

基于改进 YOLOv5 算法的管道漏磁信号识别方法

王国庆¹, 李璇¹, 杨理践¹, 高松巍¹, 耿浩^{1,2}

(1. 沈阳工业大学 信息科学与工程学院, 沈阳 110870;

2. 大连理工大学 工业装备智能控制与优化教育部重点实验室, 大连 116024)

摘要: 长输油气管道作为能源运输的主要方式, 安全问题至关重要; 管道漏磁内检测技术作为管道缺陷检测的重要方法之一, 在管道安全保障中发挥着重要作用; 人工智能技术可实现管道内检测数据的自动识别, 对于减少人力工作量, 减少人为误差, 提升数据判读准确性具有重要意义; 通过引入损失函数 Distance-IoU 对目标检测算法 YOLOv5 进行改进, 利用改进 YOLOv5 算法对管道漏磁数据进行训练, 使之具有对漏磁缺陷信号自动识别的能力; 通过实验, 对实际漏磁内检测数据进行识别; 结果表明, 改进的 YOLOv5 算法实现了管道缺陷漏磁信号的自动检测识别; 并且在相同的训练条件下, 改进的 YOLOv5 算法相较于原始算法准确率有明显的提升, 在识别缺陷数量上其精度达到 92.8%, 比原算法提升了 3.22%, 改进后的模型损失函数平均损失率为 3.6%, 比原始 YOLOv5 模型降低了 2.2%, 表明该方法在管道缺陷漏磁数据自动识别检测方面具有较好的可行性。

关键词: 管道; 漏磁内检测; 缺陷检测; 深度学习; YOLOv5 算法; 自动识别

Pipeline Magnetic Flux Leakage Signal Recognition Method Based on Improved YOLOv5 Algorithm

WANG Guoqing¹, LI Xuan¹, YANG Lijan¹, GAO Songwei¹, GENG Hao^{1,2}

(1. College of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China;

2. Key Laboratory of Intelligent Control and Optimization of Industrial Equipment, Ministry of Education, Dalian University of Technology, Dalian 116024, China)

Abstract: As the main way of energy transportation, the safety of long-distance oil and gas pipeline is very important. As one of the important methods of pipeline defect detection, pipeline magnetic flux leakage internal detection technology plays an important role in pipeline safety. Artificial intelligence technology can realize the automatic identification of pipeline inspection data, which is of great significance to reduce human workload, reduce human error and improve the accuracy of data interpretation. The Distance-IoU loss function is introduced to improve the YOLOv5 algorithm, and the improved YOLOv5 algorithm is used to train the pipeline magnetic flux leakage data, so that it can automatically identify the magnetic flux leakage signal. Through experiments, the actual magnetic flux leakage (MFL) internal detection data are identified. The results show that the improved YOLOv5 algorithm can realize the automatic identification and detection of pipeline defects. Under the same training conditions, the accuracy of the improved model is significantly higher than that of the original model. The accuracy of the defect identification is 92.8%, which is 3.22% higher than that of the original model. The average loss rate of the improved model is 3.6%, which is 2.2% lower than that of the original model. The results show that the method is feasible in the automatic identification and detection of the pipeline defect MFL data.

Keywords: pipeline; magnetic flux leakage internal detection; defect detection; deep learning; YOLOv5 algorithm; automatic identification

0 引言

管道运输作为石油和天然气等能源的主要运输手段, 其安全问题尤为重要, 并且随着管道数量和里程数的增加, 对于管道安全的维护难度也相应增加, 漏磁检测等无损检测方法可以检测出管道中的缺陷^[1], 为解决管道安全问题提供了很大帮助。

漏磁内检测数据的判读是评估管道缺陷的基础^[2]。由于长输管线输送距离较长, 漏磁内检测数据量庞大。传统的漏磁数据识别分析方法大多需要人工判读, 但是利用人工判别的方式进行漏磁数据检测, 结果会受到无损检测员专业水平的影响, 且对缺陷的判别没有统一的标准, 对于不同的检测人员, 检测结果容易受到主观影响^[3]。并且人工判读需要花费大量的精力和时间, 容易造成人员疲劳从

收稿日期: 2022-01-21; 修回日期: 2022-03-14。

基金项目: 辽宁省自然科学基金面上项目(2019-MS-243); 国家自然科学基金项目(62101356); 辽宁省教育厅高等学校基本科研项目(LJKZ0134); 大连理工大学工业装备智能控制与优化教育部重点实验室开放课题基金资助项目(LICO2021TB02)。

作者简介: 王国庆(1980-), 男, 辽宁抚顺人, 副教授, 主要从事长输管道先进在线检测技术及无损检测技术方向的研究。

通讯作者: 李璇(1997-), 女, 辽宁沈阳人, 硕士研究生, 主要从事管道漏磁内检测技术及数据识别方向的研究。

引用格式: 王国庆, 李璇, 杨理践, 等. 基于改进 YOLOv5 算法的管道漏磁信号识别方法[J]. 计算机测量与控制, 2022, 30(8): 147-154.

而导致漏检或误检。通过机器学习的方法建立模型并进行训练, 可以实现对管道漏磁内检测数据的批量处理和自动识别^[4-6]。对于减少人力工作量, 减少人为误差, 提升数据判别的准确性具有重要意义。

近年来, 众多学者在机器学习识别缺陷方面进行了大量研究, 提出了不同的算法来自动识别漏磁缺陷信号^[7-10]。不同的方法在缺陷识别的准确度和效率方面存在差异, 在管道缺陷位置识别精度上也有待提高。采用一种基于改进的 YOLOv5 算法来对管道漏磁缺陷进行识别检测^[11-14], 通过向改进 YOLOv5 网络中输入实际检测数据进行训练, 建立漏磁曲线缺陷识别系统, 从而提升缺陷的识别准确性。

1 YOLOv5 算法

YOLO (You Only Look Once) 算法是一种基于回归思想的多目标检测算法, 代表可以从一张图像上识别出多种不同种类的物体, 并通过非线性拟合计算出物体的尺寸坐标, 以便为检测出的物体打上标注框。YOLO 算法经过近几年的不断改进, 发展成为现在的 YOLOv5 算法。YOLOv5 网络模型结构总共分为输入端、Backbone、Neck 以及 Prediction 四个部分。YOLOv5 算法的网络模型结构如图 1 所示。

第一部分为输入端, 它表示输入的图片。在该网络模型中输入图像的大小为 640×640 , 在输入端模块会对图像进行图像预处理, 具体为将图像缩放至便于网络训练的大小, 以及对图像进行归一化等操作。输入端分为 3 个部分: mosaic 数据增强、自适应锚框计算和自适应图片缩放^[15], 其中 mosaic 数据增强部分可以使模型能够更好地对图像中的小目标物体进行检测, 也可以使模型的训练速度和模型精度大大提升。自适应锚框计算部分通过对每一次迭代输出的预测框面积进行更新, 从而使模型预测的结果更加地

合理化, 自适应图片缩放部分的作用是对原始图像进行缩放, 使输入图像统一为一个标准尺寸后, 再送入检测网络中检测。Backbone 为基准网络, 该模块是为了对图像提取一些通用的特征表示。它分为两个部分: 分别是 Focus 结构和 CSP 结构, 其中 Focus 结构主要的作用是对图像进行切片操作, CSP 结构是为了从网络结构设计角度使推理中计算量很大的问题得以解决^[16]。Neck 网络通常是在 Head 网络和 Backbone 网络中间的位置, 它起到进一步提升特征的多样性和鲁棒性的作用。该模块为 FPN+PAN 结构, 它可以使加强网络特征融合的效果更好。Prediction 使用的是 GIOU_Loss 损失函数^[17], 该损失函数可以对检测目标矩形框的识别损失率进行估算, 并使算法的检测精度大大提升。

YOLOv5 算法根据其含有的残差组件个数不同分为 4 个目标检测版本, 分别为 Yolov5s、Yolov5m、Yolov5l 和 YOLOv5x, 4 个目标检测版本残差组件依次递增, YOLOv5 算法的不同网络结构的残差组件个数和卷积核个数如表 1 所示。随着 YOLOv5 算法网络深度逐渐加深, 其模型的特征提取和特征融合能力也越来越强大^[18]。

表 1 YOLOv5 的不同网络结构卷积核个数以及残差组件个数

结构网络	残差组件个数/个	卷积核总数/个
YOLOv5s	12	1 001
YOLOv5m	24	1 488
YOLOv5l	36	1 984
YOLOv5x	48	2 480

其中: YOLOv5s 是网络深度最小、特征图宽度最小的网络^[19], 其他的 3 种网络都是在 YOLOv5s 的基础上对网络进行加深以及加宽, 可利用代码的编写控制每种模型的深度与宽度, 更改便捷, 实验中通过从节约内存成本和计算

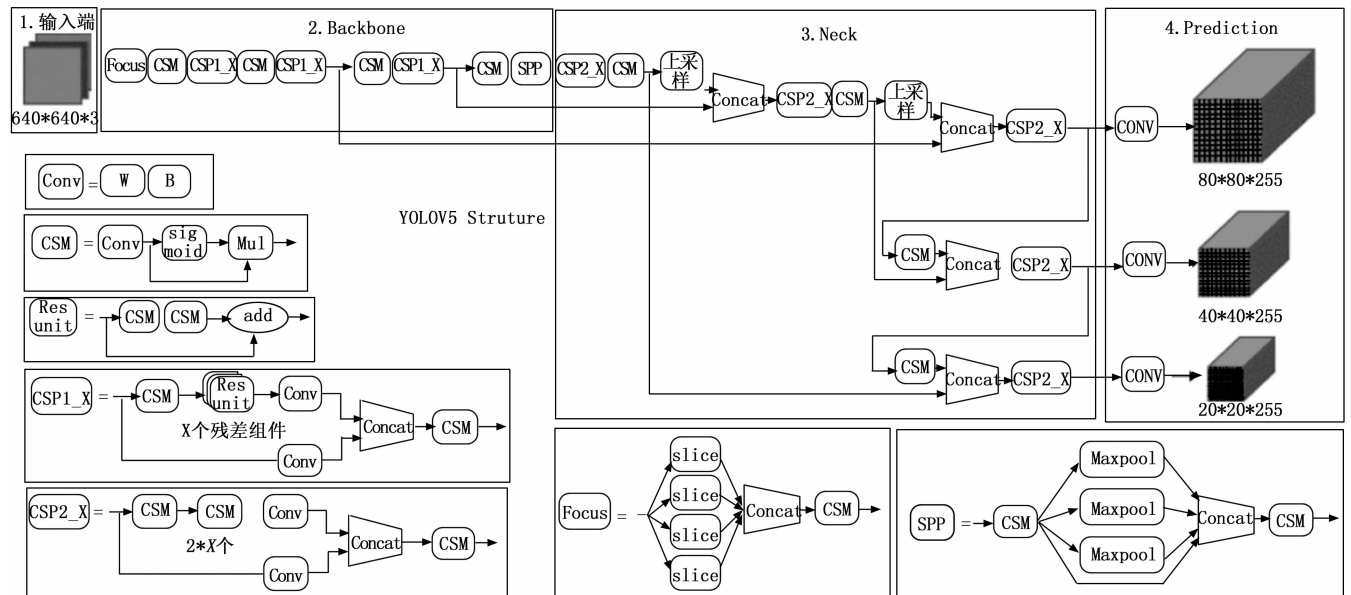


图 1 YOLOv5 网络模型结构

成本发的角度考虑, YOLOv5s 可以使网络更加地轻量级, 故本实验选择了网络模型深度以及宽度均最小的 YOLOv5s 进行模型训练, YOLOv5s 的网络结构如图 2 所示。

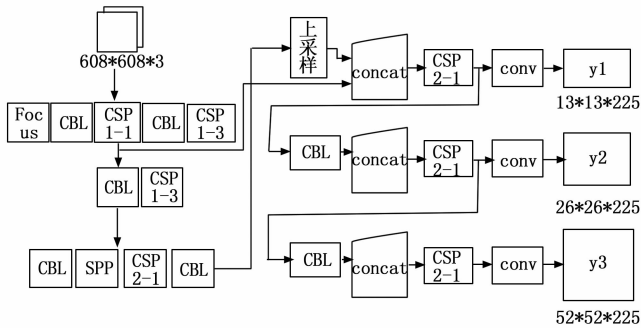


图 2 YOLOv5s 网络结构

YOLOv5 对于目标识别检测有着良好的表现的主要原因如下:

1) YOLOv5 算法输入端模块设计了 Mosaic 数据增强, 丰富了数据的多样性, 同时自适应锚框计算以及自适应图片缩放的使用, 也使模型的检测速度大大提升;

2) YOLOv5 算法的主干网络中使用了 Focus 模块和 CSP 模块^[20], Focus 模块在输入图像特征图转换过程实现切片操作, 效果表现良好, CSP 模块可以提升网络学习能力, 提升检测准确率, 节约内存成本;

3) Neck 网络中使用了与主干网络不同的 CSP 模块, 在输出端部分使用 GIOU_Loss 损失函数为预测框的损失函数, 在目标识别的后处理过程中, YOLOv5 模型采用了加权 NMS (非极大值抑制) 算法。

2 改进 YOLOv5 算法

YOLOv5 算法是一种基于回归的目标检测算法, 其采用直接输入整张图片的方式, 不再使用卷积神经网络的全连接层, 直接形成端到端的网络。边界框回归 (bounding box regression) 算法是该算法的核心, 利用边界框回归算法能够在大量的管道漏磁检测数据中准确的找到管道缺陷位置, 并对其边界进行准确划定。边界框回归算法使用窗口滑动机制将整张图片划分为 $S \times S$ 个网格, 如果待检测目标的中心在某一网格中, 则由该网格对待检测目标进行识别预测。每个网格会针对待测目标产生多个大小不一的候选检测框, 最终通过平移缩放等几何变换对候选框进行回归, YOLOv5 模型的回归计算方法为:

$$b_x = 2\sigma(t_x) - 0.5 + c_x \quad (1)$$

$$b_y = 2\sigma(t_y) - 0.5 + c_y \quad (2)$$

$$b_w = p_w(2\sigma(t_w))^2 \quad (3)$$

$$b_h = p_h(2\sigma(t_h))^2 \quad (4)$$

式中, t_x, t_y, t_w, t_h 分别为 x, y 轴坐标宽度和高度的偏移量, b_x, b_y, b_w, b_h 分别为回归的结果, (c_x, c_y) 表示边界框在左上角的坐标值, p_w, p_h 表示预测的前边框的宽度和高度。计算时的求解方法使用残差平方和, 并用逻辑回归方法找出图像管道漏磁缺陷信号的边界框。

YOLOv5 在目标识别过程中引入候选检测框, 候选检测框是一组固定尺寸和宽高比的初始区域^[21], 初始检测框越接近真实检测框, 其模型的训练越容易, 训练结果检测精度越高。所以, 初始检测框的确定会直接影响到真实检测框位置的确定和模型识别的精度。YOLOv5 模型中采用了加权 NMS (非极大值抑制) 算法对初始检测框进行筛选, 将交并比较大并且置信度较低检测框判定为冗余检测框, 并对冗余检测框进行删除。在 YOLOv5 算法中, 非极大值抑制算法会将预测框集合 B , 与集合 B 中每个预测框相对应的置信度集合 C 和最终输出的预测框集合 3 个集合进行汇总。并对集合 C 中的置信分数从高到低将集合 B 中与其对应的预测框进行排序, 将置信度值最高的预测框选出放到集合 R 中, 移除集合 B 中的该预测框。将集合 B 中其余的预测框与置信度值最高的预测框计算交并比 IOU 的数值, 并将交并比值与设定的阈值进行大小比较, 移除交并比值比设定阈值大的相对应预测框。重复对集合 B 中剩余预测框置信度进行排序, 直至集合 B 中的预测框被全部移除为止, 此时的集合 R 为该数据集所求预测框。该算法虽然解决了形成的多个检测框而导致的标记框冗余问题, 但是阈值的不同设定会影响检测精度, 实验中引进自适应阈值调整的方法, 对预测框的选择进行了自适应调整, 以减少漏检问题。

改进的 NMS 算法如下所示:

$$C^{i,j} = \begin{cases} C^i & IOU < N \\ C^i(1 - IOU) & IOU \geq N \text{ 时}, N = N_i \end{cases} \quad (5)$$

$$N_i = \frac{I_m - N}{N} \times N + N \quad (6)$$

式中, $C^{i,j}$ 为最终的置信度结果, IOU 为计算所得的两个边界框的交并比数值, N 为 YOLOv5 默认的设置阈值 0.5, N_i 为可变动的自适应阈值。即选取的最大置信度 I_m 与默认阈值 N 的差值和默认阈值 N 之比, 使默认阈值 N 向大于 0.5 方向按差值比例偏移得到的数值为 N_i 的值。更改后的自适应 NMS 算法在挑出置信度最高的预测框后, 会计算集合 B 中剩余预测框与选出预测框的 IOU 值, 在 IOU 值大于阈值的预测框中选出数值最大的值设为 I_m , 根据式 (6) 重新计算 N_i 的值为新的阈值, 最后把比 N_i 值大的 IOU 值相对应的预测框进行移除操作, 重复上述比较, 直至集合 B 中的预测框个数为零。改进后的 NMS 算法的阈值设定与预测框相关, 预测框的结果与最终的检测结果相关, 故对阈值进行上述优化, 以提升算法的识别准确率。

在 YOLOv5 算法中, 损失函数作为该算法输出端的一部分, 起到了计算边界框损失的作用。利用它可以对边界框的位置进行调节, 提升该算法对漏磁信号识别的准确性^[22]。传统的 YOLOv5 算法采用损失函数 GIOU Loss 来计算边界框的损失, 其评价指标广义交并比 GIOU (generalized intersection over union) 直接把交并比 IoU (intersection over union) 设为模型回归的损失, 用下式表示:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (7)$$

$$GIoU = IoU - \frac{|C \setminus A \cup B|}{|C|} \quad (8)$$

其中：交并比 IoU 为在遍历所有图像网格后，在网络输出端输出的置信度，置信度是候选边界框与真实边界框的交并比^[23]，式中： A 、 B 分别为真实边界框和候选边界框的面积。在任意的两个边界框 A 、 B 中先确定一个最小的闭合形状 C ，然后计算真实边界框 A 与候选边界框 B 的交并比，再利用交并比减去封闭形状 C 中没有覆盖真实边界框和候选边界框的面积占闭合形状 C 总面积的比值，进而得到损失函数 $GIoU Loss$ ，其损失函数计算如下： $L_{GIoU} = 1 - GIoU$ 。在该算法求解时，将损失函数 $GIoU Loss$ 与非极大值抑制算法（NMS）相结合，搜索局部极大值进而得到准确的漏磁信号标注结果。

$GIoU$ 由于惩罚项的引入，在目标框和预测框不重叠的情况下，预测框会向漏磁数据标定目标框移动， $GIoU$ 除了关注漏磁信号目标框与预测框的重叠区域不同，还关注了非重叠区域，能够更好的反应重合度。但 $GIoU$ 仍然在相邻缺陷识别准确性上存在问题，对于一些没有重叠的目标检测框， $GIoU$ 回归策略可能会退化为交并比 IoU 的回归策略^[24]。其主要问题在于，当 IoU 返回值为 0 时， $GIoU$ 倾向于使漏磁缺陷信号检测框和目标框以最快方式产生重叠，而后 $GIoU$ 的惩罚机制逐渐失效，即检测框与目标框之间的包含而不重叠也被认为是正确的。为了解决这一问题，在 $GIoU$ 中引入欧氏距离 ρ ，检测框和目标框之间的最小矩形斜距 c 以及检测框和目标框的中心点 b, b^g ，达到提升漏磁信号识别精度的目的。建立 $DIoU$ （Distance-IoU）公式原理如下所示：

$$L_{DIoU} = 1 - IoU + \frac{\rho^2(b, b^g)}{c^2} \quad (9)$$

在该损失函数中， b, b^g 分别表示检测框和目标框的中心点，其欧式距离为 ρ 。 c 为覆盖检测框和目标框之间的最小矩形的斜距。 $DIoU$ 中添加了一个惩罚项，故仍然保留 $GIoU$ 中当预测框和目标框不重叠时，预测框可以向目标框移动这一优点。同时，对于漏磁缺陷信号的识别， $DIoU Loss$ 能迅速使漏磁信号预测框与目标框之间的距离最小化，而 $GIoU Loss$ 优化的是识别出的漏磁信号预测框与已标定的目标框之间的面积，所以 $DIoU$ 和 $GIoU$ 相比，不但可以提升精度，还可以加快收敛速度。

3 数据集建立

3.1 管道漏磁内检测数据采集

管道漏磁内检测器中，漏磁场信号的采集记录由探头完成，然后将漏磁场信号信息传送到计算机部分，由计算机部分将漏磁数据和管道其他信息数据统一存储记录。管道漏磁数据扫描格式如图 3 所示。每次扫描的管道漏磁信号数据被保存在一个完整的文件中，一个数据文件主要包括漏磁场信号的数据和辅助数据。

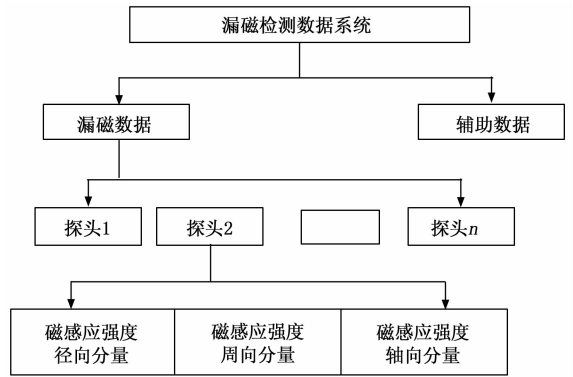


图 3 管道漏磁内检测数据组成部分

其中漏磁场信号的数据主要有 φ 分量、 ρ 分量和 z 分量，它们分别相当于管道周向、径向和轴向的三维磁感应强度分量；其他的数据主要有探头每次扫描所需要的时间信息；探头所在的周向位置信息；管道相关配置文件信息等。

探头在管道内检测器中的排列方向为逆时针方向排列，分别记录管道周向 360° 漏磁场信号特征。其中，磁感应强度径向分量、磁感应强度周向分量、磁感应强度轴向分量又为管道外部和管道内部的同一个检测点的信息。对于辅助数据的内容主要有扫描时间、探头的周向、距离、经度、纬度、温度、瞬时速度、压力、数据处理标志、硬件版本信息、备用、结束标志等设置信息。

3.2 管道漏磁信号成像

YOLO 模型对于目标的识别分类过程为有监督训练方法，需要输入图像数据集，将漏磁数据通过管道漏磁检测数据分析系统分段导出，每段数据包括 X 、 Y 、 Z 三个方向的磁场数据，分别为管道漏磁信号轴向数据、径向数据和周向数据。管道漏磁信号数据经管道漏磁内检测器的存储单元内导出，导出格式为十六进制的 DAT 数据文件，利用漏磁数据分析软件对 DAT 文件进行数据读取，将 DAT 数据格式转换为 txt 文本数据格式，通过对数据进行处理，提取数据文件中所需要的检测信息，利用代码将 txt 文件批量转化为曲线图，将管道漏磁数据可视化，以供机器进行识别判读。

曲线图像的成像原理是将转换完数据格式后的数据点直接输入到计算机中，将检测器内各个通道中的实际检测值按照描点连线的方式对其进行成像，从而生成曲线图像。其中，曲线图像中的横坐标表示沿检测器运行方向上采集检测点的数量，可通过计算得到里程数；纵向为多通道传感器并行采集的数据，每条曲线的波动情况则反映漏磁数据的大小。定义漏磁检测数据中的记录数为横坐标 X ，漏磁检测数据中的实际检测值为纵坐标 Y ，通过描点成像进而实现管道漏磁内检测的曲线显示。生成的漏磁检测曲线如图 4 所示。

长输油气管道一般由高磁导率的铁磁性材料加工而成，检测过程中需要经过励磁装置磁化。以轴向永磁励磁方式的管道漏磁内检测装置为例，磁通经过的磁路主要由永磁




图 4 漏磁检测曲线图

体、轭铁、钢刷、管道、工作气隙及装配气隙几部分组成。在磁路内部安装有磁敏元件, 以检测缺陷处漏磁通。管道壁上不存在缺陷, 磁力线会直接均匀地通过管道壁。在管道壁上存在自然缺陷或焊缝缺陷时, 磁力线无法直接通过缺陷处的管道壁, 会形成畸形的, 不均匀的磁通回路, 形成漏磁场。可通过对漏磁场的位置进行标定, 建立漏磁曲线图像缺陷数据集。

3.3 建立 YOLO 数据集

现有的数据进行某种操作后生成新的数据来扩充数据库, 采用预设的数据变换规则, 在已有数据的基础上进行数据扩增, 在单样因为 YOLOv5 模型受数据样本量的影响较大, 所以训练中需要大量的数据来支撑, 但是获取足够的图像数据集相对较难。实验利用本数据增强中, 基本上可以对图像进行以下 4 种操作, 分别为图像颜色反转、对图像进行亮度增强、图像镜像以及对图像进行旋转。实验共建立 1 400 张漏磁曲线图像作为数据集, 其中每张图像大小均为 875×656 像素。YOLOv5 模型对于图像的识别是有一种有监督的神经网络训练过程, 模型的输入是图像, 需要人为对输入图像进行标记, 定义图像特征, 为其制作标签文件。实验利用图像标注工具 labelImg 软件为漏磁信号标准缺陷进行标准标注, 从而为模型提供标准缺陷信息。漏磁缺陷信号数据标定如图 5 所示。

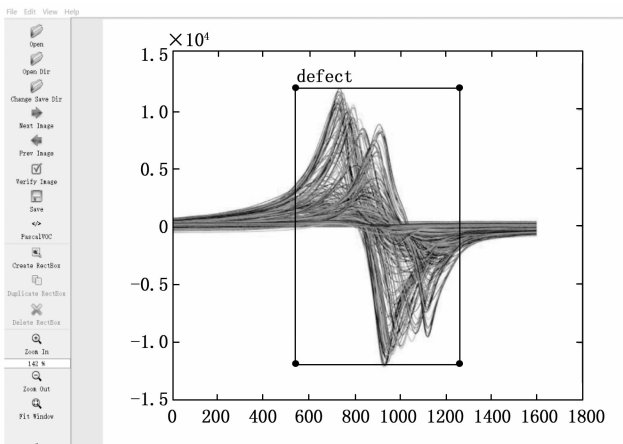


图 5 漏磁缺陷信号数据标定

通过在 labelImg 软件上为管道漏磁信号曲线缺陷处打上识别标框, 记录管道漏磁曲线缺陷信息。再通过 labelImg 软件生成格式为 PASCAL VOC 数据文件, 即 .xml 后缀文件, xml 文件中存储着标注框的关键信息, 有标注框在 x 轴上的最小值 x_{\min} 、标注框在 y 轴上的最小值 y_{\min} 、标注框在 x 轴上的最大值 x_{\max} 、标注框在 y 轴上的最大值 y_{\max} 四个关键参数, 利用标注框在 x 轴上的最大值与标注框在 x 轴上的最小值之差得到标注框的宽, 利用标注框在 y 轴上的最大值与标注框在 y 轴上的最小值之差得到标注框的高, 进而确定标注框的左上角坐标以及标注框的大小, 根据这个思想利用代码将 xml 文件转化为 txt 格式文件, 为建立 YOLO 模型数据集做准备。改进 YOLOv5 模型数据格式如图 6 所示。

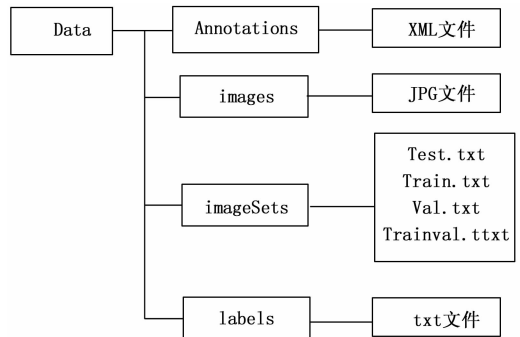


图 6 YOLOv5 数据格式

将数据集按照 5: 1: 1 比例进行训练集、验证集和测试集的划分, 随机抽取 1 000 张图像作为训练集, 200 张图像作为验证集, 剩余 200 张图像作为测试集, 并按照如上的数据格式对数据集文件夹进行建立, 完成 YOLOv5 模型数据集的制作, 其中, Annotations 文件夹和 labels 文件夹存放图像标注框的坐标信息, images 文件夹存放数据图像, imageSets 文件夹存放训练集和验证集的图像名称与存放地址。

4 模型训练

实验需要搭建深度学习平台对 YOLOv5 模型进行训练, 管道漏磁缺陷信号识别实验的运行环境如下: CPU 为 Intel i7-7700 K, GPU 为 NVIDIA GeForce GTX 1070, 系统内存为 16 G, 操作系统为 Windows 7 64 位, 安装驱动为 CUDA 11.2, 开发语言为 Python, 深度学习框架为 Pytorch。

首先进行数据预处理, 训练过程中需要 PASCAL VOC 和 YOLO 两种数据文件, 利用 LabelImg 生成格式为 PASCAL VOC 的数据, 即 .xml 后缀文件, 再利用代码将其转化为 txt 格式文件, 转换后的 txt 文件可以方便 YOLOv5 模型进行数据的读取。之后将准备好的数据集输入 YOLOv5s 进行训练, 然后初始化先验框参数, YOLOv5 采用 K-means 聚类算法对数据集的标注框进行聚类得到初始先验框。YOLOv5 中的先验框, 是由宽 w 和高 h 两个参数组成, 利用图像的像素尺寸, 来表示数据样本中样本的大概形状。在 YOLOv5 中共有 9 个先验框, 平均分配在 3 个检测层上,

每个检测层分配 3 个尺寸不同的检测框。不同尺寸的检测框对不同尺寸的特征有着不同的敏感程度，不同尺寸的特征会匹配与其对应的先验框。运行模型得到适合该数据集的先验框参数，并将先验框参数写入此模型。通过确定更精确的先验框，可以使网络模型对于待检测目标有更好的识别精度。

设置初始先验框后，为模型导入预训练模型权重，并通过训练调整该模型的权重。训练模型设置图像尺寸参数 img 为 640，单次训练图像数 $batch$ 为 16，训练次数 $epochs$ 为 100 次。分别将 $GIoU$ Loss 和 $DIoU$ Loss 作为模型训练的损失函数。

通过建立的数据集分别对原始 YOLOv5 网络和改进 YOLOv5 网络进行训练，图像尺寸参数设置、单次训练图像数和训练次数保持不变。在漏磁信号数据训练集和验证集上训练后的损失函数均值曲线与目标检测损失均值曲线分别如图 7 和图 8 所示。

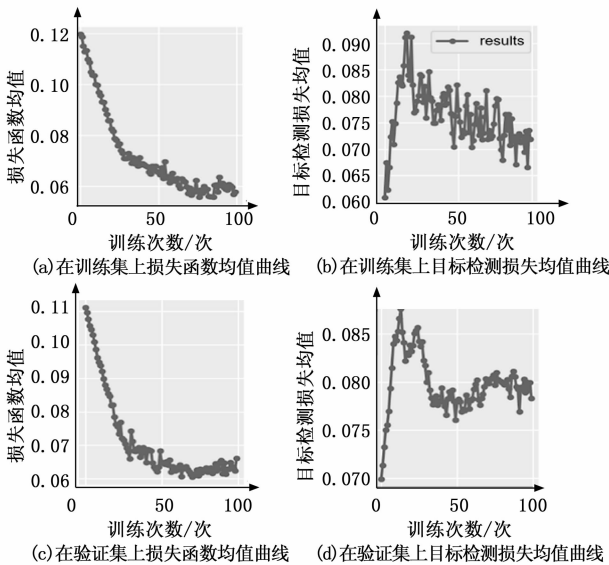


图 7 原始 YOLOv5 网络在训练集和验证集上损失函数曲线与目标检测损失均值曲线

从图 7、8 可以看出，在相同的实验条件下，改进的 YOLOv5 算法在训练集和验证集上的损失函数均值与目标检测损失均值和原始的 YOLOv5 算法相比，均有所下降。针对训练集，改进 YOLOv5 算法在训练结束后损失函数均值由 0.058 降为 0.036，目标检测损失均值由 0.071 降为 0.012；针对验证集，改进 YOLOv5 算法损失函数均值由 0.066 降为 0.033，目标检测损失均值由 0.078 降为 0.011。这表明了每处漏磁信号缺陷识别框和需要识别的对应缺陷目标框面积之差减小，漏磁信号识别框位置也更加准确，改进 YOLOv5 算法起到了更良好的效果。

5 实验结果及分析

5.1 测试过程

将测试集输入训练后的网络，并将权重文件更改为训

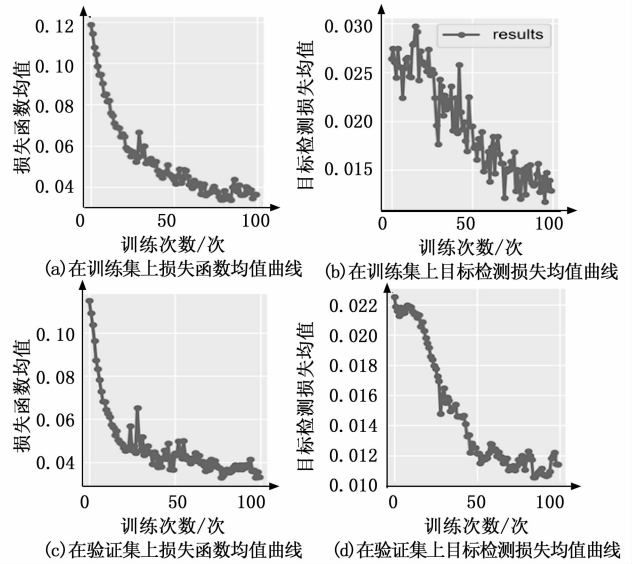


图 8 改进 YOLOv5 网络在训练集和验证集上损失函数均值曲线与目标检测损失均值曲线

练后的最佳权重。分别对 X 、 Y 、 Z 三个方向上的单个缺陷、组合缺陷、相邻缺陷、边缘缺陷以及不规则缺陷进行自动识别。运行改进后的 YOLOv5 模型，缺陷的自动识别结果如图 9~11 所示。

从图 9~11 可以看出，对于 X 、 Y 、 Z 三个方向上的磁场信号，通过改进的 YOLOv5 算法，均对漏磁缺陷信号进行了有效的自动识别。对于单个缺陷、组合缺陷、相邻缺陷、边缘缺陷以及不规则缺陷均具有很好的识别效果。测试结果表明，改进的 YOLOv5 算法可以在漏磁缺陷图像上找到缺陷信号的位置，并形成识别框。通过自动对缺陷信号进行识别标注，实现了管道缺陷自动识别的过程。

5.2 测试结果评价

采用插值平均精度方法对漏磁数据的自动识别过程进行评价，计算缺陷类别识别准确率 P 和召回率 R 并绘制 P - R 曲线， P - R 曲线下的面积为平均准确率 AP 的值，多个类别的平均准确率 AP 的平均值即为总平均准确率 mAP 。对于 YOLOv5 模型，平均准确率 AP 和总平均准确率 mAP 通常被作为评估模型的指标，缺陷类别识别准确率 P 和召回率 R 的计算如式 (10)、(11) 所示：

$$P = \frac{TP}{TP + FP} \quad (10)$$

式中， TP 为准确检测出漏磁缺陷信号的数量， FP 为将非漏磁缺陷信号检测为缺陷信号的数量。

$$R = \frac{TP}{TP + FN} \quad (11)$$

式中， FN 为将漏磁缺陷信号检测为非缺陷信号的数量。

$$mAP = \frac{1}{|Q_R|} \sum_{q \in Q} AP(q) \quad (12)$$

实验采用的评估指标主要包括：模型训练损失函数均值、目标检测损失均值以及平均准确率 mAP 。其中模型训练损失函数均值和目标检测损失均值越低，代表漏磁信号




图 9 X 向漏磁数据自动识别结果




图 10 Y 向漏磁数据自动识别结果




图 11 Z 向漏磁数据自动识别结果

识别效果越好; 平均准确率 mAP 值越高, 代表模型分辨漏磁缺陷信号和漏磁非缺陷信号的能力越好。实验利用 200 张未标注的管道漏磁信号图像对改进的 YOLOv5 模型进行验证, 图 12 为模型的 mAP 评价结果, 本次训练模型 mAP 值为 0.928, 说明该模型精度较高, 测试结果良好, 对管道漏磁信号缺陷检测具有一定的可行性。




图 12 模型 mAP 评价结果

6 结束语

针对管道漏磁信号识别中存在的问题, 在传统的

YOLOv5 算法的基础上, 对 YOLOv5 算法进行了改进, 提出了基于改进的 YOLOv5 算法的管道漏磁信号识别方法。实验结果表明, 改进的 YOLOv5 算法在漏磁信号的识别准确性上有大幅度提升, 缺陷识别精度相较于原算法有明显提高, 对漏磁信号的位置及形态均具有较好的识别能力。基于改进的 YOLOv5 算法实现了管道缺陷漏磁数据的自动检测和识别, 模型平均准确率 mAP 值达到 0.928, 实现了管道漏磁信号识别精确度的提升。经实验验证, 该方法具有一定的可行性, 可在短时间内大量标注管道漏磁曲线图像缺陷信息, 降低人员工作量, 提升数据判读的准确性。

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): 1737-1746.
 [2] 冯子勇. 基于深度学习的图像特征学习和分类方法的研究及应用[D]. 广州: 华南理工大学, 2016.
 [3] 赵瀚学, 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.

- [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 (9): 180-187.
- [5] 许德刚, 王 露, 李 凡. 深度学习的典型目标检测算法研究综述 [J]. 计算机工程与应用, 2021, 57 (8): 10-25.
- [6] 马天航, 胡家铨, 郑 莉, 等. 一种基于人工提取缺陷块的边界搜索方法 [J]. 无损检测, 2020, 8 (10): 1-7.
- [7] QI Q, ZHAO S Y, et al. High-speed video salient object detection with temporal propagation using correlation filter [J]. Neurocomputing, 2019, 356 (3): 107-118.
- [8] 白智慧. 基于卷积神经网络的管道缺陷识别研究 [J]. 价值工程, 2020, 39 (7): 270-272.
- [9] 张鑫博, 冯 建. 基于机器学习的漏磁信号异常检测方法研究 [D]. 沈阳: 东北大学, 2017.
- [10] WANG C Y, MARK LIAO H Y, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of cnn [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390-391.
- [11] 谢昊源, 黄群星, 林晓青, 等. 基于图像深度学习的垃圾热值预测研究 [J]. 浙江大学工程师学院, 2021, 72 (5): 2773-2782.
- [12] 闫登豪. 基于深度学习的车辆行人目标检测算法研究 [D]. 长春: 长春大学, 2021.
- [13] 王健羽. 基于深度学习的光伏组件异常遮挡检测系统研究 [D]. 吉林: 东北电力大学, 2021.
- [14] 高 慧. 基于深度学习的视频目标检测算法研究 [D]. 成都: 电子科技大学, 2021.
- (上接第 146 页)
- [8] 梁振宇, 段文锐, 何宇杰, 等. 风电叶片多角度疲劳力学性能检测装置 [J]. 机械管理开发, 2021, 36 (4): 3-5.
- [9] 康 爽, 陈长征, 周 勃, 等. 基于温度阈值风电叶片缺陷识别的红外检测研究 [J]. 太阳能学报, 2020, 41 (8): 337-341.
- [10] 陈荣敏, 王皓冉, 汪 双, 等. 基于无人机的坝面裂纹缺陷智能检测方法 [J]. 水利水电科技进展, 2021, 41 (6): 7-12.
- [11] 张新英, 王焱春, 王双岭. 基于深度学习的绝缘子故障巡检算法研究 [J]. 中原工学院学报, 2021, 32 (5): 45-49.
- [12] 田小壮, 石 辉, 刘家辛, 等. 复杂环境下无人机智能巡检轨迹规划方法研究 [J]. 电子设计工程, 2021, 29 (20): 77-81.
- [13] 周若彧. 电力线路中的无人机巡检方案分析 [J]. 电子技术, 2021, 50 (10): 260-261.
- [14] 沈 杰, 张星炜, 陈玉权, 等. 复杂场景下输电线路无人机巡检方法 [J]. 工程勘察, 2021, 49 (10): 73-78.
- [15] 樊邦奎, 李 云, 张瑞雨. 浅析低空物联网与无人机产业应用 [J]. 地理科学进展, 2021, 40 (9): 1441-1450.
- [16] JANELIUKSTIS R. Continuous wavelet transform-based method for enhancing estimation of wind turbine blade natural frequencies and damping for machine learning purposes [J]. Measurement, 2020, 172 (6): 108897.
- [17] LIU M, FU B, XIE S, et al. Comparison of multi-source satellite images for classifying marsh vegetation using DeepLabV3
- [15] 杨晓丽, 段 敏, 虞汉年, 等. 基于 YOLO 算法的车辆实时检测研究 [J]. 仪器仪表与分析监测, 2021 (1): 7-10.
- [16] 于 硕, 李 慧, 桂方俊, 等. 复杂场景下基于 YOLOv5 的口罩佩戴实时检测算法研究 [J]. 计算机测量与控制, 2021, 29 (12): 188-194.
- [17] 徐文静, 高云天, 陈 晨, 等. 基于 YOLOv5 的绝缘子图像自动标注 [J]. 天津: 天津工业大学, 2021 (14): 15-17.
- [18] OLAF R, PHILIPP F, THOMAS B. U-Net: convolutional networks for biomedical image segmentation [EB/OL]. [2019-11-05]. <https://arxiv.org/pdf/1505.04597/pdf>.
- [19] 徐 畅, 陈文轩, 杨远舟. 关于 Yolo 目标检测算法的基础研究 [J]. 电脑信息与技术, 2020, 28 (4): 45-47.
- [20] 朱晓春, 王 欣, 马国立, 等. 改进 YOLOv3 算法的安全帽佩戴检测 [J]. 南京工程学院学报 (自然科学版), 2020, 18 (4): 23-26.
- [21] 李鹏飞, 刘 瑶, 李 珣, 等. YOLO9000 模型的车辆多目标视频检测系统研究 [J]. 计算机测量与控制, 2019, 27 (8): 21-24.
- [22] 张 奇. 基于改进 YOLO 的小目标检测算法应用研究 [D]. 长春: 吉林农业大学, 2020.
- [23] 鞠默然, 罗海波, 王仲博, 等. 改进的 YOLO V3 算法及其在小目标检测中的应用 [J]. 光学学报, 2019, 39 (7): 253-260.
- [24] 张麒麟, 林清平, 肖 蕾. 改进 YOLOv5 的航拍图像识别算法 [J]. 信息通信, 2021, 3: 73-76.
- plus deep learning algorithm [J]. Ecological Indicators, 2021, 125 (11): 107562.
- [18] BOUDOUNIT H, TARFAOUI M, SAIFA OUI D, et al. Parametric study of accidental impacts on an offshore wind turbine composite blade [J]. Journal of Bio- and Tribo-Corrosion, 2021, 7 (1): 1-21.
- [19] 陈 浩, 谭检成, 李明鑫, 等. 基于 ARM+FPGA 的微小陶瓷管缺陷检测系统设计 [J]. 计算机测量与控制, 2018, 26 (3): 39-42.
- [20] 姚明海, 杨 圳. 基于轻量级卷积神经网络的实时缺陷检测方法研究 [J]. 计算机测量与控制, 2019, 27 (6): 22-25, 40.
- [21] 姚明海, 陈志浩. 基于深度主动学习的磁片表面缺陷检测 [J]. 计算机测量与控制, 2018, 26 (9): 29-33.
- [22] 谷 晟, 别锋锋, 郭 越, 等. 基于 LSTM 神经网络的管道缺陷模式识别方法研究 [J]. 计算机测量与控制, 2021, 29 (10): 204-210.
- [23] 杨 利, 陈柳松, 谢永超. 基于机器视觉的芯片引脚缺陷检测系统设计与实现 [J]. 计算机测量与控制, 2021, 29 (7): 16-20.
- [24] 李 超, 张志杰, 韩 宁, 等. 基于 GMR 传感器的金属表面缺陷检测系统设计 [J]. 计算机测量与控制, 2021, 29 (1): 59-65, 70.
- [25] 王新德, 王文强, 钟 峰. 基于图像分析的粘接质量评价系统设计 [J]. 计算机测量与控制, 2021, 29 (1): 240-245, 250.