

DOI: 10.7512/j.issn.1001-2303.2025.05.04

基于改进YOLOv5网络的管道环焊缝射线底片缺陷智能识别

汤大赞¹, 袁健伟^{1*}, 吴 颀^{2,3}, 何东昌^{2,3}, 张培磊^{2,3}, 潘 斌¹, 龚 浩¹, 金鸿飞¹

1. 江苏省特种设备安全监督检验研究院, 江苏 昆山 215316

2. 上海工程技术大学 材料科学与工程学院, 上海 201620

3. 上海市激光先进制造技术协同创新中心, 上海 201620

摘要: X射线数字辐射成像DR技术是环焊缝质量检测的必备手段,但现有的人工目视检测方法难以实现高精度的多种、小目标缺陷自动识别。为此,本研究提出了一种基于深度学习模型的管道环焊缝DR图像缺陷智能识别方法。首先针对工件缺陷复杂、射线噪声和散射等问题,采用对比度有限自适应直方图均衡化方法实现原始图像增强,并构建高质量的管道环焊缝DR图像数据集;其次,提出一种新颖的改进YOLOv5深度学习网络,采用C2F模块学习多种典型缺陷的特征分布,并结合多尺度特征融合检测手段来判断不同大小的目标缺陷;进一步采用均方误差损失函数提高对噪声的容忍性,并通过输出端实现对焊缝缺陷的自动检测。最终对管道环焊缝缺陷进行测试和验证,试验结果表明:通过改进YOLOv5深度网络模型,其检测结果的平均准确率为95.89%,漏检率为2.1%,能够有效准确地自动识别DR图像焊缝缺陷。

关键词: 管道环焊缝; YOLOv5; 深度学习; 缺陷检测; DR图像

中图分类号: TG457.6 文献标识码: A 文章编号: 1001-2303(2025)05-0030-07

Pipeline Girth Weld Defect Intelligent Identification of Digital Radiograph based on an Improved YOLOv5 Network

TANG Dayun¹, YUAN Jianwei^{1*}, WU Di^{2,3}, HE Dongchang^{2,3}, ZHANG Peilei^{2,3}, PAN Bin¹,
GONG Hao¹, JIN Hongfei¹

1. Special Equipment Safety Supervision Inspection Institute of Jiangsu Province, Kunshan 215316, China

2. School of Materials and Science Engineering, Shanghai University of Engineering and Technology, Shanghai 201620, China

3. Shanghai Collaborative Innovation Center of Laser Advanced Manufacturing Technology, Shanghai 201620, China

Abstract: Pipeline girth welds are a crucial component of oil and gas pipelines, significantly impacting the safety of natural gas and other transmissions. Currently, X-ray Digital Radiography (DR) technology has become an essential method for the quality inspection of girth welds. However, existing visual inspection methods struggle to achieve high-precision defect identification. Therefore, this paper proposes a deep learning-based algorithm for defect detection in pipeline girth welds using DR images. Firstly, to address issues such as complex workpiece defect structures and noise and scatter introduced by X-rays, guided filtering methods are used for data enhancement, and a pipeline girth weld DR dataset is created. Secondly, the backbone network of the improved YOLOv5 model, combined with the C2F (CSP Bottleneck with 2 convolutions) module, is employed to learn the defect feature distributions. The multi-scale feature fusion detection method is combined to judge the target defects of different sizes. The mean square error loss function is further used to improve the tolerance of noise, and the automatic detection of weld defects is realized through the output end. Finally, the common defects of pipeline girth

收稿日期: 2024-08-29 修回日期: 2025-01-03

基金项目: 国家自然科学基金(52075317);江苏省特种设备安全监督检验研究院科技计划项目(KJ(Y)202418);上海市III类高峰学科—材料科学与工程(高能束智能加工与绿色制造)

作者简介: 汤大赞(1986—),男,硕士,工程师,主要从事承压类特种设备无损检测及失效分析研究。E-mail: tdy_just@qq.com。

通讯作者: 袁健伟(1972—),男,硕士,高级工程师,主要从事焊接无损检测、缺陷评定研究。E-mail: ksyjw2001@163.com。

welds were tested and verified, and the results showed that the average accuracy of detection results by the improved YOLOv5 deep network model proposed in this paper was 95.89%, and the missed detection rate was 2.1%, which could effectively and accurately automatically identify weld defects in DR Images.

Keywords: pipeline girth welds; YOLOv5; deep learning; defect detection; DR image

引用格式:汤大赞,袁健伟,吴頔,等. 基于改进YOLOv5网络的管道环焊缝射线底片缺陷智能识别[J]. 电焊机, 2025, 55(5): 30–36.

Citation: TANG Dayun, YUAN Jianwei, WU Di, et al. Pipeline Girth Weld Defect Intelligent Identification of Digital Radiograph based on an Improved YOLOv5 Network[J]. Electric Welding Machine, 2025, 55(5): 30–36.

0 引言

在金属加工制造过程中,焊接是将零件连接起来的重要方法之一。据统计,超过45%的钢铁和金属材料通过焊接形成最终产品,其焊接质量将直接影响金属零件性能和工业成品使用寿命^[1]。在焊接过程中,由于材料和工艺因素,可能产生裂纹、未熔合或未焊透等常见缺陷^[2],从而直接严重影响产品质量和安全。特别针对产品质量要求苛刻的压力管道焊接场景,如何保障快速、精准的焊缝质量检测尤为重要。一般来说,焊接缺陷分为表面缺陷和内部缺陷,表面缺陷可通过目视、渗透检测(PT)和磁粉检测(MT)识别和评定,内部缺陷通常采用射线检测(RT)和超声检测(UT)。RT检测通过射线源照射被检测物体,由于厚度不同,射线穿过后的强度不同,从而形成灰度图像,并分析图像即可确定缺陷位置、尺寸和类型^[3]。然而传统胶片射线技术依赖人工评片,容易受到评片者经验、专业知识和专注度的影响,极易导致漏评和错评。现代的X射线计算机照相(CR)和数字成像(DR)技术虽然改进了前期过程,但仍依赖人工主观评片,其缺陷检测效率和稳定性不足。在我国工业自动化、敏捷化、数字化的快速发展趋势下,传统人工焊缝质量评估已不能满足大批量生产和数字化信息管理的需要,迫切需要更加智能化的焊缝缺陷智能识别方法的出现。

近年来,随着大数据、云计算和5G物联网的发展,基于深度学习的计算机视觉技术快速发展,能够实现焊缝缺陷自动检测和识别,将有助于降低评片者劳动强度,提高评片效率、准确度和稳定性。文献^[5]提出一种复杂结构背景内的缺陷检测法,应用两次阈值并利用锐化、平滑及背景减除等操作完

成缺陷分割,但该方法并不适用于面积较小缺陷的检测。焦等人^[6]从焊缝图像中提取出15种可用于焊缝表面缺陷状态表征的特征参数,并结合BP神经网络进行内焊缝表面缺陷识别,但所得91%的整体识别准确率不足以应用于实际工业生产,有待进一步提高。文献^[7]描述了一种基于自适应神经网络的模糊系统,并用于识别射线照相图像中的焊缝缺陷,但是模糊系统缺乏自学习能力。为得到更好的焊缝缺陷特征表示能力,深度卷积神经网络日益得到重视。Li等人^[4]比较研究了不同卷积层数量、卷积核大小,以及不同激活函数对缺陷特征的提取效果,设计了十层卷积神经网络对六类常见的焊接缺陷进行分类,平均准确率能达到90%。Hou等人^[8]提出了一种深度卷积神经网络(Deep convolutional neural network, DCNN)模型,从X射线图像中提取深部特征,由于焊缝数据样本的不均衡,采用三重采样方法平衡数据,进一步提高了准确率。综上,国内外针对X射线焊缝图像的缺陷检测与识别,已取得了一定进展和成果,但仍存在多种类型缺陷检测复杂、缺陷对比度低和形状不规则等突出问题,从而制约了复杂焊缝图像缺陷的可靠识别。

为了解决上述难题,本文首先针对原始管道环焊缝X射线DR图像,采用自适应直方图均衡化算法进行图像数据增强,以提升图像细节和对比度;进一步提出一种基于改进YOLOv5网络的多尺度缺陷检测方法,结合C2F模块作为主干网络进行多尺度特征提取,并构建端到端的缺陷检测模型,从而实现焊缝缺陷的智能识别目标。

1 研究方法和结果分析

图1为改进YOLOv5焊缝缺陷DR图像智能识

别方法的完整流程。首先通过 DR 成像系统对压力管道环焊缝缺陷进行数字成像后,再对原始图像进行增强、扩充和标注处理得到完整的环焊缝缺陷数据集。最终将该数据集送入改进 YOLOv5 模型中进行训练和测试,得到缺陷检测结果并分析验证。




图1 基于改进 YOLOv5 模型的 DR 图像缺陷智能识别方法流程

Fig. 1 DR image defect intelligent identification method process based on improved YOLOv5 model

1.1 DR 图像数据集构建


在 X 射线扫描仪同等的观察条件下,各类焊缝缺陷有其独特的视觉特征。其中,圆形缺陷(圆缺)一般表现为清晰、规则的圆形区域,其边缘平滑且内部颜色均匀。裂纹缺陷通常表现为细长、不规则的线状区域,边缘可能存在不规则锯齿状,并且沿裂纹方向颜色逐渐变化。条形缺陷(条缺)与裂纹相似,但条缺更为宽大且通常平行于焊缝方向,颜色变化较均匀。未焊透缺陷表现为焊缝区域局部明显的深色阴影,这种阴影通常具有较大的面积且呈现不规则形状,边缘模糊。总体来说,这些典型缺陷形态均呈现出一定的规律性排列和纹理特征,从而作为缺陷检测识别的重要依据^[9]。

本文原始试验数据来自压力管道检验中的压力管道环焊缝 DR 图像,并进行图像扩充处理,得到 3120 张焊缝缺陷图像,其中裂纹 330 张,未熔合 670 张,未焊透 660 张,条形缺陷 500 张,圆形缺陷 500

张,根部内凹 260 张,根部咬合 200 张。受 DR 成像系统中成像板的结构噪声、高压射线源电噪声、漫散射效应以及成像环境等多种因素影响,图像清晰度较低,其中圆形缺陷不清晰度尤为明显,如图 2a 所示。针对以上问题,本文采用了拉普拉斯滤波和对比度有限的自适应直方图均衡化算法(CLAHE, contrast limited adaptive histogram equalization),对原始图像进行图像增强处理,处理后的圆形缺陷效果如图 2b 所示。可以看出,经过处理后,圆形缺陷的清晰度明显增强,并保留重要的细节特征。



(a)原始缺陷图像



(b)经 CLAHE 图像增强后缺陷图像

图2 基于对比度有限自适应直方图均衡化增强前后对比
Fig. 2 Comparative result before and after image enhancement based on CLAHE algorithm

1.2 改进 YOLOv5 模型框架

1.2.1 模型介绍

YOLOv5 模型作为 YOLO(You Only Look Once)系列的最新迭代,整合了众多提高检测精度的先进方法,实现了在目标检测精度和推理速度之间的优化平衡,超越了传统的单阶段目标检测模型^[10]。该网络结构分明,初始阶段通过骨干网络提取图像特征,生成多层级的特征图。随后特征融合模块融合高层的语义信息与低层的空间信息,生成多尺度的下采样输出,最终通过预测头网络进行目标坐标的回归与缺陷分类^[10-11]。

为实现单张焊缝缺陷图像的多尺度缺陷识别,本研究提出了一种改进的 YOLOv5 模型(见图 3)。

该模型的预测层输出四个特征图,分别对应原始 YOLOv5n 模型的 4、8、16、32 倍下采样。具体而言,大尺寸特征图通过较大的卷积核检测小目标缺陷,如圆缺和气孔,而小尺寸特征图则侧重于大目标缺陷,如条缺、未熔透和裂纹。此外,改进版的 YOLOv5 模型采用了 C2F (CSP Bottleneck with 2 convolutions) 模块以增强高阶特征的提取能力并减少模型参数,从而取代了传统的 CSPDarknet53 模块。C2F 模块使用两层 Bottleneck 层进行特征提取,通过多分支流设计和重复利用不同阶段特征,有效提高了特征提取能力,能够捕捉到更多的细节信息。在特征融合模块的 Neck 部分,引入了快速空间金字塔池化 (Spatial Pyramid Pooling Fast, SPPF) 层,将不同核大小池化后的特征图串联在一起作为输出,从而有效增加了骨干网络的感受野,显著区分了最重要的上下文特征。此外, YOLOv5 将特征金字塔网络 (Feature Pyramid Network, FPN) 与路径聚合网络 (Path Aggregation Network, PAN) 相结合,其中,顶层的语义信息自上而下与底层的空间信息融合,细粒度的局部信息可以自下而上传播到顶层,从而实现了更加有效的特征融合^[12]。

改进后的 YOLOv5 网络模型损失函数由三部分构成,分别是二元交叉熵置信度损失函数 L_{obj} , 多元交叉熵分类损失函数 L_{cls} 以及边框回归损失函数 L_{bbox} 。具体如式(1)~式(3)所示:

$$L_{obj} = \sum_{i=0}^k \sum_{j=0}^k (p_{ij}^{obj} [C_i \log(C_i) + (1 - C_i) \log(1 - C_i)] - \lambda_{nobj} [C_i \log(C_i) + (1 - C_i) \log(1 - C_i)]) \quad (1)$$

多元交叉熵分类损失函数 L_{cls} 用于判断检测到的目标属于某一具体类别。其中: $\hat{p}_i(c)$ 是模型对第 i 行第 j 列的单元格预测属于类别 c 的概率:

$$L_{cls} = \sum_{i=0}^k \sum_{j=0}^k p_{ij}^{obj} \sum_{c \in classes} [p_i(c) \log(\hat{p}_i(c)) + (1 - p_i(c)) \log(1 - \hat{p}_i(c))] \quad (2)$$

边框回归损失函数 L_{bbox} 用于精确预测目标的位置和大小:

$$L_{bbox} = \lambda_{coord} \sum_{i=0}^k \sum_{j=0}^k p_{ij}^{obj} (2 - w_{ij} \cdot h_{ij}) (1 - CIoU) \quad (3)$$

式中 λ_{coord} 是坐标预测的权重, w_{ij} 、 h_{ij} 是模型预测目标的宽和高, CIoU (Complete Intersection over Union)

是一种改进的 IoU 计算方法,考虑了边框的重叠面积、中心点距离和长宽比^[13]。最后,改进后的 YOLOv5 通过引入 C2F 模块、SPPF 层以及结合 FPN 和 PAN 网络,以提高多种焊缝缺陷 (特别是小目标缺陷) 的检测能力,同时采用迁移学习方法进一步提升模型训练的稳定性和泛化能力。




图3 改进后的 YOLOv5 的网络结构示意图

Fig. 3 Schematic diagram of the improved YOLOv5 network structure

1.2.2 Neck 结构改进

在 YOLOv5n 的传统架构中, Neck 结构借助特征金字塔网络 FPN 和路径聚合网络 PAN 的结合,输出三层尺度不同的特征图,分别用于检测不同大小的目标。然而,此结构在处理小目标时展现了一定的局限性。为提高对小目标的检测能力,本研究对 YOLOv5n 的 Neck 结构进行了改进,特别是通过增加一个额外的特征图层,以强化对小目标的检测。

(1) 增加特征层。

在原有的三层特征图 (8 倍、16 倍、32 倍下采样) 的基础上,增加了一层特征图 (4 倍下采样)。这层特征图具有更高的分辨率,可以捕捉到更多的细节信息,有助于提高小目标的检测精度。

(2) 特征融合。

新增加的特征层通过特征金字塔网络 FPN 与

其他层级的特征进行融合。通过自上而下和自下而上的信息传递,确保高层语义信息与低层空间信息的有效融合。具体而言,在FPN基础上,将4倍下采样的特征图与8倍下采样的特征图进行融合,再通过PAN结构将细粒度信息向上传递,进一步提升特征表达能力。

(3)改进后的结构。

在改进后的YOLOv5模型中,输入特征图是原始图像经过Backbone提取后的特征图。通过增加一层卷积和下采样操作,引入了4倍下采样特征图,从高分辨率特征中提取更多的细节信息。同时,保留了原有的8倍、16倍、32倍下采样特征图,这些特征图通过FPN和PAN进行特征融合。为了进一步丰富特征表达,将新增加的4倍下采样特征图与现有的特征图进行融合,从而形成了一个多尺度特征融合的结构,显著提升了模型在小目标检测方面的性能。

2 改进YOLOv5模型训练结果分析

2.1 模型训练参数

试验环境为CPU Intel(R) Xeon(R) Gold 6246R CPU@3.40GHz,内存为256G,GPU为NVIDIA RTX A5000,内存152G。深度学习框架使用PyTorch,编程语言为Python。模型训练硬件软件参数如表1所示。

表1 模型训练硬件软件参数

Table 1 Model training hardware and software parameters

训练设备	设备参数	训练参数	环境参数
GPU	Intel(R) Xeon(R) Gold 6246R cpu@3.40GHz(256G)	CUDA	11.3
CPU	NVIDIA RTX A5000(152G)	Torch	1.11.0

2.2 模型评价指标

识别的评价指标为分类中常用的识别 P (准确率), R (召回率)和 F (F-score)。准确率 P 是预测正确的样本数与总的正样本数的比值,如式(4)所示,主要用于表征模型正确的预测能力,数值越大则缺陷检测效果越佳。

$$P = \frac{TP}{TP + FP} \quad (4)$$

召回率 R 是预测正确的结果占有所有正样本的比

值,如式(5)所示,主要用于表征模型检出缺陷的能力,数值越大则缺陷检测效果越佳。

$$R = \frac{TP}{TP + FN} \quad (5)$$

P 与 R 两者呈相互制约的关系,引入 F 主要用于表征构建预测模型同时具有良好 P 与 R 的综合能力。 F 的定义是 P 与 R 的谐波平均值,如式(6)所示

$$F = \frac{2 \times P \times R}{P + R} \quad (6)$$

2.3 原始YOLOv5n与改进模型的对比较证

在保证模型各项训练参数不变的情况下训练改进YOLOv5模型与原始YOLOv5n模型,对两种模型迭代过程中的准确度指标进行对比较证。图4是两种模型在300轮训练过程中的总体F得分数值变化折线。从折线图中可以看出,改进模型的F-score值显著优于原始YOLOv5n模型。随着训练进一步进行,改进模型在150个批次后的F-score值保持稳定,并持续高于YOLOv5n,而且F-score平均保持在90%,从而展示了改进模型对于焊缝缺陷检测的优越性能。




图4 改进YOLOv5和原始YOLOv5n模型的总体F-score值对比

Fig. 4 Overall F-score results between improved YOLOv5n and original YOLOv5n models

原始YOLOv5n和改进后的YOLOv5在各缺陷下的识别准确率与召回率如表2所示。图5为原始YOLOv5n和改进后的YOLOv5对应的混淆矩阵图结果。对比改进前后的混淆矩阵,可以看到明显的模型性能提升:(1)准确率提升。改进前各类别的准确率普遍较低,例如圆形缺陷准确率最低为69%;改进后各类别准确率均有显著提高,特别是圆形缺陷,准确率提高到93%;(2)误分类减少。改进




图 5 原始 YOLOv5n 和改进后 YOLOv5 模型的混淆矩阵对比结果

Fig. 5 Confusion matrix results between YOLOv5n and improved YOLOv5 models

表 2 原始 YOLOv5n 和改进 YOLOv5 模型的检测统计结果
Table 2 Detection statistical results between original YOLOv5n and YOLOv5 models

缺陷类型	原始 YOLOv5n			改进 YOLOv5		
	P	R	F-score	P	R	F-score
裂纹	87%	76%	81%	96%	95%	95%
未熔合	84%	76%	79%	96%	96%	96%
未焊透	82%	80%	81%	97%	98%	97%
条形缺陷	83%	84%	83%	95%	95%	95%
圆形缺陷	69%	83%	75%	93%	97%	95%
根部内凹	83%	86%	84%	96%	92%	94%
根部咬合	84%	82%	83%	98%	92%	95%
平均值	82%	81%	81%	96%	95%	95%

前各类别间的误分类较多,特别是易于与其他类别混淆的类别,例如缺陷标注与根部咬合之间的误分

类。改进后误分类显著减少,大多数类别的主要对角线元素(即正确分类的比例)都接近或超过 90%,说明模型的鲁棒性和分类能力均得到加强;(3)稳定性提升。改进前某些类别的准确率指标波动较,改进后所有类别的准确率更加均衡,表明改进后模型对不同类型的缺陷识别更为稳定。

3 改进 YOLOv5 模型的试验验证

基于上文提出的改进模型,对管道环焊缝 DR 图像数据集的裂纹、未焊透、圆形缺陷检测进行了试验验证。部分检测结果如图 6 所示,可以看出,通过初期的适应和参数优化后,改进模型显著提升了




图 6 改进后 YOLOv5 模型检测结果

Fig. 6 Improved YOLOv5 model detection results

各种缺陷检测精度。经过长时间训练,本文提出的改进模型显示出更稳定和高效的性能,尤其在处理小目标检测方面表现出色。例如针对未焊透和圆形缺陷检测,其平均检测准确率为95.89%,漏检率为2.1%。

4 结论与展望

本文提出一种基于改进YOLOv5模型的管道环焊缝DR图像缺陷智能识别方法,将该方法与传统YOLOv5n模型进行对比,验证了改进模型在焊缝缺陷检测方面具有更优越的性能,主要结论如下:

(1)针对环焊缝缺陷复杂、噪声和散射等多种图像干扰问题,采用拉普拉斯滤波和CLAHE算法,对原始DR图像进行增强处理,有效改善了图像的信噪比,提高了缺陷识别的精度和稳定性,并构建了高质量的DR图像数据集。

(2)引入C2F模块进行多尺度特征融合,提出了一种基于改进YOLOv5网络的X射线DR图像缺陷检测算法,试验结果表明,该改进模型在多种缺陷(未熔合、未焊透、圆缺和条缺等)类型上的检测准确度均达到了较高水平,平均检测准确率为95.89%,漏检率为2.1%。

(3)尽管改进后的YOLOv5模型在焊缝缺陷检测方面表现优异,未来研究将继续探索更高效的网络结构和特征提取方法以及构建更大规模和多样性的DR数据集,并结合硬件加速技术(如GPU、FPGA等)和优化算法,从而进一步提升模型检测精度和运行速度。

参考文献:

- [1] 苟星禄,吴頔,董金枋,等. 基于机器学习的铝合金脉冲激光焊接工艺及质量预测研究[J]. 电焊机, 2023, 53(9):84-90.
GOU X L, WU D, DONG J F, et al. Quality Prediction of Pulse Laser Welding of Aluminum Alloy Based on Machine Learning[J]. Electric Welding Machine, 2023, 53(9):84-90.
- [2] 李恩,何冰,江国焱,等. 反应堆压力容器管座贯穿件与顶盖J型焊缝缺陷分析及改进[J]. 电焊机, 2024, 54(4):77-83.
- [3] 王飞,朱建江. 机器视觉在复杂环境下焊接缺陷检测的应用研究[J]. 焊接技术, 2017, 46(5):127-133.
WANG F, ZHU J J. Research on the Application of Machine Vision in Welding Defect Detection in Complex Environments[J]. Welding Technology, 2017, 46(5):127-133.
- [4] Li Y P, Gao W X. Research on X-ray welding image defect detection based on convolution neural network[J]. Journal of Physics: Conference Series, 2019, 1237(3):032005.
- [5] Torkzadeh V, Toosizadeh S. Automatic visual inspection system for quality control of the sandwich panel and detecting the dipping and buckling of the surfaces[J]. Measurement and Control, 2019, 52(7-8):804-813.
- [6] 焦敬品,李思源,常予,等. 集箱管接头内焊缝表面缺陷识别方法研究[J]. 仪器仪表学报, 2017, 38(12):3044-3052.
JIAO J P, LI S Y, CHANG M, et al. Defect classification of weld surface in header pipe joint[J]. Chinese Journal of Scientific Instrument, 2017, 38(12):3044-3052.
- [7] Zapata J, Vilar R, Ruiz R. An adaptive-network-based fuzzy inference system for classification of welding defects[J]. NDT & E International: Independent Non-destructive Testing and Evaluation, 2010, 43(3):191-199.
- [8] Hou W, Ye W, Yi J, et al. Deep features based on a DCNN model for classifying imbalanced weld flaw types[J]. Measurement, 2018, 131:482-489.
- [9] 王春妮,李健,白真权,等. 油气输送管道失效分析技术现状及研究进展[J]. 石油管材与仪器, 2024, 10(1):1-8.
WANG C N, LI J, BAI Z Q, et al. Research Progress in Failure Analysis Technology for Oil and Gas Transmission Pipelines[J]. Petroleum Tubular Goods & Instruments, 2024, 10(1):1-8.
- [10] 任文坚,王永红,李春凯,等. 液体火箭发动机推力室熔焊缝数字化胶片图像缺陷识别方法研究[J]. 电焊机, 2023, 53(1):9-14.
REN W J, WANG Y H, LI C K, et al. Research on Au