

基于改进YOLOv8的丁基胶塞表面缺陷检测算法

吴凡^{1,2}, 丁晓波^{1,2}

(1. 三峡大学 计算机与信息学院;
2. 三峡大学 湖北省建筑质量检测装备工程技术研究中心, 湖北 宜昌 443002)

摘要: 针对国内丁基胶塞生产线普遍依赖人工进行缺陷检测存在的成本高、效率低问题,提出一种基于YOLOv8的改进型表面缺陷检测算法。首先,设计了一种多尺度卷积模块FMSCov,以增强网络对不同尺度缺陷特征的提取能力,有效应对产品表面缺陷尺寸变化显著的问题;其次,在检测头中引入SEAM注意力机制,强化关键特征响应,缓解因产品堆叠或遮挡导致的漏检与误检,提升复杂场景下的检测精度;最后,采用MPDIoU替代CIoU作为边界框回归损失函数优化模型定位性能,加快训练收敛速度。在丁基胶塞表面缺陷数据集上的实验表明,改进后的模型在mAP@0.5指标上达到83.7%,相较于原始的YOLOv8n模型提升5.5%,模型参数量仅为2.4 MB,计算量为6.2 GFLOPs,具备良好的轻量化特性。在GC10-DET数据集上的跨数据集验证结果表明,该方法具有较强的泛化性与鲁棒性,可满足工业领域的实际应用需求。

关键词: 丁基胶塞;表面缺陷检测;YOLOv8;注意力机制;多尺度卷积;损失函数

DOI:10.11907/tj.251429

扫描二维码阅读全文:

中图分类号:TP391.4

文献标识码:A

文章编号:1672-7800(2025)010-0190-06

Surface Defect Detection Algorithm of Butyl Rubber Stoppers Based on Improved YOLOv8

WU Fan^{1,2}, DING Xiaobo^{1,2}

(1. College of Computer and Information Technology, China Three Gorges University; 2. Hubei Province Engineering Technology Research Center for Construction Quality Testing Equipment, China Three Gorges University, Yichang 443002, China)

Abstract: Aiming at the high cost and low efficiency of manual defect detection in domestic butyl rubber stopper production lines, an improved surface defect detection algorithm based on YOLOv8 is proposed. Firstly, a multi-scale convolution module, FMSCov, was designed to enhance the network's ability to extract defect features at different scales, effectively addressing the issue of significant changes in product surface defect size; Secondly, the SEAM attention mechanism is introduced into the detection head to enhance the response of key features, alleviate missed and false detections caused by product stacking or occlusion, and improve detection accuracy in complex scenes; Finally, MPDIoU is used instead of CIoU as the bounding box regression loss function to optimize the localization performance of the model and accelerate the convergence speed of training. Experiments on the defect dataset on the surface of butyl rubber plugs show that the improved model performs well mAP@0.5 On the indicators, it reached 83.7%, which is 5.5% higher than the original YOLOv8n model. The model parameter size is only 2.4 MB, and the computational cost is 6.2 GFLOPs, demonstrating good lightweight characteristics. The cross dataset validation results on the GC10-DET dataset show that the method has strong generalization and robustness, and can meet the practical application needs in the industrial field.

Key Words: butyl rubber plug; surface defect detection; YOLOv8; attention mechanism; multi-scale convolution; loss function

0 引言

2023年,全球丁基胶塞市场销售额达到了11.06亿美

元,预计2029年将达到15.40亿美元,年复合增长率(CAGR)为4.75%(2023-2029)^[1]。随着医用胶塞产品使用制度越来越严格,产品质量与成本控制成为企业发展要解决的首要任务。深入行业调研发现,目前丁基胶塞产线的

收稿日期:2025-06-26

作者简介:吴凡(1997-),男,三峡大学计算机与信息学院硕士研究生,研究方向为深度学习、工业物联网技术;丁晓波(1974-),男,博士,三峡大学计算机与信息学院副教授,研究方向为物联网技术、人工智能应用技术。

缺陷检测方法主要依靠人工识别,时间成本较高,存在效率低下、错误率高及漏检等问题。为此,改变丁基胶塞产线检测质量和成本控制,对降低企业运作成本,提升效益具有重要意义。

随着计算机视觉技术的不断发展,为缺陷检测提供了新的解决方案。目前,计算机视觉下的缺陷检测主要分为传统缺陷检测、基于深度学习的缺陷检测。传统缺陷检测需人工定位缺陷目标,而深度学习检测方法既具备自动学习特征的能力,还表现出更强的抵抗外部干扰的能力,在准确性和效率方面更具优势^[2]。在表面缺陷检测领域,许多专家学者将深度学习应用于工业场景,例如制造业、半导体产业、电子制造、材料科学等^[3-6]。

基于深度学习的缺陷检测算法可分为以下两大类:

(1) 基于候选区域的两阶段算法。Song 等^[7,8]提出一种改进的 Faster R-CNN 方法,通过可变形卷积和 ROI(Region-of-Interest)对齐来提升模型对具有复杂和不规则形状的大尺度缺陷的检测性能。翁玉尚等^[9]通过改进的 Mask R-CNN 算法与 K-means II 聚类算法,提升带钢表面缺陷的检测速度和精度。Selamet 等^[10]结合 Faster R-CNN 和光照形状恢复(Shape From Shading, SFS)方法,提取表面特征来检测缺陷类型和位置。

(2) 基于回归的单阶段算法。针对两阶段目标检测模型复杂度高、参数众多、训练时间长及实时检测效果较差等问题,YOLO(You Only Look Once)舍弃了候选框的建议,采用回归的方法对目标进行分类和位置定位,经过单个阶段就可直接获得最终的检测结果,显著提升了检测速度^[11]。在工业场景环境中,窦智等^[12]对 YOLOv7 中的 ELAN 模块进行优化,以更好地提取钢板表面缺陷的重要特征信息,并引入 ACmix 注意力模块增强对钢板表面小尺寸缺陷的关注度。Wang 等^[13]以 YOLOv8 为基线提出一种基于多分支扩张卷积聚合与多域感知检测头的轻量级模型,在 NEU-DET 数据集上的平均精度达到 81.97%,参数量为 18.7 MB。王艳等^[14]在 YOLOv8 的 backbone 中采用 ADown 采样,并引入 WIoUv3 损失函数改进模型,在 PCB 板表面缺陷检测中的精度达到 98.37%。综上,YOLO 模型在工业场景下表面缺陷检测领域应用广泛,均达到了较高的检测精度。

目前,尚未发现针对丁基胶塞表面缺陷检测的研究文献,同时由于产线环境及企业发展规划,导致产线也没有应用相关技术进行胶塞缺陷检测。然而,本文在丁基胶塞表面缺陷检测试验中得出 YOLOv8 相较于其他模型精度更高,但存在特征提取能力不强等问题。

为此,提出一种基于 YOLOv8 改进的丁基胶塞表面缺陷检测算法,解决了产线上因人工识别造成的漏检、误检问题,为产线缺陷产品的检测提供了新的解决方案。首先,提出一种多尺度卷积模块(Fusion Multi-Scale Conv, FMSCConv),以应对产品表面缺陷的尺度变化问题,并在此

基础上改进 C2F 网络模块,增强了模型的多尺度特征提取能力;其次,在检测头中引入 SEAM 注意力机制,提升模型在遮挡情况下对目标的处理能力,减少了因重叠造成的误判,以进一步提升检测精度^[15];最后,通过 MPDIoU 替换 CIoU 损失函数以优化模型训练效果,加快收敛速度,提升整体检测性能^[16]。

1 改进 YOLOv8n 网络结构

2023 年,Ultralytics 发布了 YOLO 系列的最新版本 YOLOv8 框架,支持图像分类、物体检测及实例分割任务,最显著的改进之处在于其出色的可扩展性。相较于前代的不同之处在于,YOLOv8 结合了新的特性以提升性能和灵活性,并采用无锚结构以提升检测速度和准确性。其中,主干网(Backbone)依据 YOLOv5 中的 CSP 思想;颈部网络(Neck)参考 YOLOv7 的 ELAN 结构,但将 C3 模块更换为可增强卷积神经网络特征融合能力的 C2F 模块;将检测头(Head)更换为能将分类和检测分离的解耦头结构。

图 1 为改进后的 YOLOv8n 模型结构。首先,使用多尺度卷积模块 FMSCConv 改进 C2F 模块,增强多尺度特征提取能力;其次,引入 SEAM 注意力改进检测头,以提升目标遮挡检测能力;最后,使用 MPDIoU 替换原 CIoU 损失函数。




Fig. 1 Network structure of the improved YOLOv8 algorithm model

图 1 改进后的 YOLOv8 算法模型结构

1.1 融合多尺度卷积 FMSCConv 的 C2F 模块

为了解决丁基胶塞表面缺陷尺度变化导致的特征损失问题,从模块结构、性能指标和工业场景验证 3 个维度展开分析。同时,从特征提取方式、特征融合策略及计算复杂度对传统的 C2F 模块进行改进,参照 FasterNet 的思想提出多尺度卷积 FMSCConv,旨在提升模型的多尺度特征提取和融合能力^[17]。FMSCConv 的设计思想是通过多尺度特征提取和融合,增强模型对不同尺度特征的敏感性,提升图像特征表示能力。该模块通过逐层提取特征,使用不同

大小的卷积核(3×3、5×5、7×7)捕捉局部和全局信息,同时结合残差连接保留原始输入的特征。

FMSConv 相较于同类多尺度模块 MSCConv (YOLOv6) 和 C3_EMSCP (YOLOv8 改进), 提取分离的不同尺度特征以更高效地利用参数, 提升模型表现能力, 但不显著增加计算开销。图 2 为 C2F_FMS 结构。通过 FMSConv 优化 C2F 模块的具体操作为: 使用 FMSConv 替换 C2F 模块中的 Bottleneck 模块, 强调输出通道的多尺度特征, 以加强模块跨尺度特征提取能力。




Fig. 2 C2F_FMS structure

图 2 C2F_FMS 结构

1.2 SEAM 检测头

SEAM 模块是一种专为应对遮挡场景所设计的注意力机制, 将深度可分离卷积与残差连接相结合, 以提升特征表达能力并降低模型计算复杂度, 如图 3 所示^[16]。

首先, SEAM 通过逐通道的深度卷积操作, 能高效学习不同通道的特征; 其次, 逐点卷积能进一步整合各通道的




Fig. 3 SEAM attention mechanism structure

图 3 SEAM 注意力机制结构

特征, 以弥补单一通道间特征联系的不足, 并通过残差连接将卷积输出与输入特征融合, 确保信息流的连续性, 避免梯度消失问题; 最后, SEAM 模块利用两层全连接网络融合通道间的特征, 并通过指数函数处理融合结果, 将取值范围从 [0, 1] 扩展至 [1, e], 使遮挡区域与未遮挡区域的有效特征能够相互联系。在此基础上, SEAM 生成的注意力权重被用于与原始特征相乘, 从而突出模型对遮挡场景中重要特征的关注, 提升模型在复杂环境中的表现, 减少因遮挡导致的信息丢失。

综上, 通过 SEAM 注意力改进检测头可改善目标遮挡检测能力, 能有效捕捉遮挡目标与未遮挡目标之间的相关特征, 减少因遮挡导致的信息丢失, 从而提升检测鲁棒性。Detect_SEAM 结构如图 4 所示。




Fig. 4 Detect_SEAM structure

图 4 Detect_SEAM 结构

1.3 MPDIoU 损失函数

YOLOv8 原始模型使用 CIoU 损失函数, 在处理目标检测任务时虽能综合考虑预测框与真实框之间的 IoU、中心点距离和宽高比, 但在某些情况下无法准确反映宽高与置信度之间的真实差异, 这种缺陷会导致模型在本文数据集上出现收敛速度缓慢的情况, 增加漏检、误检现象。

为此, 本文使用 MPDIoU 替代 CIoU, 基于最小点距离的边界框相似度度量, 以更精确地反映预测框与真实框之间的空间关系和形状匹配程度。MPDIoU 的计算公式为:

$$MPD_{IoU} = IoU - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \quad (1)$$

$$d_1^2 = (x_1^B - x_1^A)^2 + (y_1^B - y_1^A)^2 \quad (2)$$

$$d_2^2 = (x_2^B - x_2^A)^2 + (y_2^B - y_2^A)^2 \quad (3)$$

$$L_{MPD_{IoU}} = 1 - MPD_{IoU} \quad (4)$$

式中: IoU 表示图形 A 与图形 B 的交并比; w, h 表示输入图像的宽度和高度; d_1, d_2 表示图形 A、B 左上角点之间和右下角点之间的欧氏距离; x_1^A, x_2^A 分别表示图形 A 左上和右下点的横坐标; x_1^B, x_2^B 分别表示图形 B 左上和右下点的横坐标; $y_1^A, y_2^A, y_1^B, y_2^B$ 同理表示纵坐标 (见图 5)。

2 实验结果与分析

2.1 实验环境

本文模型的训练基于 Ubuntu 22.04 操作系统, 12th Gen Intel(R) Core(TM) i7-12700H 处理器, 16 GB 内存和




Fig. 5 MPDIoU example

图5 MPDIoU 示例

NVIDIA RTX 3060 显卡,显存为 6 GB。模型使用框架为 Pytorch 2.0.0, Python 版本为 3.8.16, CUDA 版本为 11.8, 训练过程中使用随机梯度下降(Stochastic Gradient Descent, SGD)优化器,设置动量参数为 0.937,权重衰减参数为 0.000 5,初始学习率与最终学习率都被调整为 0.01。图像输入尺寸统一缩放为 640×640,每个批次的大小为 16,模型最多运行 500 个 epochs。

2.2 数据集

实验采用丁基胶塞产线上收集的产品表面缺陷数据集,并对数据集进行扩展,得到气泡(bubble)、污染(pollute)、剪伤(cut)、缺胶(short_molding)等 4 类表面常见缺陷的实验数据集,如图 7 所示(第一列分别为气泡和剪伤,第二列分别为污染和缺胶)。随后,通过旋转、引入噪声等数据增强方式扩充数据集,得到 1 988 张图片,并将数据集按照 4:1 的比例划分训练集和验证集。




Fig. 6 Partial defect images from the dataset

图6 数据集中部分缺陷图片

2.3 评价指标

在工业环境中,检测表面缺陷的任务除了要考虑精度外,还需优化检测效率与模型权重。为了综合评估模型的整体性能,采用精确率(Precision, P)、召回率(Recall, R)、

平均精度(Average Precision, AP)、均值平均精确率(Mean Average Precision, mAP)、帧率(FPS)、浮点运算次数(GFLOPs)和参数量(Params)等指标衡量模型性能。其中,平均精确率(mean average precision, mAP)是指在不同召回率下精度的平均值;mAP@0.5 是指当 IoU 值等于 0.5 时,对所有类的 AP 值求平均得到 mAP;FPS 表示模型每秒可检测到的图像数,值越高代表模型检测速度越快;GFLOPs 表示模型每秒可执行的浮点运算数量,值越高代表计算复杂度越高;参数量通常是指模型中可训练参数的个数,包括网络中的层数和各层的权重。

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

$$AP = \int_0^1 P(R) dR \quad (7)$$

$$mAP = \frac{\sum_{j=1}^S AP(j)}{S} \quad (8)$$

式中:TP(true positive)表示被判定为正例且正确的样本;FP(false negative)表示被判定为正例的负例样本;FN(false negative)表示被判定为负例的正例样本;S 表示所有类别的个数,本文 S=4。

2.4 实验结果

2.4.1 消融实验

为了验证各模块对模型的改进效果,在丁基胶塞表面缺陷数据集上进行消融实验,所有比较实验均在完全相同的训练策略下进行,包括固定的学习率、批量大小、训练轮数及数据增强方法,未对网络结构和训练流程进行任何调整,以确保实验结果的公平性和科学性。

表 1 为消融实验结果。其中,“√”表示在模型中加入相应改进模块后的性能表现。由此可知,①为基线模型;②为使用 C2F_FMS 替换原 YOLOv8 中 C2F 模块的模型,尽管 FPS 有所下降,但参数量、计算复杂度分别减少 0.4 MB、1.0 GB,主干网络的特征提取能力得到了有效提升,mAP@0.5 提升 2.7%;③为通过 SEAM 注意力机制对 YOLOv8 的检测头进行改进的模型,mAP@0.5 提升 2.9%,参数量和计算复杂度有所降低;④为使用 MPDIoU 替代 CIoU 损失函数的模型,在模型参数量、计算复杂度基本不变的情况下,mAP@0.5 提升 2.3%;⑤为使用 C2F_FMS 模块与 Detect_SEAM 检测头的模型,相较于②进一步降低了参数量和计算量,且 mAP@0.5 提升 1.4%;⑥为使用 C2F_FMS 模块与 MPDIoU 损失函数进行改进的模型,相较于②在参数量、计算量基本不变的情况下,mAP@0.5 提升 1.8%;⑦为使用 Detect_SEAM 检测头与 MPDIoU 损失函数相结合的模型,相较于①参数量、计算复杂度有所下降,mAP@0.5 提升 5%;⑧为将 C2F_FMS 模块、Detect_SEAM 检测头和 MPDIoU 损失函数相结合的模型,相较于①参数量、计算量均有所下降,mAP@0.5 提升 5.5%。


消融实验表明,每个改进点及改进点间的相互作用均对模型产生了积极影响,不仅在检测精度方面取得了显著效果,还降低了模型参数量和计算复杂度。

Table 1 Results of ablation experiment

表 1 消融实验结果

Methods	C2F_F	Detect_	MPDIoU	mAP@	Params/	FLOPs/	FPS
	MS	SEAM		0.5	MB	GB	
①				0.782	3.0	8.2	172.4
②	√			0.809	2.6	7.2	126.6
③		√		0.811	2.8	7.1	153.8
④			√	0.805	3.0	8.2	170.2
⑤	√	√		0.823	2.4	6.2	143.6
⑥	√		√	0.827	2.6	7.2	124.0
⑦		√	√	0.832	2.8	7.1	152.1
⑧	√	√	√	0.837	2.4	6.2	142.4

图 7 为原模型 YOLOv8n 和改进模型在数据集上的检测结果。由此可知,改进后的模型在大部分局部缺陷的检测精度上都优于原模型。具体地:第一行中,两种模型均能准确识别出所有缺陷,且改进模型的锚框置信度相较于 YOLOv8n 模型更高;在第二、三、四行的场景中,YOLOv8n 均出现了不同程度的漏检现象。



(a) YOLOv8n

(b) 改进算法

Fig. 7 Example of partial test results

图 7 部分检测结果示例

2.4.2 比较实验

将本文模型与 SSD、Faster-RCNN、YOLOv3、Yolov3-tiny、YOLOv5s、YOLOv7-tiny、YOLOv7 和 YOLOv8n, 在构建的丁基胶塞表面缺陷数据集上进行测试,实验结果如表 2 所示。由此可知,现有 SSD 检测精度低、速度慢;Faster-RCNN 虽然检测精度较高,但检测速度极低,FPS 仅为 6.5;

YOLOv3、YOLOv7 的推理速度慢,参数量和计算复杂度较大,不适合在移动设备上部署;YOLOv3-tiny、YOLOv7-tiny 和 YOLOv5s 模型较轻量,但检测精度不足;本文模型在 mAP@0.5、mAP@0.5:95 的精度分别为 83.7%、47.6%,参数量为 2.4 MB,计算量为 6.2 GB。

综上,本文所提模型相较于其他主流模型而言,在检测精度、参数量和计算量 3 个方面均表现最佳,且具备较高的实时性。

Table 2 Comparative experimental results

表 2 比较实验结果

Methods	mAP@0.5	mAP@0.5:	Params/MB	FLOPs/GB	FPS
		95			
SSD	0.737	0.334	25.1	88.24	29.0
Faster-RCNN	0.750	0.386	99.2	123.0	6.5
YOLOv3-tiny	0.561	0.223	8.7	12.90	172.3
YOLOv3	0.757	0.395	61.5	154.60	33.7
YOLOv5s	0.760	0.394	7.0	15.80	122.0
YOLOv7-tiny	0.728	0.362	6.0	13.10	81.3
YOLOv7	0.759	0.397	36.5	103.20	34.2
YOLOv8n	0.782	0.450	3.0	8.20	172.4
Our	0.837	0.476	2.4	6.20	142.4

2.4.3 鲁棒性验证

为了验证本文算法在鲁棒性方面的优势,在钢表面缺陷数据集(GC10-DET)上进行实验,比较基线算法与本文算法的性能差异^[18]。GC10-DET 是一个真实的行业数据集,包含 2 294 张大小为 2 048×1 000 的灰度图像,涵盖了 10 种类型的表面缺陷:冲孔、焊缝、新月形缝隙、水斑、油斑、丝斑、夹杂物、轧坑、折痕和腰部折痕。本文按照 4:1 的比例将数据集划分为训练集和验证集,并在实验设置上与上述比较实验保持一致,实验结果如表 3 所示。

Table 3 Research on robustness on GC10-DET dataset

表 3 在 GC10-DET 数据集上的鲁棒性研究

Model	mAP@0.5	Params/MB	FLOPs/GB	FPS
YOLOv8	0.673	3.0	8.2	99.0
Our	0.686	2.4	6.2	86.6

由表 3 可知,在 GC10-DET 数据集上,本文算法相较于基线算法,在 mAP@0.5 提升 1.3%,参数量、计算量分别减少 0.6 MB、2.0 GB。虽然,FPS 相较于基线降低了 12.4,但仍满足实时性需求。综上,本文算法在鲁棒性方面优势明显,在性能和计算效率上取得了不错的平衡。

3 结语

本文提出一种基于 YOLOv8n 的改进型轻量化目标检测算法,旨在提升丁基胶塞表面缺陷检测的精度与效率。首先,引入多尺度卷积模块 FMSCConv,并对 C2F 结构进行优化,增强网络对多尺度特征的提取能力,以应对缺陷目标尺度变化显著的问题;其次,将 SEAM 注意力机制嵌入检测头,增强模型对遮挡、重叠缺陷的特征响应和在复杂场景下的判别性能,降低误检、漏检率;最后,采用 MPDIoU

替代 CIoU,作为边界框回归损失函数,不仅提升了定位精度,还加快了模型收敛速度,进一步优化了模型训练稳定性与检测可靠性。

在自建的丁基胶塞表面缺陷数据集上的结果表明,本文方法相较于原始 YOLOv8n 模型,在显著降低模型复杂度的同时检测性能更高,模型参数量减少 20.0%,计算量(FLOPs)降低 24.4%,mAP@0.5 提升 5.5%。同时,在公开数据集 GC10-DET 上的跨数据集实验表明,所提方法具备良好的泛化能力与鲁棒性,适用于工业视觉检测的实际应用场景。

未来,将致力于进一步提升模型的实用性。一方面,引入更多样化的工业缺陷数据集以增强模型泛化能力;另一方面,探索网络剪枝与知识蒸馏等模型压缩技术,进一步降低计算开销、提升推理速度,推动算法在边缘设备上高效部署。

参考文献:

- [1] DONG P C. Research on quality pre analysis of butyl rubber stoppers for intelligent manufacturing production lines [D]. Beijing: Beijing Institute of Technology, 2021.
董鹏程. 面向智能制造生产线的丁基胶塞质量预分析研究[D]. 北京: 北京理工大学, 2021.
- [2] ZHANG Y T, HUANG D Q, WANG D W, et al. Review on research and application of deep learning-based target detection algorithms [J]. Computer Engineering and Applications, 2023, 59(18): 1-13.
张阳婷, 黄德启, 王东伟, 等. 基于深度学习的目标检测算法研究与应用综述[J]. 计算机工程与应用, 2023, 59(18): 1-13.
- [3] LI W, YAO X M, ZHANG P C, et al. Research on improved YOLO-V7 steel surface defect detection algorithm [J/OL]. Mechanical Science and Technology for Aerospace Engineering, 2025-09-23. <https://doi.org/10.13433/j.cnki.1003-8728.20230368>.
李伟, 姚小敏, 张鹏超, 等. 改进的 YOLO-V7 钢材表面缺陷检测算法研究[J/OL]. 机械科学与技术, 2025-09-23. <https://doi.org/10.13433/j.cnki.1003-8728.20230368>.
- [4] LIANG J X, XU C D, ZHANG H. Ultrasonic testing of internal defects of composite insulator silicone rubber for high voltage transmission lines [J/OL]. Insulating Materials, 2023-12-31. https://kns.cnki.net/kcms2/article/abstract?v=rr6VKxMbACpM0F3JB2tUAzhbp9N4jBgvt529ger4Yep8nyvVydSrxEvVUHutlNah0N8eKujzmVJwBycwSfjX-0ySnFGIDHIOPe-zyZ2tBAnMHbMee23lcP_o9QGH_VIshuFZ0grvVJuuTwGl-yROx0UYY2QAEUhqKNqJjrjclNCUUh3SHgkA== &uniplatform=NZKPT&language=CHS.
梁进祥, 徐偲达, 张虎. 高压输电线路复合绝缘子硅橡胶内部缺陷超声检测[J/OL]. 绝缘材料, 2023-12-31. https://kns.cnki.net/kcms2/article/abstract?v=rr6VKxMbACpM0F3JB2tUAzhbp9N4jBgvt529ger4Yep8nyvVydSrxEvVUHutlNah0N8eKujzmVJwBycwSfjX-0ySnFGIDHIOPe-zyZ2tBAnMHbMee23lcP_o9QGH_VIshuFZ0grvVJuuTwGl-yROx0UYY2QAEUhqKNqJjrjclNCUUh3SHgkA== &uniplatform=NZKPT&language=CHS.
- [5] WANG H T, ZHANG S, ZHANG C Y. Lightweight PCB defect detection based on YOLOv5 [J]. Radio Engineering, 2022, 52(11): 2094-2100.
王恒涛, 张上, 张朝阳, 等. 基于 YOLOv5 的轻量化 PCB 缺陷检测[J]. 无线电工程, 2022, 52(11): 2094-2100.
- [6] PENG H K, CHEN Q Y, HAN L, et al. Gas PE pipeline weld defect detection based on deep learning [J]. Semiconductor Optoelectronics, 2023, 44(6): 942-949.
彭惠奎, 陈芊一, 韩露, 等. 基于深度学习的燃气 PE 管道焊缝缺陷检测[J]. 半导体光电, 2023, 44(6): 942-949.
- [7] SONG C, CHEN J, LU Z, et al. Steel surface defect detection via deformable convolution and background suppression [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-9.
- [8] GIRSHICK R. Fast R-CNN [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2015: 1440-1448.
- [9] WENG Y S, XIAO J Q, XIA Y. Strip surface defect detection based on improved mask R-CNN algorithm [J]. Computer Engineering and Applications, 2021, 57(19): 235-242.
翁玉尚, 肖金球, 夏禹. 改进 Mask R-CNN 算法的带钢表面缺陷检测[J]. 计算机工程与应用, 2021, 57(19): 235-242.
- [10] SELAMET F, CAKAR S, KOTAN M. Automatic detection and classification of defective areas on metal parts by using adaptive fusion of faster R-CNN and shape from shading [J]. IEEE Access, 2022, 10: 126030-126038.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [12] DOU Z, HU C G, LI Q H, et al. Improved YOLOv7 algorithm for small sample steel plate surface defect detection [J]. Computer Engineering and Applications, 2023, 59(23): 283-292.
窦智, 胡晨光, 李庆华, 等. 改进 YOLOv7 的小样本钢板表面缺陷检测算法[J]. 计算机工程与应用, 2023, 59(23): 283-292.
- [13] WANG J, XU P, LI L, et al. DAssd-Net: a lightweight steel surface defect detection model based on multi-branch dilated convolution aggregation and multi-domain perception detection head [J]. Sensors, 2023, 23(12): 5488-5509.
- [14] WANG Y, LUO J, TAO J, et al. Defect detection of printed circuit boards based on YOLOv8-PCB [J]. Laser & Optoelectronics Progress, 2025, 62(4): 87-96.
王艳, 罗健, 陶金, 等. 基于 YOLOv8-PCB 的印制电路板缺陷检测[J]. 激光与光电子学进展, 2025, 62(4): 87-96.
- [15] YU Z, HUANG H, CHEN W, et al. Yolo-facev2: a scale and occlusion aware face detector [J]. Pattern Recognition, 2024, 155: 110714.
- [16] MA S, XU Y. MPDIoU: a loss for efficient and accurate bounding box regression [DB/OL]. <https://arxiv.org/abs/2307.07662>.
- [17] CHEN J, KAO S, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021-12031.
- [18] LYU X, DUAN F, JIANG J, et al. Deep metallic surface defect detection: the new benchmark and detection network [J]. Sensors, 2020, 20(6): 1562-1577.

(责任编辑:刘嘉文)