光电技术及应用

DOI：10.16818/j.issn1001－5868.2023091103

基于深度学习的燃气 PE 管道焊缝缺陷检测

彭惠奎，陈芊一，韩　露，田裕鹏*

（南京航空航天大学 自动化学院，南京 210016）

摘　要： 为了解决人工与传统数字图像处理方法进行燃气 PE 管道焊缝缺陷识别时面临的效率低、漏检率高、评片效果不佳等问题，提出了基于深度学习算法的燃气 PE 管道焊缝缺陷智能检测方法，实现从输入燃气 PE 管道焊缝 DR 检测图像到输出缺陷种类及其测量值的精细化测量。首先，在宏观区域层面采用 YOLOv5 网络预提取缺陷区域，减少与缺陷相似的非目标区域的干扰，并设计了融合坐标注意力机制（CA）与加权双向特征金字塔网络（BiFPN）的 CA-BiFPN 模块，以提高对小目标缺陷检测能力，其最终的缺陷识别定位平均精确度为 95.1%。然后，在微观边界层面采用语义分割算法 Deeplabv3＋，实现像素级别的缺陷分割，缺陷分割平均像素准确率为 91.25%、平均交并比值为 85.52%。最后，在几何特征层面采用最小外接矩形法计算其实际尺寸大小，其平均相对误差为 5.47%。结果表明该检测方法可实现燃气 PE 管缺陷高效率、高精度、智能化检测。

关键词： 燃气 PE 管道焊缝；机器视觉；深度学习；YOLOv5；坐标注意力机制；DeepLabv3＋

中图分类号： TP183　**文章编号：** 1001－5868(2023)06－0942－08

Gas PE Pipeline Weld Defect Detection Based on Deep Learning

PENG Huikui, CHEN Qianyi, HAN Lu, TIAN Yupeng

（Nanjing University of Aeronautics and Astronautics, Nanjing 210016, CHN）

Abstract: In order to solve the problems of low efficiency, high missed detection rate and poor evaluation effect when manual and traditional digital image processing methods are used to identify gas PE pipeline weld defects, an intelligent detection method for gas PE pipeline weld defects based on deep learning algorithms is proposed. The fine measurement from inputting gas PE pipeline weld DR Detection image to outputting defect types and their measured values were realized. Firstly, YOLOv5 network was used to pre-extract the defect region at the macro region level to reduce the interference of non-target regions similar to the defect. And a CA-BIFPN module integrating coordinate attention mechanism (CA) and weighted bidirectional Feature Pyramid network (BiFPN) was designed to improve the detection ability of small target defects. The final average accuracy of defect identification and location was 92.5%. Then, at the micro boundary level, Deeplabv3＋, a deep semantic segmentation network, was used to achieve pixel-level defect segmentation. The average pixel accuracy of defect segmentation was 91.25%, and the average intersection-union ratio was 85.52%. Finally, the minimum enclosing rectangle method was used to calculate the actual size at the geometric feature level, and the average relative error was 5.48%. The results show that the method can achieve high efficiency, high precision and intelligent detection of gas PE pipe defects.

Key words: gas PE pipeline weld; Machinevision; deep learning; YOLOv5; CA

收稿日期：2023－09－11.

基金项目：江苏省工业和信息产业转型升级专项.

* **通信作者：**田裕鹏　**E-mail:** 332383032@qq.com

mechanism；DeepLabv3＋

0　引言

聚乙烯(Polyethylene,PE)管道具有耐腐蚀性、柔韧性、环保性、抗冲击性好、施工简单等优点，在城市中低压燃气管网建设中已逐渐取代钢制管道。焊缝作为燃气管道重要的特征之一，其质量直接影响管道的安全。焊缝引起事故的原因主要有：焊缝射线片不合格，隐藏有缺陷；焊缝射线底片与焊口对应不上等。数字 X 射线摄影(Digital Radiography，DR)是一种射线数字检测技术，是燃气管道常用的检测手段。同时焊缝检测底片是判断焊缝质量好坏的重要依据，但焊缝数据涉及量大、信息多以及识别难度大。目前针对 DR 检测缺陷底片的评判，主要是通过人工评片，但通过基于传统数字图像处理和基于机器学习的评片方法也逐渐兴起。在传统图像处理方法中，Chen 等[1]采用稀疏重建的思路重构检测图像，再计算测试图像与重建图像的差值得到缺陷。肖辉[2]在焊缝缺陷分割过程中使用一种生成算法，首先在含有焊接缺陷的图像中采用平滑模板去除图像中的缺陷，利用处理前后的图像相减获得被模板去除的缺陷，从而获得分离出来的焊缝缺陷。Zhang 等[3]利用大津法结合描述局部像素不均匀的值对焊缝进行分割，并通过区域生长的算法进行缺陷的识别。而在传统机器学习算法中，Malarvel 等[4]利用调整梯度信息实现对焊缝射线图像的缺陷检测。

近年来深度学习算法迅速兴起，研究者们开始采用深度学习方法进行焊缝缺陷的检测。相较于传统数字图像处理，深度学习并不依靠人为设计规则，避免了复杂的图像处理过程的同时，通过设计多层神经网络结构来自主学习图像数据内部蕴含的信息，并采用合适的优化算法以及损失函数加速学习过程，可大幅度提高对焊缝识别的准确性。郭瑞鸿等[5]利用改进的 SSD 算法实现 X 光图像管制刀具检测与识别，刘涵等[6]采用 CNN 与 Softmax 分类器相结合的算法，以缺陷和噪声为输入样本训练 CNN，实现了石油钢管焊缝缺陷检测与识别。蔡彪等[7]采用 MaskR-CNN 算法对的铸件 X 射线 DR 图像缺陷进行分类分级。

基于深度学习的焊缝缺陷智能评片包括检测算法和分割算法[8]。焊缝缺陷检测算法通常采用目标检测算法来进行检测，获取图像中焊缝缺陷的位置及类别信息。基于深度学习的目标检测算法主要分为双阶段检测算法和单阶段检测算法。双阶段检测算法采用先生成候选框，再基于候选框做二次修正的方式得到检测结果，如 MaskR-CNN 算法。单阶段检测算法[9]是以 YOLO 系列为代表，其主要思想为：将图像分为 $N\times N$ 大小的子区域后，直接预测每个子区域中存在目标的概率、类别等信息。目前研究显示，单阶段检测算法既能在检测精度与双阶段检测算法差异不大，有的甚至优于双阶段检测算法，且在检测速度上有着明显优势，同时 YOLOv5 算法是目前最新的 YOLO 系列算法，因此本文选择 YOLOv5 算法[10]进行 PE 管道焊缝缺陷的识别与定位，并针对小目标缺陷检测效果不佳的问题，对原算法进行改进优化。

后者采用基于深度学习的图像语义分割算法实现。基于深度学习的图像语义分割算法[11]按照应用场景不同，分为高分割精度的经典语义分割方法、高效率的实时性语义分割方法和复杂场景 RGBD 语义分割方法三类。由于本文分割对象的背景比较单一且对时效性要求不高，故选择分割精度较高的经典语义分割方法，其主要包括 FCN，U-Net，SegNet，DeepLab 系列。DeepLabv3＋算法[12-13]作为谷歌公司推出的最新的 DeepLab 系列算法，通过增加对物体边界信息的关注，从而改进了分割效果，并借鉴了 FPN 等网络的 encoder-decoder 架构，实现了 Feature Map 跨 block 的融合。在此类算法中表现最佳，故采用 DeepLabv3＋网络模型作为本文的语义分割模型。

基于上述提出的缺陷检测算法，最后采用最小外接矩形算法实现精细化测量，从而实现一体化的燃气 PE 管道焊缝缺陷智能识别与测量。

1　基于深度学习的缺陷检测方法

1.1　燃气 PE 管道焊缝缺陷智能检测算法框架

燃气 PE 管道焊缝缺陷智能检测算法[14-15]主要包括缺陷识别定位、缺陷分割、缺陷测量三部分，如图 1 所示。首先通过 YOLOv5 裂缝识别定位模型检测测试图像是否包含裂缝，然后针对包含缺陷的图像，通过 Deeplabv3＋裂缝分割模型提取裂缝像素，输出缺陷分割图像，再运用最小外接矩形法，获

取缺陷尺寸信息。

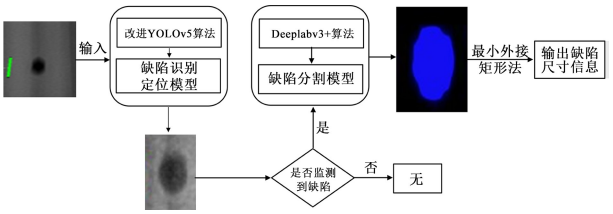


图 1 燃气 PE 管道焊缝缺陷智能检测算法框架

1.2 YOLOv5 缺陷识别定位算法及其改进

YOLOv5 模型网络结构主要由输入端、骨干网络(Backbone)、颈部(Neck)和输出端组成[16]。第一部分为输入端,该模块采用了和 YOLOv4 相似的 Mosaic 数据增强形式,实现了数据多样化,并间接地改善了对小目标检测效果,算法的鲁棒性也得到了增强。第二部分为主干网络,输入图像经过 Focus 结构进行切片操作,实现了对输入端图像长宽两个维度的特征信息融合,再进行图像下采样,减少图像特征信息损失。然后通过 CSPDarknet 模块在特征图上进行特征提取,获取其中的有效信息。相较于其他深层次神经网络结构,CSPDarknet 结构能有效防止神经网络优化过程中的梯度数据过度重复。最后采用 SPP 模块增加网络的接受域,获得不同尺度的特征。第三部分为颈部网络,该部分结合了 FPN 结构与 PAN 结构,前者从上到下传递了强大的语义特征,后者从下往上传递了强大的定位特征,两种结果的结合实现了不同尺度特征信息的聚合,有效地提高了算法对不同大小目标的检测精度。最后一部分为输出端,YOLOv5 延续了前一版本的多尺度检测结构,利用不同尺度的特征图,分别在不同特征层上实现对不同大小目标的类别和位置预测,再利用非极大值抑制方法筛选出置信度过小的预测锚框,并将其去除从而输出最优的预测锚框。整体算法结构如图 2 所示。

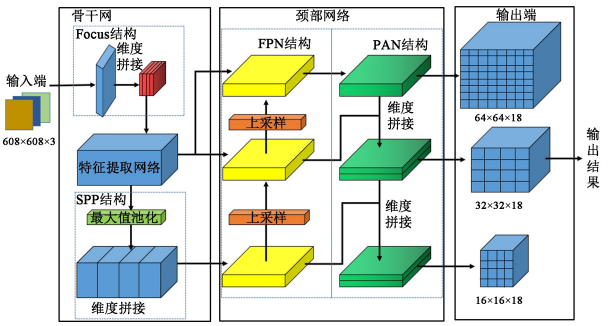


图 2 YOLOv5 模型

YOLOv5 是一种检测精确、速度快的检测算法,在开源数据集上有良好的效果,但是在 PE 管焊缝缺陷分类识别任务上检测性能仍需要改进。针对其边界特征不明显、目标较小以及背景复杂等问题,本文在 YOLOv5 的基础上进行改进优化,提出了一种针对燃气 PE 管道焊缝缺陷 DR 检测图像的改进 YOLOv5 算法。坐标注意力机制(Coordinate Attention,CA)[17]是一种新颖且高效的混合域注意力机制,通过将位置信息嵌入到通道注意力之间的操作,使网络能在避免大量计算开销的前提下,识别较大的区域。另外通过将通道注意力机制分解成两个沿着不同方向聚合的 1D 特征编码,实现在沿着一个空间方向捕获长程依赖的同时,又能沿着另一个空间方向准确计算位置信息。再将产生的特征图分别进行编码,生成一系列方向和位置互相感知的特征图,并以互补的形式运用到输入特征图上,有效提高了对小目标缺陷的注意,如图 3 所示。

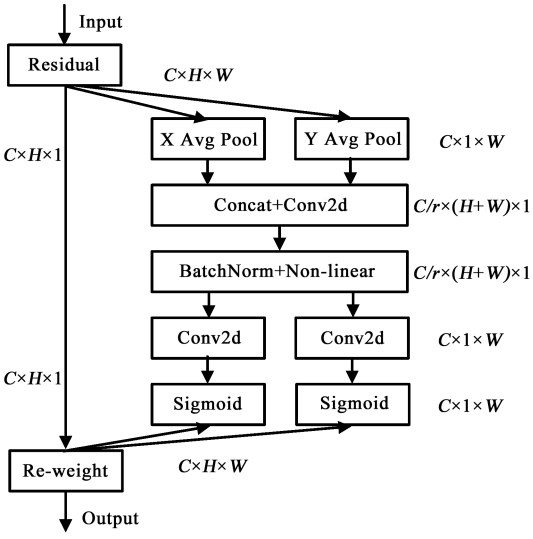


图 3 坐标注意力机制(CA)

FPN 在提出后迅速发展出了多种不同的版本,如 PANET,NAS-FPN,BiFPN 等,都是为了将来自不同网络层的特征输出进行融合,增强不同尺寸特征图的特征信息。BiFPN 是加权双向特征金字塔[18],如图 4 所示,在前向传播之外重新构造自顶向下、自底向上的双向通道,进行不同尺度的特征信息融合,再通过上采样与下采样统一特征分辨率尺度,并在同一特征的原始输入和输出节点之间添加横向连接,以融合更多特征信息。

因此,本文在主干特征提取网络 CSPDarkNet-53 的卷积层之间添加了注意力机制 CA 模块,并将

原算法中的 FPN＋PAN 结构替换成 BiFPN 结构，构建 CA-BiFPN 模块以改善各缺陷的检测精度及对小目标缺陷的检测能力。

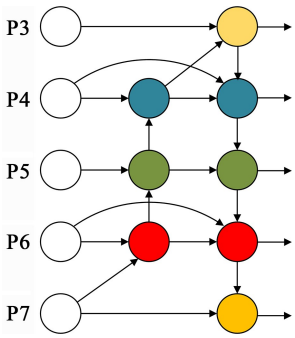


图 4　BiFPN 结构

1.3　基于 DeepLabv3＋的缺陷分割算法

DeepLabv3＋算法的网络结构[19]如图 5 所示，由空间金字塔池化(ASPP)模块和编码器-解码器结构两部分相结合组成。编码器模块首先通过 Resnet50 网络对输入的图像进行特征提取，再运用 ASPP 模块融合连接许多不同采样率的空洞卷积，实现对上下文信息的多层次、多尺度的获取。之后通过一个卷积核降低通道数，获取了目标的高层次语义特征图，再将其输入到解码器中，此时的特征图尺寸缩小了 16 倍。解码器模块在 ResNet50 网络的 Conv 2 结构中获得低层次语义特征图，并采用 1×1 的卷积操作尽可能地让通道数变得更少。通过对多尺度高层特征图进行上采样操作，将其尺寸变为输入解码器特征图的 4 倍，然后融合高低层次的特征图，进行一个 3×3 的卷积变化，此时图像的尺寸为输入图像的四分之一。最后再次进行 4 倍双线性插值进行上采样处理合并特征图，使图像恢复原尺寸并完成分割。

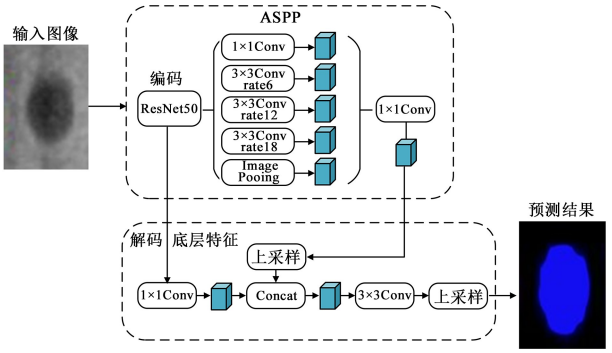


图 5　DeepLabv3＋算法的网络结构图

1.4　基于最小外接矩形法测量缺陷长度

图像目标的外接矩形[20]是指完全包含了图像上所有的点、线，且各边均与图形相切的矩形。目标的外接矩形有多个，而面积最小的矩形被称为最小外接矩形，如图 6 所示。采用上述方法在语义分割后的图像上进行缺陷大小的定量分析。

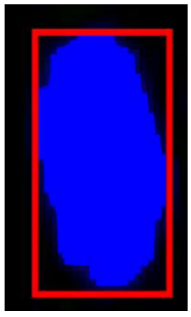


图 6　缺陷大小测量

由其长边的像素长度 l，加上通过双丝像质计(如图 7)得知的每像素对应的物理尺寸 j，计算缺陷的实际大小，计算公式如下式：

$$D = l \times j \tag{1}$$

式中，D 为缺陷实际大小，j 为每像素代表的实际物理尺寸。

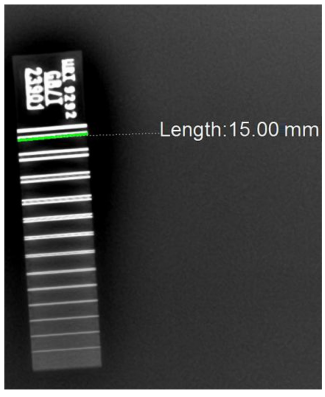


图 7　双丝像质计

2　缺陷检测模型训练

2.1　YOLOv5 缺陷识别定位模型数据集的制作与训练

本文采用的试验平台：处理器为 Intel(R)Core(TM)i9-10900X CPU@3.70 GHz，显卡为 NVIDIA GeForce RTX 2060，使用的深度学习框架为 Pytorch1.8.1，Python 版本为 3.7，GPU 加速软件 CUDA10.0 和 CUDNN7.6。

本文采用自制 PE 管焊缝缺陷 DR 检测图像，所有 PE 管焊缝缺陷皆由燃气管道的检测工程师与无锡华润公司专业人员结合行业内常见焊缝缺陷[21]，参照 TSG D2002-2006《燃气用聚乙烯管道焊

接技术规则》与 CJJ63-2018《聚乙烯燃气管道工程技术标准》制作孔洞；圆状夹杂（长宽比小于等于3）；条状夹杂（长宽比大于3）；裂纹4种缺陷及无缺陷试件。总计305张4种不同类型的PE管焊缝DR检测图像如图8。同时针对数据样本量不足的情况，利用图像亮度与对比度调整及翻转等数据增强手段对数据集进行扩充，最终数据集数量达到1 000张，并以4∶1的比例将数据集分为训练集和测试集。同时利用LabelImg图像标注软件进行训练集的标注。

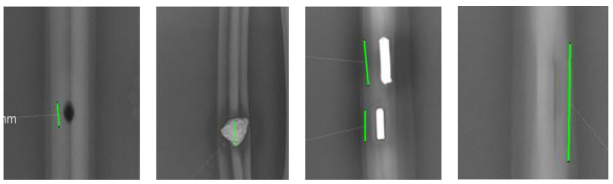


图8 4种PE管道焊缝缺陷DR检测图

缺陷识别定位模型在上述环境进行训练，并采用迁移学习方法，将在COCO数据集预训练完成的YOLOv5模型作为初始模型，优化模型训练速度，并设置训练批量大小为64，训练动量为0.9，初始学习率为0.001，权重衰减为0.000 5，最大训练轮数为1 000次，模型整体训练时间为10 h，最后采用网络输出的最佳训练权重来构建缺陷识别定位模型。

2.2 Deeplabv3+缺陷分割模型数据集的制作

Deeplabv3+缺陷分割模型数据集是由上一部分改进YOLOv5定位识别模型输出组成，数据集大小为1 000张，同时也按4∶1的比例划分测试集与训练集，测试集上采用专门的标注工具Labelme进行语义分割标签的制作过程如图9。缺陷分割模型也在上述环境下进行训练，训练参数设置：训练批量大小为4张，学习率为1×10^{-4}，最大训练轮数为400次。模型训练时间为4 h，采用网络输出的损失最低时的权重来构建缺陷分割模型。

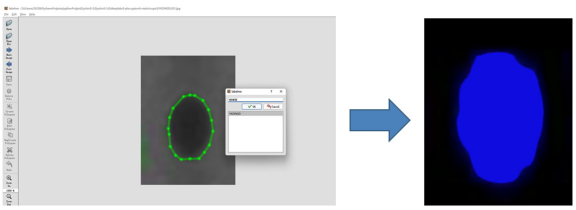


图9 Labelme标注过程

3 缺陷检测模型测试与评估

3.1 算法评价体系

为了验证改进YOLOv5算法[17]的性能，常使用精确度（precision，P）、召回率（recall，R）、平均精度均值（mean average precision，mAP）这三个指标来评价检测算法的性能。其中，精确率即正检率如下式：

$$P=\frac{TP}{TP+FP} \tag{2}$$

召回率是指在所有正样本中被正确预测的比例，如下式：

$$R=\frac{TP}{TP+FN} \tag{3}$$

漏检率即为R，其中TP代表真阳性，为预测框与真实框的$IoU>0.5$的个数。FN代表假阴性，是指被遗漏的真实框的个数。FP代表假阳性，是指预测为正类，实际为负类的个数。

平均精确度（AP）表示为P-R曲线的积分值，其值越高表示检测效果越佳。平均精确度AP定义见下式：

$$AP=\int_0^1 P(R) \tag{4}$$

式中，$P(R)$表示精确率P与召回率R所表示的曲线。平均精确度均值mAP：表示算法对数据集中所有类别的AP值的均值，它是用来评价算法对所有类别目标的检测性能。

在语义分割任务中常用的评价指标有像素准确率（Pixel Accuracy，PA），表示分割算法准确预测出的像素数与整张图像的总像素之比，如下式：

$$PA=\frac{TP+PN}{TP+TN+FP+FN} \tag{5}$$

mPA则表示分别计算每个类的PA后求它们的平均值。

IoU表示为模型对某一类别预测结果和真实值的交集与并集的比值，如下式：

$$IoU=\frac{TP}{TP+FP+FN} \tag{6}$$

MIoU则表示模型对每一类预测的结果和真实值的交集与并集的比值求和再平均的结果，反映整个网络分割位置的准确性及分割区域的完整性。

3.2 结果分析及针对小目标缺陷检测效果差的改进策略

采用原YOLOv5算法的检测结果如表1所示。

对于输入图像，焊缝缺陷只占据图像的较小部分，其余均为背景信息，在卷积时，背景的迭代累积会形成大量冗余信息，从而淹没部分目标，导致检测准确率不高。其次针对小目标缺陷如图所示的孔

洞，原本 YOLOv5 算法并不能检测出来，如图 10。

表 1　YOLOv5 算法检测结果

缺陷类型	正检率/%	漏检率/%	mAP/%
圆状夹杂	92.3	7.3	94.6
条状夹杂	83	10.3	88.3
圆状孔洞	97	5.3	95.8
条状裂纹	91.6	12	87
整体	91	8.7	91.4

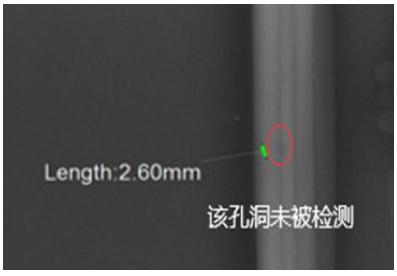


图 10　未检测的孔洞(像素大小为 5×7)

因此，将原 YOLOv5 算法中 neck 部的 FPN＋PAN 特征融合模块替换成 CA-BiFPN 模块并引入 CA 坐标注意力机制，改进 YOLOv5 算法的检测结果如表 2。

表 2　改进 YOLOv5 检测结果

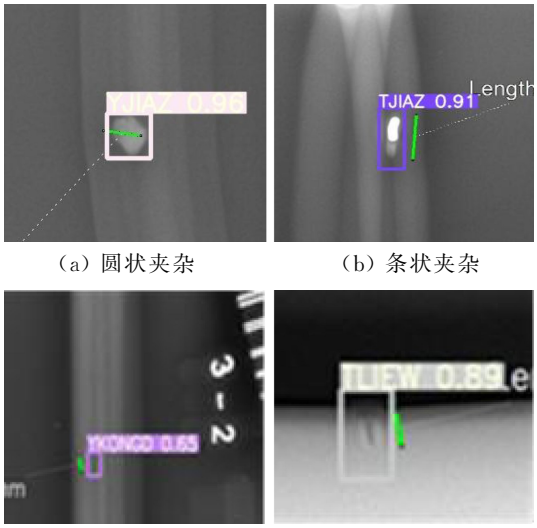
缺陷类型	正检率/%	漏检率/%	mAP/%
圆状夹杂	95.3	4.5	95.6
条状夹杂	91.7	2.8	94.8
孔洞	98.1	3.6	97.3
裂纹	93.4	9.8	92.6
整体	94.6	4.9	95.1

正如上表所示，改进 YOLOv5 较原来的 YOLOv5 算法，从正检率来看圆状夹杂提升 3%，条状夹杂提升 8.7%，孔洞提升 1.1%，裂纹提升 1.8%，整体提升 3.6%。同时各类别的漏检率也随之下降，分别降低 2.8%，7.5%，1.7%，2.2%，整体下降 3.8%。最后从平均精确度均值上来看，各类别分别提升 1%，6.5%，1.5%，5.6%，整体提升 3.7%，其中条状裂纹的改善最明显，原因为裂纹多为细小目标，原算法对其检测置信度不高，多为 70%上下，而改进 YOLOv5 算法对其检测置信度多为 80%以上。同时，采用引文[5-7]所提算法与本文算法进行对比实验，缺陷整体的检测结果如表 3 所示。

表 3　改进 YOLOv5 算法与其他算法比较

算法	正检率/%	漏检率/%	mAP/%
改进 SSD	81.2	22.1	80.3
CNN	88.9	12.3	87.6
Mask R-CNN	90.9	13.2	88.7
YOLOv5	91	8.7	91.4
改进 YOLOv5	94.6	4.9	95.1

为了展示改进 YOLOv5 算法对燃气 PE 管道的检测效果，从测试集中随机的选取不同种类的 PE 管焊缝缺陷 DR 检测图片进行测试，测试结果如表 3 所示。可从图 10 与图 11 中的孔洞对应来看，之前未被检测的小孔洞缺陷被成功检测，检测置信度达到 65%(超过阈值 50%可认为检测为孔洞正类)。



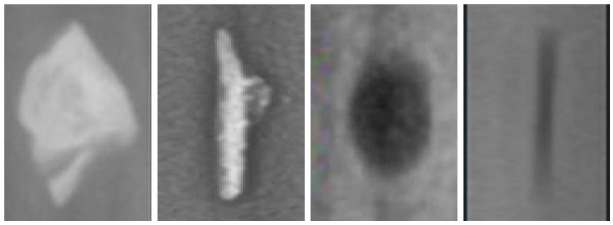
(a) 圆状夹杂　(b) 条状夹杂

(c) 孔洞　(d) 裂纹

图 11　各缺陷检测图

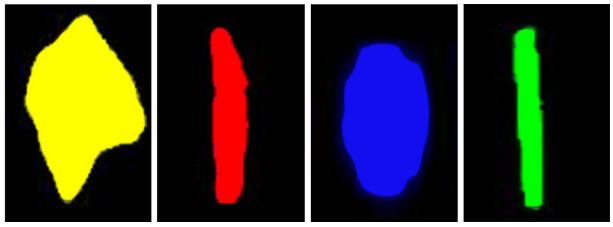
3.3　Deeplabv3＋语义分割及测量结果分析

将被改进 YOLOv5 网络模型成功识别的缺陷图像输入 DeepLabv3＋裂缝分割模型进行分割，各类缺陷分割前如图 12 所示，分割后如图 13 所示。



(a) 圆状夹杂 (b) 条状夹杂　(c) 孔洞　(d) 裂纹

图 12　语义分割前缺陷图



(a) 圆状夹杂 (b) 条状夹杂　(c) 孔洞　(d) 裂纹

图 13　语义分割后缺陷图

再依据双丝像质计得到的每像素代表的实际物理尺寸 j，以及最小外接矩形法得到的长边长度 l，最终得到缺陷的实际大小。经统计，DeepLabv3＋缺陷分割结果及测量误差见表 4。

表 4 DeepLabv3＋缺陷分割结果及测量误差

缺陷种类	mIoU/%	mPA/%	测量的平均相对误差/%
条形夹杂	89.39	95.28	2.3
裂纹	72.71	87.37	8.2
孔洞	84.69	89.29	7.26
圆形夹杂	87.11	95.81	4.1
ALL	85.52	91.25	5.47

从最终的分割结果与测量来看，除裂纹在 mIoU 这一评价指标上表现不佳外，其余缺陷分割及测量误差均较好。导致其原因有二：(1)裂纹在视觉表现上为浅、细小等特征，(2)在人工作标签时也易造成不可避免的标注不准。

综合缺陷识别定位阶段的平均精确度均值为 95.1%，以及最终的缺陷测量的平均相对误差为 5.47%，本文所提出的方法能较好地完成燃气 PE 管道焊缝缺陷的识别定位及测量。

4 结束语

本文基于改进 YOLOv5 与 Deeplabv3＋深度学习相关理论，并结合最小外接矩形方法，完成燃气 PE 管道 DR 图像缺陷智能识别与测量。首先利用 YOLOv5 深度学习网络进行缺陷识别与定位，并针对小目标缺陷检测精度不高的问题，在其原网络基础上设计了融合坐标注意力机制(CA)与加权双向特征金字塔网络(BiFPN)的 CA-BiFPN 模块，有效地降低了小目标缺陷检测的误检和漏检。再采用 Deeplabv3＋语义分割算法进行缺陷像素级的分割，最后采用最小外接矩形法实现各类缺陷精确测量。实验数据表明，本文算法可以对燃气 PE 管道 DR 检测图像中的孔洞、圆状夹杂、条状夹杂、裂纹等 4 种缺陷类别进行有效的识别与定位，并能精确地对缺陷进行定量分析，完成其大小的测量，不仅有效提高了缺陷的检测效率，且同时具有较高的精度。为燃气管道焊缝缺陷智能化识别与测量提供了一种切实可行的新方案。

参考文献：

[1] Chen B Z, Fang Z H, Xia Y, et al. Accurate defect detection via sparsity reconstruction for weld radiographs[J]. NDT & E International, 2018, 94: 62-69.

[2] 肖 辉. 焊接缺陷射线 DR 图像自动检测与识别统研究[D]. 南昌：南昌航空大学，2017：15-19.
Xiao Hui. Research on automatic detection and identification system of X-ray DR images of welding defects[D]. Nanchang: Nanchang Hangkong University, 2017: 15-19.

[3] Zhang L, Zhang Y J, Dai B C, et al. Welding defect detection based on local image enhancement[J]. IET Image Processing, 2019, 13(13): 2647-2658.

[4] Malarvel M, Sethumadhavan G, Bhagi PCR, et al. An improved version of Otsu's method for segmentation of weld defects on X-radiography images[J]. Optik, 2017, 142: 109-118.

[5] 郭瑞鸿，张 莉，杨 莹，等. 基于改进 SSD 的 X 光图像管制刀具检测与识别[J]. 激光与光电子学进展，2021，58(4)：65-72.
Guo Ruihong, Zhang Li, Yang Ying, et al. X-ray image control tool detection and recognition based on improved SSD [J]. Advances in Laser and OptoElectronics, 2019, 58(4): 65-72.

[6] 刘 涵，郭润元. 基于 X 射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J]. 仪器仪表学报，2018，39(4)：247-256.
Liu Han, Guo Runyuan. Detection and identification of weld defects in petroleum steel pipes based on X-ray images and convolutional neural networks [J]. Chinese J. of Scientific Instrument, 2018, 39(4): 247-256.

[7] 蔡 彪，沈 宽，付金磊，等. 基于 Mask R-CNN 的铸件 X 射线 DR 图像缺陷检测研究[J]. 仪器仪表学报，2020，41(3)：61-69.
Cai Biao, Shen Kuan, Fu Jinlei, et al. Research on defect detection of casting X-ray DR image based on Mask R-CNN[J]. Chinese J. of Scientific Instrument, 2019, 41(3): 61-69.

[8] 曹家乐，李亚利，孙汉卿，等. 基于深度学习的视觉目标检测技术综述[J]. 中国图象图形学报，2022，27(6)：1697-1722.
Cao Jiale, Li Yali, Sun Hanqing, et al. Review of visual object detection technology based on deep learning[J]. J. of Image and Graphics, 2022, 27(6): 1697-1722.

[9] Du Y C, Pan N, Xu Z H, et al. Pavement distress detection and classification based on Yolo network[J]. Inter. J. of Pavement Engineering, 2021, 22(13): 1659-1672.

[10] Zhang C B, Chang C C, Jamshidi M. Concrete bridge surface damage detection using a single-stage detector[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(4): 389-409.

[11] 张 鑫，姚庆安，赵 健，等. 全卷积神经网络图像语义分割方法综述[J]. 计算机工程与应用，2022，58(8)：45-57.
Zhang Xin, Yao Qingan, Zhao Jian, et al. A review of image semantic segmentation methods by full convolutional neural networks[J]. Computer Engineering and Applications, 2022, 58(8): 45-57.

[12] Dung C V, Anh L D. Autonomous concrete crack detection using deep fully convolutional neural network [J]. Automation in Construction, 2019, 99: 52-58.

[13] Ji Ankang, Xue Xiaolong, Wang Yuna, et al. An integrated approach to automatic pixel-level crack detection and quantification of asphalt pavement [J]. Automation in Construction, 2020, 114: 103176.

[14] 余加勇，刘宝麟，尹　东，等. 基于 YOLOv5 和 U-Net3＋的桥梁裂缝智能识别与测量[J]. 湖南大学学报(自然科学版)，2023，50(5)：65-73.
Yu Jiayong, Liu Baolin, Yin Dong, et al. Intelligent identification and measurement of bridge cracks based on YOLOv5 and U-Net3＋[J]. J. of Hunan University (Natural Sciences), 2023, 50(5): 65-73.

[15] 胡文博，王卫东，汪雯娟，等. 基于宏微观耦合深度学习的高速铁路无砟轨道板表面裂缝精细化测量[J]. 中南大学学报(自然科学版)，2022，53(5)：1965-1975.
Hu Wenbo, Wang Weidong, Wang Wenjuan, et al. Fine measurement of surface crack of ballastless track plate of high-speed railway based on macro and micro coupled deep learning [J]. J. Central South University (Natural Science Edition), 2022, 53(5): 1965-1975.

[16] 郎　松，曹　选，张艳微，等. 融合改进 YOLOv5 算法的图像全站仪全自动测量方法[J]. 仪器仪表学报，2022，43(5)：120-127.
Lang Song, Cao Xuan, Zhang Yanwei, et al. Automatic measurement method of image total station based on improved YOLOv5 algorithm [J]. Chinese J. Scientific Instrument, 2022, 43(5): 120-127.

[17] 李海军，孔繁程，林　云. 基于改进的 YOLOv5s 红外舰船检测算法[J]. 系统工程与电子技术，2023，45(8)：2415-2422.
Li Haijun, Kong Fancheng, Lin Yun. Based on improved YOLOv5s infrared ship detection algorithm [J]. System Engineering and Electronics, 2023, 45(8): 2415-2422.

[18] 鲁　博. 融合 BiFPN 和改进 Yolov3-tiny 网络的航拍图像车辆检测算法研究[D]. 长沙：湖南师范大学，2021.
Lu Bo. Research on aerial image vehicle detection algorithm based on BiFPN and improved Yolov3-tiny network [D]. Changsha: Hunan Normal University, 2021.

[19] 张荣军，谭　海，马天浩，等. 基于 DeepLabV3＋的遥感影像道路中心线提取[J]. 遥感信息，2022，37(1)：94-100.
Zhang Rongjun, Tan Hai, Ma Tianhao, et al. Road centerline extraction from remote sensing image based on DeepLabV3＋[J]. Remote Sensing Information, 2022, 37(1): 94-100.

[20] 黄　超，茅　健，徐　斌，等. 基于最小外接矩形和 Hough 变换的定位算法[J]. 组合机床与自动化加工技术，2021(8)：66-71.
Huang Chao, Mao Jian, Xu Bin, et al. Positioning algorithm based on minimum external rectangle and Hough transform[J]. Combined Machine Tool & Automatic Processing Technology, 2021(8): 66-71.

[21] 付晓霞，吕兴祥. PE 燃气管道焊缝缺陷无损检测技术分析[J]. 煤气与热力，2022，42(6)：44-50.
Fu Xiaoxia, Lv Xingxiang. Technology analysis of non-destructive testing of weld defects in PE gas pipeline[J]. Gas & Heat, 2022, 42(6): 44-50.

[22] 赵雪冰，王俊杰. 基于改进 DeeplabV3＋和迁移学习的桥梁裂缝检测[J]. 计算机工程与应用，2023，59(5)：262-269.
Zhao Xuebing, Wang Junjie. Bridge crack detection based on improved DeeplabV3＋ and transfer learning [J]. Computer Engineering and Applications, 2023, 59(5): 262-269.

作者简介：

彭惠奎(1997－)，男，硕士在读，主要研究方向为健康监测数据分析；

田裕鹏(1967－)，男，博士，教授，硕士生导师，主要研究方向为传感器与无损检测以及图像处理与视觉测量等。