

基于改进型 YOLOv4 的焊缝图像检测与识别

程松, 戴金涛, 杨洪刚, 陈云霞*

上海电机学院机械学院, 上海 201306

摘要 针对 YOLOv4 在焊缝 X 射线探伤缺陷图中检测精度与召回率低的问题, 设计了 YOLOv4-cs 算法。该算法改进了 YOLOv4 的卷积方式, 使得模型训练参数大大减小, 其次通过去除下采样及在 52×52 的特征层中融合第 2 个残差块得到的特征图的方式提高模型检测精确率, 与此同时利用 K-means 对数据集重新聚类, 修改 YOLOv4 模型的先验框。实验结果表明, YOLOv4-cs 在识别铝合金焊接接头 X 射线 3 种缺陷的召回率提高显著, 其平均精准度均值 (mAP) 为 88.52%, 较原 YOLOv4 模型提升了 2.67 个百分点, 检测速度由 20.43 frame/s 提升到了 24.47 frame/s。

关键词 图像处理; 深度学习; 焊缝内部缺陷检测; 目标检测; YOLOv4

中图分类号

文献标志码

DOI: 10.3788/LOP202259.1610002

Weld Image Detection and Recognition Based on Improved YOLOv4

Cheng Song, Dai Jintao, Yang Honggang, Chen Yunxia*

School of Mechanical Engineering, Shanghai Dianji University, Shanghai 201306

Abstract To address the problem of low detection accuracy and recall rate in YOLOv4 of weld X-ray flaw detection defect maps, the YOLOv4-cs algorithm is designed. The algorithm improves the convolution mode of YOLOv4 and greatly reduces the model training parameters; further, it improves the accuracy of model detection by removing the down-sampling layer and fusing the feature map obtained by the second residual block in the 52×52 feature layer. Simultaneously, K-means is used to recluster the dataset and modify the priori frame of YOLOv4 model. The experimental results show that the recall rate of YOLOv4-cs in identifying three kinds of X-ray defects within aluminum alloy welded joints significantly improved, its mean average precision (mAP) was 88.52%, which was 2.67 percentage points higher than the original YOLOv4 model, and the detection speed increased from 20.43 frame/s to 24.47 frame/s.

Key words image processing; deep learning; internal defect detection of weld; object detection; YOLOv4

1 序 言

铝合金材料具有强度高、耐腐蚀性好等优点, 其焊接件在汽车、高铁和航空航天领域得到了广泛应用^[1]。由于焊接过程中工艺参数的影响, 铝合金焊接件容易产生咬边、气孔、裂纹、夹渣及未焊透等焊接缺陷^[2]。首先铝极易氧化产生三氧化二铝薄膜, 焊缝内部极易出现夹渣。其次在焊接过程中, 液态铝可溶解大量的氢, 所以当熔池温度快速冷却与凝固后, 不及时逸出的氢容易形成气孔。最后焊接的速度过快, 电弧过长也很容易导致未焊透。因此本实验组重点对这 3 种焊缝内部常见类型缺陷进行检测与识别。工业生产中常采用射线技术对焊缝内部缺陷进行检测识别, 但人工检

查结果受检测人员的水平限制易出现漏检与错检、检测工作量大且检测效率低等问题^[3]。且随着计算机和数字图像处理技术的快速发展, 亟待开发一种对焊缝 X 射线探伤缺陷的自动检测与识别的有效方法。

深度学习凭借从图像和声音中执行分类任务, 解决数据存在的高维度等优势, 在焊缝缺陷检测识别有广泛的应用。主流的目标检测模型有 Faster-RCNN^[4]、YOLOv2^[5]、YOLOv3^[6-7]、YOLOv4^[8-9]等, 其中 YOLOv4 由于检测速度快且检测精确率高而被广泛应用。但上述模型对于小目标缺陷的检测精度和召回率低, 因此很多学者进行了相关研究与改进。黄海新等^[10]基于 YOLOv4 网络进行了相应的改进, 提高了焊缝边缘缺陷检测的各个指标; 王家晨等^[11]提出了一

收稿日期: 2021-05-06; 修回日期: 2021-05-18; 录用日期: 2021-07-05

基金项目: 国家自然科学基金(51809161)、上海市自然科学基金(18ZR1416000)

通信作者: *chenyx@sdju.edu.cn

种基于 ButterWorth 滤波的钢管焊缝缺陷检测方法,该方法有效降低了焊缝缺陷的漏检率和误检率;王欣等^[12]对采集图像的像素矩阵进行了主元分析,并结合模糊识别中的模糊 C 均值聚类算法对圆形缺陷和线形缺陷进行识别。X 射线焊缝内部缺陷图片的分辨率低于其他图像,虽然图片背景信息并不复杂,但就气孔与未焊透缺陷而言,两者与焊缝区域的灰度值较为接近,边缘信息很难提取,导致使用原始的 YOLOv4 网络进行缺陷检测的效果不佳。因此,受到文献[13-15]的启发,本文对 YOLOv4 网络进行改进,改善模型对气孔、夹渣与未焊透 3 种缺陷的特征提取能力,提高其对 3 种缺陷的检测效果及相应评判指标。

2 YOLOv4 算法

2.1 算法原理

YOLOv4 在 YOLOv3 的主干特征提取网络、数据增强、特征金字塔、激活函数等方面进行了改进与优化,模型的检测速度与平均精准度均值(mAP)显著提高。YOLOv4 主要通过主干提取特征网络 CSPDarknet53 与加强特征提取网络 PANet 对输入图像进行特征提取,将提取后的特征层输入 YOLO Head 层进行解码并输出最终的预测结果。

CSPDarknet53 首先通过 Darknet 卷积对特征进行初步提取,其次通过一系列的残差块堆叠结构防止梯度弥漫或梯度爆炸,最后对主干特征提取网络输出的结果进行最大池化并输入 PANet 网络进行特征提取与特征融合。加强特征提取网络的核心是通过上采样和下采样方法对上下文的特征进行融合,实现特征金字塔,得到更高的语义信息,从而提高目标检测的精确率。

2.2 激活函数

YOLOv4 的主干特征提取网络 CSPDarknet53 使用的是 Mish 激活函数,其表达式为

$$\text{Mish}(x) = x \times \tanh\left\{\ln\left[1 + \exp(x)\right]\right\}. \quad (1)$$

图 1 为 Mish 激活函数图。从图 1 可以看出,激活




图 1 Mish 激活函数

Fig. 1 Mish activation function

函数呈递增趋势且在 x 轴负半轴有较小梯度流入,可以有效避免模型出现饱和问题,保证信息的连续,模型具有更好的泛化能力。

2.3 损失函数

YOLOv3 的损失函数由三部分共同决定, YOLOv4 的损失函数考虑了检测目标与 anchor 间的距离、重叠率及惩罚项,则 YOLOv4 损失函数的表达式为

$$L_{\text{CIoU}} = 1 - R_{\text{IoU}} + \frac{\rho^2(A, B)}{c^2} + av, \quad (2)$$

$$a = \frac{v}{1 - R_{\text{IoU}} + v}, \quad (3)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2, \quad (4)$$

式中: R_{IoU} 是通过框的左上角 (x_1, y_1) 和右下角 (x_2, y_2) 坐标计算的; $\rho^2(A, B)$ 是真实框和预测框的中心点的欧氏距离; c 为闭包的对角线距离; a 和 v 分别代表了权衡参数与衡量长宽比一致性参数; $w^{\text{gt}}, h^{\text{gt}}$ 为真实框的宽高; w, h 为预测框的宽高。

3 YOLOv4 算法的改进

3.1 K-means 聚类

YOLOv4 的先验框是在 VOC 数据集上聚类得出的,而铝合金焊缝缺陷属于小目标,故 YOLOv4 模型的先验框不适用于铝合金焊缝内部缺陷检测。为了使先验框与真实框更接近,本实验组采用 K-means 聚类算法根据数据集的 XML 文件进行重新聚类。首先随机选择 9 个 anchor boxes, 根据包含标注框位置与类别信息的 XML 文件计算每个标注框到每个 anchor box 的 R_{IoU} 值,用距离参数 d 衡量,即 $d = 1 - R_{\text{IoU}}$ 。比较每一个距离,选取误差最小的 anchor box,将该标注框分类给它,每个标注框执行相同操作直至分类完成。再将标注框的宽高中值大小作为 anchor box 新的尺寸,重复上述步骤,直至标注框的分类不再更新。本次实验输入模型的图片大小为 416×416 ,综合考虑 3 种类别缺陷的大小和尺度变化范围,通过上述方法针对 3 种尺度 $[(13 \times 13), (26 \times 26), (52 \times 52)]$ 特征层分别设计 9 种尺度 $[(172, 16), (84, 14), (36, 49), (24, 24), (32, 13), (14, 26), (18, 17), (13, 13), (9, 11)]$ 的先验框。K-means 聚类提高了先验框的命中率,加快了模型训练速度及损失函数的收敛速度。

3.2 网络结构优化

为了提高铝合金焊缝缺陷的检测速度与精度,对加强特征提取网络进行了改进,图 2 为改进后的网络框架图。

图 2 加强特征提取网络 PANet 中的 Conv 为 1×1 卷积,通过该卷积对主干特征提取网络提取到的特征进行整合,将其中全部的 3×3 卷积改为深度可分离卷

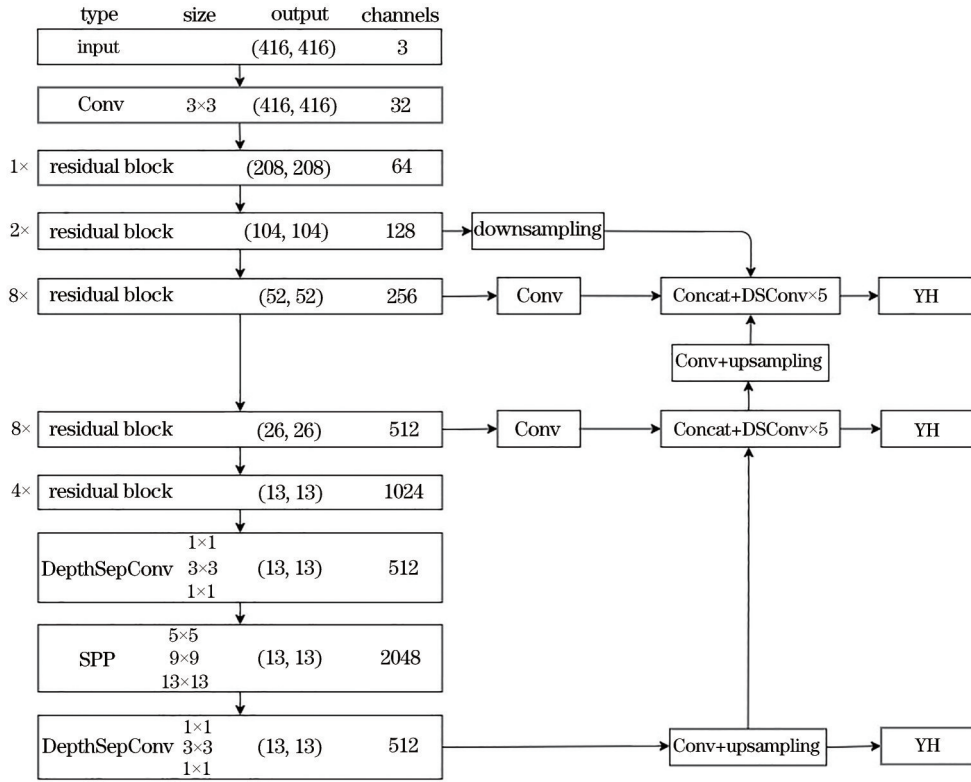


图 2 改进后的 YOLOv4 网络框架图
Fig. 2 Network framework diagram of improved YOLOv4

积(DepthSepConv),通过卷积方式的改变大幅度减小了模型训练的参数量,其中激活函数改为 ReLU6,防止数值爆炸。以 Conv2d 中的 3×3 过滤器为例,分开使用 $3 \times 3 \times 3$ 中的 3 个核仅对一个通道进行卷积得到 $3 \times 3 \times 1$,最后将 3 个通道堆叠,使得最后结果与 Conv2d 相同,在保持深度不变的前提下改变了空间维度,加快了模型的训练速度。DepthSepConv 的计算量与 Conv2d 的计算量之比为

$$\frac{D_A D_A M D_B D_B + M N D_B D_B}{D_A D_A M N D_B D_B} = \frac{1}{N} + \frac{1}{D_A^2}, \quad (5)$$

式中: $D_A D_A$ 为卷积核大小; $D_B D_B$ 为输入特征层和输出特征层的大小; M 为输入特征图的通道数; N 为输出特征图的通道数。

气孔类缺陷检测精确率不高是由于下采样时容易丢失小目标的边缘信息,因此本实验组去除了 PANet 的两个下采样及特征融合,在 52×52 的特征图上融合上一层的特征,最后对输出的 13×13 、 26×26 、 52×52 三个特征层进行解码。考虑到原网络 Spatial Pyramid Pooling(SPP)层 3 个尺度的池化能增加感受野,有利于边缘特征的检出,故保留 SPP 层。

YOLOv4 模型进行卷积、池化等操作的次数为 433,其参数总量为 64040001。YOLOv4-cs 模型采用深度可分离卷积,去除了加强特征网络中的下采样层及特征融合,其卷积、池化等操作的次数共计 427 次,参数总量为 32486977。改进后,模型的参数量大大减

小,使其更加轻量化。

4 实验及结果分析

4.1 图像增强

数据集为焊缝 X 射线探伤缺陷图片,数据集内含有气孔(pore)、未焊透(incomplete penetration)及夹渣(slag inclusion)3 种缺陷图片共 790 张。深度学习训练数据不足时,神经网络中的每个单元不得不考虑每个样本中物体的定位和分类特征,整个神经网络容易出现过拟合^[16]。考虑到初始训练样本仅有 790 张图片,数目较少,通过图像批量旋转、裁剪、改变图像的色调和饱和度等操作扩充数据集,降低模型对某些属性的依赖性及对目标位置的敏感性,提高深度学习模型的鲁棒性,扩充后的图片共 2801 张。扩充后的数据集更复杂,训练后的模型鲁棒性更好,可提高焊缝内部缺陷的实际检测效果。

4.2 实验验证

实验是在 Windows 10 环境下基于 Pytorch 深度学习框架实现的,硬件设备包括 AMD R7 4800H 处理器、NVIDIA GTX 1650Ti 显卡、16 GB 内存。数据集为通过图像增强获得的 2801 张焊缝 X 射线探伤缺陷图片,每次迭代时将图像总量的百分之九十用于训练,剩余百分之十用于验证。实验中所有模型通过冻结训练进行 50 次迭代,batch size 设置为 8,初始学习率设为 0.001,使用 Adam 优化器优化,每轮训练后学习率递

减 0.00005,用于计算梯度以及梯度平方的运行平均值的系数 betas 采用默认值,与此同时为了增加数值计算的稳定性而加到分母里的 eps 设为 1×10^{-8} 。50 次迭代后进行解冻训练,为防止显存不足,程序报错或运行途中程序终止,解冻后的 batch size 设置为 2,学习率为 0.0001,进行 100 次迭代,每次迭代后学习率递减 0.00005,共计迭代 150 次。

4.3 实验结果及分析

YOLOv4-cs 在 50 轮迭代后进行解冻训练,损失大幅度下降,逐渐低于 YOLOv4 模型,当 epoch 达到 120 次时损失稳定在 6.6 左右。图 3 为损失函数对比曲线图。

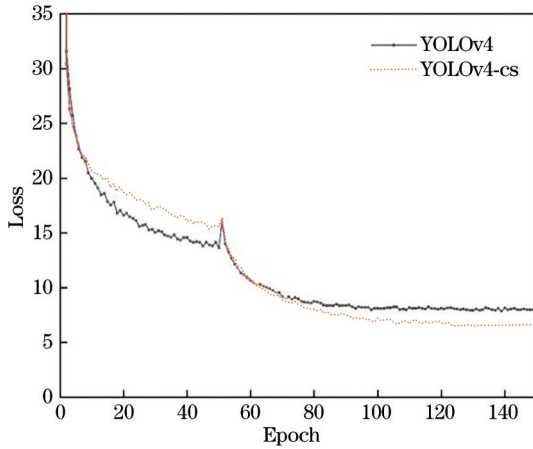


图 3 损失函数对比曲线

Fig. 3 Loss function comparison curve

为了验证与评价所提 YOLOv4-cs 模型的优化效果,将通过图像增强的 2801 张焊缝内部缺陷图作为测试集,选取常用的精确率(precision)、召回率(recall)、检测速度、平均精准度(AP)、mAP 作为评价指标^[17]。精确率是对给定数据集分类正确样本个数和总样本数的比值,召回率用来说明分类器中判定为真的正例占总正例的比值,表达式分别为

$$R_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (6)$$

$$R_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (7)$$

式中: N_{TP} 表示正确识别出是气孔的个数; N_{FP} 表示被错误识别出气孔的个数; N_{FN} 表示没有被检测出气孔的个数。

表 1 为不同算法的精确率与召回率。从表 1 可以看出,YOLOv3 和 YOLOv4-Tiny 对 3 种缺陷的检测精确率较好,但对未焊透缺陷的召回率较低。YOLOv4 虽然在未焊透缺陷上的召回率有了显著提升,但精确率有所下降。YOLOv4-cs 在去除加强特征提取网络中的下采样层及对应的特征融合后,通过上采样放大特征并与上一层的特征图进行融合,在 52×52 用于检测小目标缺陷的 Yolo Head 层中融入了第 2 个残差块获得的特征图,有效地保留了边缘信息,更有利于气孔及未焊透缺陷的检测。实验结果表明,YOLOv4-cs 在 3 种缺陷检测上的召回率相比于其他模型提升显著,且改进后模型的检测速度上比原模型提升了 4.04 个百分点。

表 1 不同算法测试结果

Table 1 Test results of different algorithms

Algorithm	Pore		Slag inclusion		Incomplete penetration		Detection speed / (frame·s ⁻¹)
	Precision / %	Recall / %	Precision / %	Recall / %	Precision / %	Recall / %	
YOLOv4-cs	95	74.43	96.52	84.74	84.2	67.59	24.47
YOLOv4	97.13	56.23	95.6	75.47	87.02	53.42	20.43
YOLOv3	96.58	66.27	98.09	80.95	94.78	48.41	25
YOLOv4-Tiny	92.29	60.27	93.18	70.42	85.05	20.4	84.7
SSD	96.18	44.5	97.19	61.89	99.95	0.11	34.1

在 3 种缺陷检测结果中,YOLOv4-cs 相比于 YOLOv4 虽然召回率得到了提升,但精确率却有所下降,因此使用 F1 指标来表征算法的性能。

$$S_{\text{F1}} = \frac{2 \times R_{\text{precision}} \times R_{\text{recall}}}{R_{\text{precision}} + R_{\text{recall}}}. \quad (8)$$

表 2 为不同模型的 F1 值。从表 2 可以看出,YOLOv4-cs 模型在 3 种缺陷的 F1 值均优于其他模型,表明改进后的模型更适用于这 3 种缺陷的检测识别。

AP 是指模型对某一种缺陷检测的平均精度,mAP

表 2 不同模型 F1 值对比

Table 2 Comparison of F1 values of different models

Model	Pore F1	Slag inclusion F1	Incomplete penetration F1
YOLOv4-cs	0.83	0.9	0.75
YOLOv4	0.71	0.84	0.66
YOLOv3	0.79	0.89	0.64
YOLOv4-Tiny	0.73	0.8	0.33
SSD	0.61	0.76	0.002

是模型对所有类别检测判断的平均精度,表达式分别为

$$P_{AP_c} = \frac{\sum_{i=1}^{N_c} R_{\text{precision}, i}}{N_c}, \quad (9)$$

$$P_{\text{mAP}} = \frac{\sum_{c=1}^C P_{AP_c}}{C}, \quad (10)$$

式中: P_{AP_c} 表示某一缺陷的所有精确率之和与这一缺陷总数的比值; P_{mAP} 表示不同种类缺陷的 AP 值的总

与与缺陷种类 C 的比值。

表 3 为不同模型 AP 及 mAP 值对比。YOLOv4-cs 在网络结构及先验框上进行了相应的改进,通过更全面的边缘信息训练网络,使先验框和真实框的重合度更高,因此在 3 种缺陷的 AP 值较 YOLOv4 分别提升了 4 个百分点,3 个百分点,1 个百分点,整体 mAP 值提升了 2.67 个百分点。图 4、图 5 直观表现了 YOLOv4 和 YOLOv4-cs 在不同缺陷上的 AP 值和 mAP 值。

表 3 不同模型 AP 及 mAP 值对比

Table 3 Comparison of AP and mAP values in different models

Model	Pore AP / %	Slag inclusion AP / %	Incomplete penetration AP / %	mAP / %
YOLOv4-cs	91	95	80	88.52
YOLOv4	87	92	79	85.85
YOLOv3	88	95	76	86.59
YOLOv4-Tiny	74	83	44	67.02
SSD	82	90	41	71.06




图 4 YOLOv4 的 AP 与 mAP
Fig. 4 AP and mAP of YOLOv4

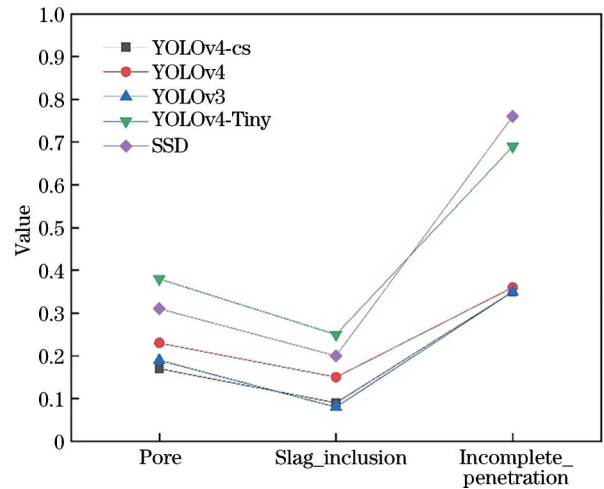


图 6 不同模型漏检率
Fig. 6 Missed detection rate of different models

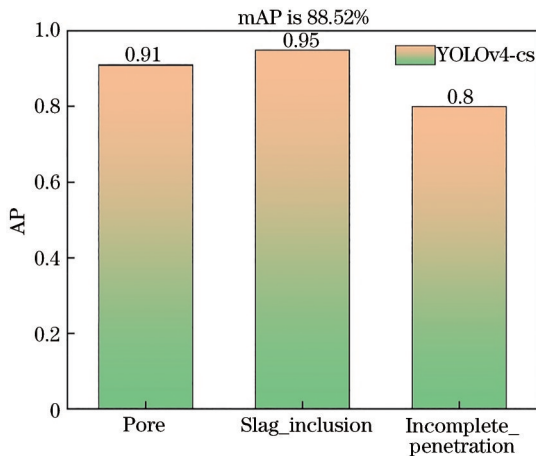


图 5 YOLOv4-cs 的 AP 与 mAP
Fig. 5 AP and mAP of YOLOv4-cs

图 6 是 5 种模型对 3 种焊缝内部缺陷漏检率的对比图,从图中可以看出,YOLOv4-cs 与 YOLOv3 对 3 种缺陷的漏检率较低。

图 7 为改进后的 YOLOv4-cs 模型与原 YOLOv4 模型的预测结果对比。从图 7 可以看出,改进后的模

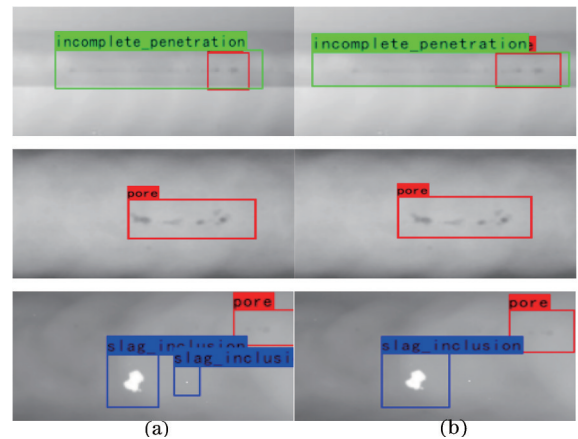


图 7 不同模型预测结果。(a) YOLOv4-cs; (b) YOLOv4
Fig. 7 Prediction results of different models. (a) YOLOv4-cs; (b) YOLOv4

型在未焊透缺陷检测上的预测更为准确,且较小的夹渣也被检测出。

5 结 论

针对 YOLOv4 在焊缝 X 射线探伤缺陷检测精度与召回率低的问题,对 YOLOv4 模型进行了改进,通过图像增强提升模型鲁棒性,对网络的特征提取结构和初始先验框大小进行改进与调整,使得改进后的模型能够提取气孔类小目标物体的边缘特征,提高模型检测精确率。实验结果表明, YOLOv4-cs 模型在气孔、夹渣、未焊透 3 种缺陷检测上的召回率相比于 YOLOv4 有较大提升且 3 种缺陷的平均精确率为 92%。召回率的提升表示未检测出缺陷的数目减少,在保证精确率的前提下提升该缺陷的 AP 值,使得模型的 mAP 值提升至 88.52%,较原 YOLOv4 模型提升了 2.67 个百分点。检测速度由 20.43 frame·s⁻¹ 提升到了 24.47 frame·s⁻¹。但在未焊透缺陷检测上,召回率和漏检率仍有提升的空间,后续将尝试加入注意力机制使得模型更注重该缺陷的边缘信息,进一步改善该类缺陷的各个检测指标。

参 考 文 献

- [1] 王池权, 石亮, 张祥春, 等. 焊接缺陷对异种铝合金 TIG 对接接头疲劳行为的影响[J]. 北京航空航天大学学报, 2021, 47(7): 1505-1514.
Wang C Q, Shi L, Zhang X C, et al. Effect of welding defects on fatigue behavior of dissimilar aluminum alloy TIG butt joint[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(7): 1505-1514.
- [2] 罗鸿君. 铝合金搭接焊缝数字射线成像典型缺陷参考图像库的建立[J]. 无损检测, 2019, 41(1): 23-26.
Luo H J. Establishment of typical defect reference image library for digital radiography aluminum alloy lap welding [J]. Nondestructive Testing, 2019, 41(1): 23-26.
- [3] 樊丁, 胡桢得, 黄健康, 等. 基于改进卷积神经网络的管焊缝 X 射线图像缺陷识别方法[J]. 焊接学报, 2020, 41(1): 7-11, 97.
Fan D, Hu A D, Huang J K, et al. X-ray image defect recognition method for pipe weld based on improved convolutional neural network[J]. Transactions of the China Welding Institution, 2020, 41(1): 7-11, 97.
- [4] 曹之君, 张良. 基于 Faster-RCNN 的快速目标检测算法[J]. 航天控制, 2020, 38(4): 49-55.
Cao Z J, Zhang L. Fast object detection algorithm based on faster-RCNN[J]. Aerospace Control, 2020, 38(4): 49-55.
- [5] Xu K, Wang X Y, Wang D. A scalable OpenCL-based FPGA accelerator for YOLOv2[C]//2019 IEEE 27th Annual International Symposium on Field-Programmable Custom Computing Machines, April 28-May 1, 2019, San Diego, CA, USA. New York: IEEE Press, 2019: 18742103.
- [6] Ouyang L C, Wang H L. Aerial target detection based on the improved YOLOv3 algorithm[C]//2019 6th International Conference on Systems and Informatics (ICSAI), November 2-4, 2019, Shanghai, China. New York: IEEE Press, 2019: 1196-1200.
- [7] Wang J T, Xiao W, Ni T W. Efficient object detection method based on improved YOLOv3 network for remote sensing images[C]//2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD), May 28-31, 2020, Chengdu, China. New York: IEEE Press, 2020: 242-246.
- [8] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2021-03-04]. <https://arxiv.org/abs/2004.10934>.
- [9] 唐小煜, 黄进波, 冯洁文, 等. 基于 U-net 和 YOLOv4 的绝缘子图像分割与缺陷检测[J]. 华南师范大学学报(自然科学版), 2020, 52(6): 15-21.
Tang X Y, Huang J B, Feng J W, et al. Image segmentation and defect detection of insulators based on U-net and YOLOv4[J]. Journal of South China Normal University (Natural Science Edition), 2020, 52(6): 15-21.
- [10] 黄海新, 金鑫. 基于 YOLOv4 的小目标缺陷检测[J]. 电子世界, 2021(5): 146-147.
Huang H X, Jin X. Small target defect detection based on YOLOv4[J]. Electronics World, 2021(5): 146-147.
- [11] 王家晨, 王新房. 基于 ButterWorth 滤波的 X 射线钢管焊缝缺陷检测方法[J]. 微型机与应用, 2017, 36(23): 21-24.
Wang J C, Wang X F. Automatic detection of weld defects in X-ray based on ButterWorth filtering[J]. Microcomputer & Its Applications, 2017, 36(23): 21-24.
- [12] 王欣, 高炜欣, 武晓朦, 等. 基于模糊模式识别的焊缝缺陷图像检测[J]. 西安石油大学学报(自然科学版), 2016, 31(4): 115-121.
Wang X, Gao W X, Wu X M, et al. Image detecting of weld defect based on fuzzy pattern recognition[J]. Journal of Xi'an Shiyou University (Natural Science Edition), 2016, 31(4): 115-121.
- [13] 陈磊, 张孙杰, 王永雄. 基于改进的 YOLOv3 及其在遥感图像中的检测[J]. 小型微型计算机系统, 2020, 41(11): 2321-2324.
Chen L, Zhang S J, Wang Y X. Based on improved YOLOv3 and its detection in remote sensing images[J]. Journal of Chinese Computer Systems, 2020, 41(11): 2321-2324.
- [14] 方叶祥, 甘平, 陈俐. 金属表面缺陷检测的改进 YOLOv3 算法研究[J]. 机械科学与技术, 2020, 39(9): 1390-1394.
Fang Y X, Gan P, Chen L. Improved YOLOv3 algorithm for detection of metal surface defect[J]. Mechanical Science and Technology for Aerospace Engineering, 2020, 39(9): 1390-1394.
- [15] 孙佳, 郭大波, 杨甜甜, 等. 基于改进的 YOLOv3 网络的实时目标检测[J]. 激光与光电子学进展, 2020, 57(22): 221505.
Sun J, Guo D B, Yang T T, et al. Real-time object detection based on improved YOLOv3 network[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221505.
- [16] 卢依宏, 蔡坚勇, 郑华, 等. 基于深度学习的少样本研究综述[J]. 电讯技术, 2021, 61(1): 125-130.

- Lu Y H, Cai J Y, Zheng H, et al. Researches on few-shot learning based on deep learning: an overview[J]. Telecommunication Engineering, 2021, 61(1): 125-130.
- [17] 杨耘, 李龙威, 高思岩, 等. 基于 YOLOv3 网络训练优化的分辨率遥感影像目标检测[J]. 激光与光电子学进展, 2021, 58(16): 1601002.
- Yang Y, Li L W, Gao S Y, et al. Objects detection from high-resolution remote sensing imagery using training-optimized YOLOv3 network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1601002.