: 柴万昊(1999—), 男, 硕士研究生, 主要研究方向: 脑电信号处理与识别; 卿粼波(1982—), 男, 博士, 教授, 博士生导师, 主要研究方向: 人工智能与计算机视觉, 图像/视频处理。

通信作者: 吴晓红(1970—), 女, 博士, 副教授, 硕士生导师, 主要研究方向: 图像处理, 模式识别, 电子与通信系统。Email: wxh@scu.edu.cn。

收稿日期: 2023-08-14

处的漏磁场信号的变化判别缺陷情况,从而诊断出管道中的腐蚀、凹沟凹槽、制造损伤等缺陷。



图1 漏磁检测器

Fig. 1 Magnetic flux leakage detector

较为传统的漏磁数据分析方法主要通过人工判断的方式进行分析,这类分析方法费时费力,分析结果又较为依靠分析人的主观意识,容易导致较大的误差。与人工分析方法相比,将漏磁数据可视化后,通过深度学习的方法进行目标检测,不仅可以有效地提高漏磁检测的正确率,精准地检测出管道的缺陷,还可以节省大量的人力物力,拥有较高的应用前景^[3]。如今的目标检测,已经从传统目标检测算法过渡到了基于深度学习的目标检测算法时期。传统的目标检测算法主要分为目标实例检测和传统目标类别检测这两大类^[4],如 HOG 特征^[5]、AdaBoost 算法^[6]等。基于深度学习的目标检测算法主要分为两类:一类是双阶段目标检测算法,如 Fast R-CNN^[7]、R-FCN^[8]等,该类算法首先通过提取图像中的候选区域,然后再对每个候选区域进行分类处理,确定候选区域包含目标后,完成对于目标类别、位置信息的检测;另一类是单阶段目标检测算法,如 YOLO^[9]、SSD^[10]等,该类算法舍弃了对图像区域进行提取这一过程,直接对特定目标进行检测,从而得到目标的类别和位置信息^[11]。作为单阶段目标检测算法的一种,YOLO 系列算法在近年来得到了快速的发展,在保证检测速度的基础上其检测精度也在不断提高,被广泛应用于各个实际场景中,而本文也因 YOLOv5 优异的性能而选取其作为基础网络。

基于目标检测的漏磁数据检测主要解决的问题可以分为 3 个方面,首先要确定管道中存在缺陷的位置,其次是确定管道缺陷的大小,最后通过进一步的判断来确定管道中缺陷的类型,包括金属损失-腐蚀、环焊缝异常等^[12]。其中,基于目标检测的方法需要进行漏磁数据可视化分析、数据预处理、数据增强、数据集的制作、模型训练、对模型进行优化等步骤^[13]。

本文在将漏磁数据进行可视化、数据增强后,利用 YOLOv5 进行自动化检测,并且为了让整体模型

更加轻量化,采用了 MobileNetv3^[14]对 YOLOv5 算法进行改进,同时引入 SIOU^[15]损失函数、CARAFE^[16]上采样算子,在使模型轻量化的同时进一步提升检测精度。

1 网络结构设计

1.1 YOLOv5 算法

YOLOv5 是一种单阶段的目标检测算法,其网络结构主要由 Backbone、Neck、Head 3 部分组成。其中,Backbone 主要作用在于对输入图像进行特征提取,Neck 部分对已提取到的特征进行融合,最后通过 Head 部分对结果进行预测。与 YOLOv3^[17]、YOLOv4^[18]相比,YOLOv5 在输入端增加了自适应锚框计算和自适应图片缩放,保留了 YOLOv4 的 Mosaic 数据增强方式,在 Backbone 部分引入了 Focus 以及 C3 结构,在 Neck 部分采用了 FPN+PAN 的特征融合机制,不仅使检测结果在精度和速度上均得到了改善,并且使得模型更加轻量化。本文所采用的基础网络是 YOLOv5 的 v6.1 版本,网络结构如图 2 所示。

1.2 YOLOv5 算法改进

YOLOv5 算法在 Backbone 主干网络中采用了 C3 模块,整体网络模型比较笨重,因此在设计模型时,考虑使用 MobileNet3 网络来对 YOLOv5 中 Backbone 网络中的模块进行相应的替换;同时,原模型中 Neck 部分的上采样方法采用的是最临近插值法,这种采样方法的感受野较小,不利于进行数据处理的同时还会带来不必要的多余计算,因此可以采用拥有更好感受野的 CARAFE 采样算子进行替换;YOLOv5 算法中的默认损失函数为 CIoU 损失函数,虽然 CIoU 损失函数在 DIoU 损失函数的基础上进行了改进,考虑到了预测框和目标框的宽长比,但是未能考虑到预测框与真实框相对位置之间的角度信息,因此在模型的训练过程中采用了 SIOU 损失函数来进行模型训练损失的计算。

1.2.1 MobileNetv3

MobileNet3 是由 Google 在 2019 年提出的一种针对移动端设备的高效神经网络结构,相比之前的 MobileNet1^[19]和 MobileNet2^[20],MobileNet3 在保留 MobileNet1 的深度可分离卷积和 MobileNet2 的逆残差结构的基础上引入了 SE 通道注意力模块,并且引入了新型激活函数 H-Swish,从而使整体模型更加轻量化,同时在精度和效率之间取得了更好的平衡。

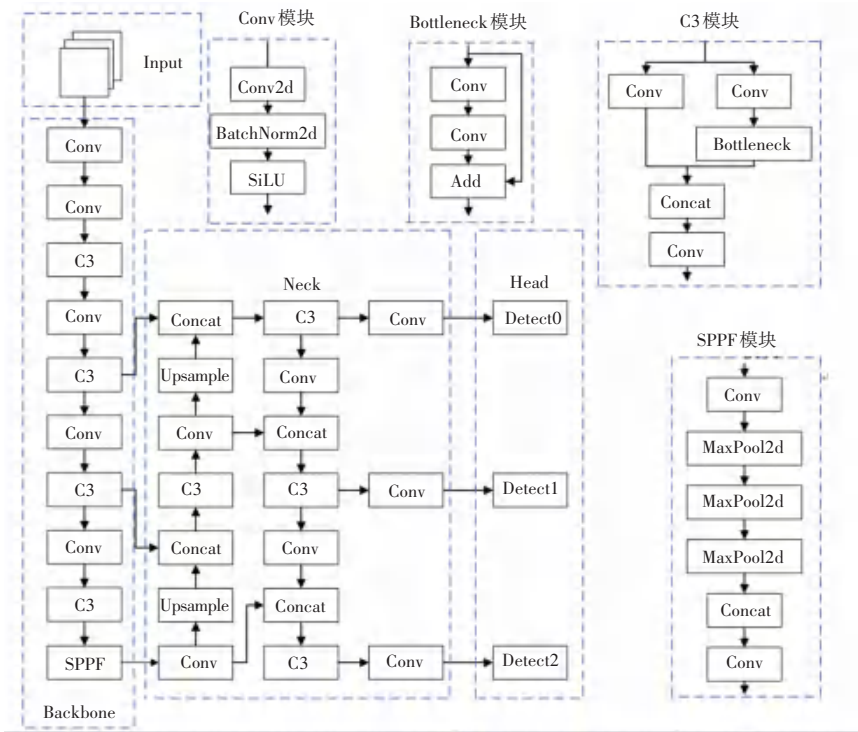


图 2 YOLOv5 v6.1 网络模型

Fig. 2 YOLOv5 v6.1 Network Model

MobileNetv3 中的核心模块 bneck 如图 3 所示。该模块首先通过一个 1×1 的卷积层将输入的特征图的通道数进行扩张,从而增强特征表达能力;然后通过一个 3×3 的可分离卷积层来降低计算代价,一个可分离卷积包括一个深度卷积和一个点卷积两个

步骤;在经过可分离卷积层后,将特征信息通过 SE 注意力机制来自适应地调整每个通道的权重;最后一层卷积的作用是将特征图的通道数降低至目标通道数,同时对特征进行加权处理。




图 3 bneck 模块

Fig. 3 bneck module

1.2.2 上采样算子 CARAFE

常见的上采样方法主要有:最近邻或者双线性上采样、逆卷积等。最近邻或者双线性上采样方法可以看作一种较为“均匀”的上采样方法,只通过像素点的空间位置决定上采样核,通常只有很小的感受野,并没有利用到特征图的语义信息,YOLOv5 默认采用的就是最近邻插值法进行上采样。

理想的上采样算子应该具有较大的感受野,并且其上采样核应与特征图的语义信息相关,最后就是尽可能的轻量化。相关研究人员基于以上原理,

设计了本文所使用的上采样算子 CARAFE (见图 4),其主要由上采样核预测和特征重组两个模块组成。其中,上采样核预测模块的工作主要包括以下步骤:首先是特征图像压缩,主要是通过对输入特征图通道数的压缩减少后续的工作量;然后是内容编码和上采样核预测,主要利用卷积对上一步中压缩后的输入特征图进行上采样核的预测,并在空间维度进行展开;最后是上采样核归一化,这一步主要是将上一步得到的上采样核利用 Softmax 进行归一化处理,得到最终的上采样核。而特征重组模块的主

要作用是找到输出特征图中每个位置在输入特征图中的对应位置,并取出以该位置为中心的特征图区

域,将区域里的值与该点的预测上采样核做点积,得到最终的输出值。




图4 CARAFE 模块

Fig. 4 CARAFE module

1.2.3 SIoU 损失函数

SIoU 损失函数在已有损失函数的基础增加了对角度的处理,提高了锚框向真实框收敛的速度,减少了网络的总自由度。YOLOv5 网络中默认使用 CIoU 作为损失函数,与 SIoU 相比,CIoU 在训练的过程中没有考虑预测框和真实框之间的角度关系导致回归速度缓慢,训练出的模型效果不理想。因此,为了提高检测结果的准确性,本文在实验阶段将 YOLOv5 网络中的损失函数替换为 SIoU 损失函数。SIoU 损失函数由 4 部分组成:角度成本、距离成本、形状成本、IoU 成本。

角度成本即 SIoU 损失函数中最核心的内容,其公式如下:

$$\Lambda = 1 - 2 \times \sin^2 \left(\arcsin \left(\frac{c_h}{\sigma} \right) - \frac{\pi}{4} \right) = \cos \left(2 \times \left(\arcsin \left(\frac{c_h}{\sigma} \right) - \frac{\pi}{4} \right) \right) \quad (1)$$

$$\frac{c_h}{\sigma} = \sin(\alpha) \quad (2)$$

$$\sigma = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2} \quad (3)$$

$$c_h = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y}) \quad (4)$$

式(1)中, c_h 为预测框和真实框两中心点的垂直高度差, σ 为两中心点之间的直线距离。角度 α 的定义如式(2)所示,上述式子中 $(b_{c_x}^{gt}, b_{c_y}^{gt})$ 为真实框中心点坐标, (b_{c_x}, b_{c_y}) 为预测框中心点坐标。

距离成本与角度成本之间具有很强的相关性,具体公式如下:

$$\Delta = \sum_{l=x,y} (1 - e^{-\gamma \rho_l}) = 2 - e^{-\gamma \rho_x} - e^{-\gamma \rho_y} \quad (5)$$

$$\rho_x = \left(\frac{b_{c_x}^{gt} - b_{c_x}}{c_w} \right)^2 \quad (6)$$

$$\rho_y = \left(\frac{b_{c_y}^{gt} - b_{c_y}}{c_h} \right)^2 \quad (7)$$

$$\gamma = 2 - \Lambda \quad (8)$$

式中: c_w 和 c_h 为真实框和预测框最小外接矩形的长和宽。

形状成本的公式如下:

$$\Omega = \sum_{t=w,h} (1 - e^{-w^t})^\theta = (1 - e^{-w^t})^\theta + (1 - e^{-h^t})^\theta \quad (9)$$

$$W_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})} \quad (10)$$

$$W_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \quad (11)$$

式中: θ 值为形状成本在网络中占据的权重值,可自行设置, (w, h) 为预测框的宽和高, (w^{gt}, h^{gt}) 为真实框的宽和高, IoU 为真实框与预测框交集和并集的比值。

综上所述, SIoU 损失函数公式如下:

$$L_{\text{box}} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (12)$$

1.3 整体网络模型

本文在 YOLOv5 的 v6.1 版本基础上,对其进行轻量化处理,改进后的主干网络见表 1,整体网络结构如图 5 所示。从图中可以看出,本文将 Backbone 部分除了第一个卷积以外的卷积模块、C3 模块和 SPPF 模块都替换成了更加精简的 MobileNet Block 模块(即 bneck 模块);在减少参数数量的同时,对输入图片进行特征提取,将 Neck 部分的采样方式替换成 CARAFE 采样。为了能在后面的 Neck 部分对提取到的特征进行融合,将第三层和第八层 MobileNet Block 模块提取的特征信息与 CARAFE 采样处理后的特征信息进行拼接处理,将不同层次的特征图进行融合,生成更丰富的特征信息。此外,为了进一步减少参数数量,去除冗余的卷积通道,将 Neck 部分的卷积通道数精简为原先的一半,使用 SIoU 来充分利用预测框和真实框之间的角度关系,进一步改善网络模型的性能。

表 1 改进后的主干网络

Table 1 Improved Backbone Network

层数	模块	输出通道数	卷积核	注意力机制	激活函数
0	Conv2d	16	3		h-swish
1	bneck	16	3	SE	ReLU
2	bneck	24	3		ReLU
3	bneck	24	3		ReLU
4	bneck	40	5	SE	h-swish
5	bneck	40	5	SE	h-swish
6	bneck	40	5	SE	h-swish
7	bneck	48	5	SE	h-swish
8	bneck	48	5	SE	h-swish
9	bneck	96	5	SE	h-swish
10	bneck	96	5	SE	h-swish
11	bneck	96	5	SE	h-swish

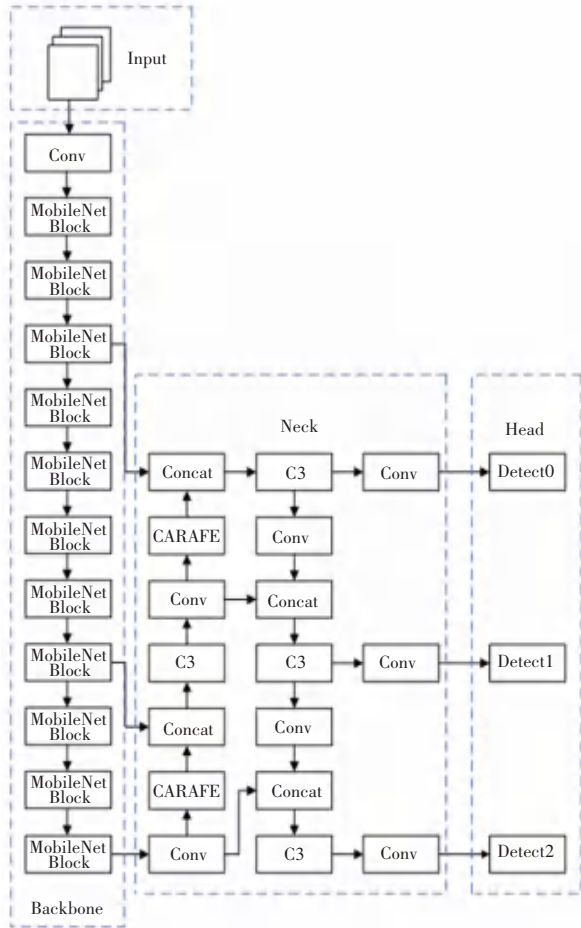


图 5 改进后的整体网络结构

Fig. 5 Improved overall network structure

2 实验结果分析

2.1 实验数据集

本文通过帝泰克检测设备有限公司研发制造的

漏磁检测设备,对油气管道进行多通道漏磁数据的采集,每个通道的漏磁信号为 npz 格式的一维数据,然后对整条管道的漏磁信息进行分段处理,将多通道漏磁信号转化为二维图片的形式,如图 6 所示。为了充分利用到已采的数据,本文根据漏磁数据的特点,采用如图 7 所示的方式重新生成模拟漏磁曲线,将两个真实管道缺陷对应的漏磁曲线进行融合,模拟生成全新的管道缺陷漏磁曲线;此外,本文还通过尺度变换、镜像变换、平移变换等的方式,在原始数据上进行数据增强处理。通过以上两种方式,本文将漏磁曲线数据集扩充至 1 172 张,每张可视化漏磁曲线图中有若干个缺陷,包括腐蚀、凹沟凹槽、制造损伤等,训练集和验证集之比约为 8 : 2。




图 6 漏磁曲线可视化处理

Fig. 6 Visualization processing of magnetic flux leakage curve




图 7 生成模拟漏磁曲线

Fig. 7 Generate simulated magnetic leakage curve

2.2 实验环境及参数设置

本文实验在 Linux 操作系统下进行,所用显卡为 NVIDIA GeForce RTX 2080Ti、显存为 11 GB,使用 python3.8 作为编程语言,在 PyCharm 2021.3.3 上进行测试。另外,本文将实验的训练轮次 epoch 设置为 200, batch-size 为 32,初始权重为 YOLOv5s.pt。

2.3 对比实验及分析

对比实验结果见表 2,其中 YOLOv5-MobileNet3 是将 YOLOv5 的主干特征提取网络替换成了 Mobilenet3;YOLOv5-SIoU 是在 YOLOv5 原始网络的基础上选择 Siou 作为损失函数;YOLOv5-CARAFE 将轻量级通用上采样算子 CARAFE 作为 YOLOv5 的上采样方式;而 Proposed 是本文所提出的轻量化目标检测模型,在使用 MobileNet3 作为

YOLOv5 主干网络的基础上,采用 SIoU 作为损失函数以及 CARAFE 算子作为网络模型的上采样方式。

表 2 对比实验结果

Table 2 Comparison of experimental results

模型	参数量	模型大小/MB	mAP/ %
YOLOv5	7 012 822	13.7	88.7
YOLOv5-MobileNetv3	1 374 732	3.0	88.5
YOLOv5-SIoU	7 012 822	13.7	89.3
YOLOv5-CARAFE	7 146 878	14.0	89.7
Proposed	1 416 196	3.1	89.5

通过表 2 的实验结果可以看出,在将 YOLOv5 的主干网络替换成了更加轻量化的 MobileNetv3,并且将 YOLOv5 的 Neck 部分的卷积通道数减少为原始网络的一半之后,网络模型的参数量减少了 80.4%,模型大小减少了 78.1%。与此同时,由于网络模型的轻量化,导致准确率不可避免地出现了下降,从 88.7% 下降至 88.5%。将 SIoU 作为 YOLOv5 的损失函数之后,得益于 SIoU 能够充分利用到真实框和预测框之间向量角度等信息, mAP 提高了 0.6%。将 CARAFE 上采样算子作为 YOLOv5 的上采样方式之后, CARAFE 算子会通过特征图对上采样核进行预测,然后利用预测的上采样核进行处理,由此能够获取更大的感受野,将 mAP 提高了 1%。本文模型在利用 MobileNetv3 对 YOLOv5 进行轻量化处理的基础上,针对轻量化后准确率下降的问题,将能够提升 mAP 的 SIoU 和 CARAFE 上采样算子引入网络结构中,在参数量减少了 79.8%、模型大小减少了 77.4% 的同时, mAP 提高了 0.8%,既优化了模型的准确率,也使得模型更加的轻量化。

2.4 部分实际效果展示

将本文所改进的算法模型应用于实际场景测试,从测试结果(见图 8)可以看出,将真实管道的漏磁数据进行可视化后,该模型能够将全部缺陷检测出来,并且排除了焊缝等无关因素的干扰,极大地减少了误检的可能性,能够满足实际工程上的应用。




图 8 部分实际测试效果

Fig. 8 Partial actual test results

3 结束语

针对油气管道缺陷检测模型体积、参数量较大的问题,本文提出一种基于 YOLOv5 的轻量化目标检测模型。首先用 MobileNetv3 对 YOLOv5 网络的部分模块进行替换,将前者作为特征提取的主干网络,并精简模型参数,但相应的代价就是准确率的下降;于是,为了在保证轻量化的基础上提升模型检测准确率,本文用 SIoU 损失函数替换原有的损失函数,并引入了 CARAFE 上采样算子。最终根据上述改进方法,本文所提出轻量化目标检测模型的参数量为 1 416 196,模型大小为 3.1 MB,准确率达到了 89.5%,与 YOLOv5 相比,参数量减少了 79.8%,模型大小减少了 77.4%, mAP 提高了 0.8%,在精简模型的基础上,提升目标检测准确率,满足了实际工程中的应用需求。

参考文献

- [1] 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. DOI:10.19650/j.cnki.cjsi.2016.08.005
- [2] 林俊明. 漏磁检测技术及发展现状研究[J]. 无损探伤,2006(1):1-5,11.
- [3] PENG L, HUANG S, WANG S, et al. A simplified lift-off correction for three components of the magnetic flux leakage signal for defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [4] 方路平,何杭江,周国民. 目标检测算法研究综述[J]. 计算机工程与应用,2018,54(13):11-18,33.
- [5] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2005:886-893.
- [6] FREUND Y, SCHAPIRE R E. Experiments with a new boosting algorithm[C]//Proceedings of Thirteenth International Conference on International Conference on Machine Learning. Piscataway, NJ: IEEE, 1996:148-156.
- [7] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards realtime object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.
- [8] DAI J, LI Y, HE K, et al. R-fcn: Object detection via region-based fully convolutional networks [C]//Proceedings of the Annual Conference on Neural Information Processing Systems. Piscataway, NJ: IEEE, 2016. DOI:10.48550/arXiv.1605.06409
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016:779-788.
- [10] LI W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]// Proceedings of the 2016 European Conference on Computer Vision. Cham: Springer, 2016:21-37.

-
- [11] JIA Y, LIANG K, WANG P, et al. Enhancement method of magnetic flux leakage signals for rail track surface defect detection [J]. IET Science, Measurement & Technology, 2020, 14(6): 711–717.
- [12] LIU X, HU C, PENG P, et al. In-pipe detection system based on magnetic flux leakage and eddy current detection[C]// Proceedings of 2020 International Conference on Sensing, Measurement & Data Analytics in the Era of Artificial Intelligence (IC-SMD). Piscataway, NJ: IEEE, 2020: 164–169.
- [13] SHI Y, ZHANG C, LI R, et al. Theory and application of magnetic flux leakage pipeline detection [J]. Sensors, 2015, 15(12): 31036–31055.
- [14] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetv3[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ:IEEE, 2019: 1314–1324.
- [15] GEVORGYAN Z. Siou loss: More powerful learning for bounding box regression [J]. arXiv preprint arXiv, 2205, 12740, 2022.
- [16] WANG J, CHEN K, XU R, et al. Carafe: Content-aware reassembly of features [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: 2019: 3007–3016.
- [17] REDMON J, FARHADI A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv,1804.02767, 2018.
- [18] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. arXiv preprint arXiv,2004.10934, 2020.
- [19] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv,1704.04861, 2017.
- [20] SANDLER M, HOWARD A, ZHU M, et al. MobileNetv2: Inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ:IEEE, 2018: 4510–4520.