

王岳继, 吴瑞瑾, 李超, 等. 融合归一化 Wasserstein 距离损失的轻量化金属表面缺陷分割模型[J]. 智能计算机与应用, 2026, 16(2): 128-133. DOI:10.20169/j.issn.2095-2163.25091002

融合归一化 Wasserstein 距离损失的轻量化金属表面缺陷分割模型

王岳继^{1,2}, 吴瑞瑾^{1,2}, 李超^{1,2}, 冯夫健^{1,2}

(1 贵州民族大学 数据科学与信息工程学院, 贵阳 550025;

2 贵州民族大学 贵州省模式识别与智能系统重点实验室, 贵阳 550025)

摘要: 针对金属表面缺陷存在对比度低、尺度变化大, 导致现有模型检测精度低的问题, 提出一种基于深度学习的金属表面缺陷分割模型。首先, 在模型中采用归一化 Wasserstein 距离损失函数 NWD loss, 缓解边界框不重叠场景下的误判问题。其次, 在特征融合时引入 VoVGSCSP 轻量化模块, 在降低模型计算复杂度的同时, 有效保持缺陷特征的表达能。最后, 在 NEU-Seg 数据集上的实验结果表明, WNet 的检测平均精度达 93.9%、分割平均精度达 91.2%, 相较于基础模型分别提升了 0.6% 和 0.2%; 同时, 模型参数量与计算量分别降低 11% 和 16.7%, 兼顾检测精度与运行效率, 为工业质量控制领域的金属表面缺陷检测提供了高效解决方案。

关键词: 深度学习; 缺陷分割; 轻量化; 损失函数; 特征融合

中图分类号: TP391.4

文献标志码: A

文章编号: 2095-2163(2026)02-0128-06

Lightweight metal surface defect segmentation model integrating normalized Wasserstein distance loss

WANG Yueji^{1,2}, WU Ruijin^{1,2}, LI Chao^{1,2}, FENG Fujian^{1,2}

(1 School of Data Science and Information Engineering, Guizhou Minzu University, Guiyang 550025, China; 2 Key Laboratory of Pattern Recognition and Intelligent System of Guizhou Province, Guizhou Minzu University, Guiyang 550025, China)

Abstract: Aiming at the problem that metal surface defects have low contrast and large scale variation, which results in low detection accuracy of existing models, a metal surface defect segmentation model based on deep learning is proposed. Firstly, the Normalized Wasserstein Distance loss function (NWD loss) is adopted in the model to alleviate the misjudgment problem in scenarios where bounding boxes do not overlap. Secondly, the lightweight VoVGSCSP module is introduced during feature fusion, which reduces the computational complexity of the model while effectively maintaining the expressive ability of defect features. Finally, experimental results on the NEU-Seg dataset show that the proposed WNet model achieves a mean Average Precision (mAP) of 93.9% for detection and 91.2% for segmentation, which are 0.6 and 0.2 percentage points higher than those of the base model, respectively. Meanwhile, the number of model parameters and computational load are reduced by 11% and 16.7%, respectively. The model balances detection accuracy and operational efficiency, providing an efficient solution for metal surface defect detection in the field of industrial quality control.

Key words: deep learning; defect segmentation; lightweight; loss function; feature fusion

0 引言

随着国内工业产业的快速发展, 对金属产品质

量需求的不断增长, 使得金属产品表面缺陷引发的一系列问题愈发严峻。在生产和加工过程当中, 金属产品表面会不可避免地产生裂纹、划痕、斑块等缺

基金项目: 贵州省科技计划项目 (QKHJCZK2022YB195, QKHJCZK2023YB143, QKHJCZK2022YB197); 贵州省教育厅自然科学研究项目 (QJJ2022015, QJJ2023061, QJJ2023012, QJJ2022047); 贵州民族大学基金科研项目 (GZMUZK [2023] YB04, GZMUZK [2023] YB14); 贵州省模式识别与智能系统重点实验室开放课题 (GZMUKL [2022] KF01)。

作者简介: 王岳继 (2000—), 男, 硕士研究生, 主要研究方向: 工业检测; 吴瑞瑾 (2000—), 男, 硕士研究生, 主要研究方向: 图像抠图; 李超 (2001—), 男, 硕士研究生, 主要研究方向: 工业检测。

通信作者: 冯夫健 (1986—), 男, 博士, 教授, 硕士生导师, 主要研究方向: 智能计算, 微计算及其应用。Email: fujian_feng@gzmu.edu.cn。

收稿日期: 2025-09-10

陷^[1]。因此,金属产品表面缺陷检测成为产品生产的重要环节。

近年来,随着深度学习技术的快速发展,基于计算机视觉的深度学习检测方法在工业缺陷检测领域展现出显著优势。在铁轨缺陷^[2]、钢带缺陷^[3]等领域已取得了可观进展。例如,汤华椿等学者^[4]针对气门边缘关键点难以精准检测问题,设计了一种基于亚像素边缘搜索算法,在检测精度和稳定性上均达到了工业要求。罗太维等学者^[5]提出基于 YOLOv8 的钢材表面缺陷检测模型 GL-YOLO,在钢材表面缺陷检测中具有较好的综合性能。王岳继等学者^[6]提出了一种基于改进 YOLOv8 的自适应权重下采样带钢表面缺陷检测模型,有效地提升了模型对钢材表面缺陷的检测精度。上述方法虽然能有效定位缺陷,对金属表面缺陷的检测精度和检测速度取得了令人满意的效果。然而,此类方法仅能定位缺陷的大概位置,无法解析精确轮廓,难以满足计算金属表面缺陷面积的需求。

因此,许多学者围绕缺陷分割方法展开研究。基于深度学习的缺陷分割方法可以分为语义分割方法和实例分割方法。其中,FCN^[7]、DeepLabv3+^[8]和 U-Net^[9]等语义分割方法可实现像素级缺陷分割,有效捕捉缺陷的轮廓语义信息。例如,Yin 等学者^[10]提出了一种用于工业表面缺陷语义分割的方法,提出全局和局部特征融合模块,解决了类内分割结果不一致的问题。Li 等学者^[11]提出了一种由粗到精生成分割结果的铁路缺陷分割方法,不仅能够充分利用低级特征信息,还能降低模型计算复杂度。Zhou 等学者^[12]提出了 TR-PCB 分割框架,消除了 PCB 图像中缺陷区域阴影和照明不均匀的问题。

然而,语义分割方法缺乏区分单个缺陷实例的能力,分割效果难以达到预期水平。实例分割方法,如 Mask R-CNN^[13]、Yolact^[14]和 SOLO^[15]等方法集成了目标检测和语义分割技术。这些方法不仅能提取检测对象的形状和大小等关键信息,准确定位缺陷,还能生成完整、精确的缺陷分割轮廓掩膜。例如,Xu 等学者^[16]提出了一种基于 Mask R-CNN 的隧道缺陷检测方法,解决人工特征提取方法在隧道缺陷检测方面效果不佳的问题。王九鑫等学者^[17]提出了改进 YOLOV5 的金属表面缺陷分割方法,有效地提升模型的检测精度。

然而,金属表面缺陷类型复杂多样,缺陷对比度低、尺度变化大,给分割模型准确识别缺陷带来了挑战。针对上述问题,提出了一种融合归一化 Wasserstein

距离损失的轻量化金属表面缺陷分割模型 WLNet,在减少模型参数的同时增强了对高阶特征的识别和交互能力。

1 WLNet 模型结构

由于金属表面在复杂背景下缺陷类型多样,缺陷对比度低、尺度变化大,导致模型检测精度低的问题,提出了融合归一化 Wasserstein 距离损失的轻量化金属表面缺陷分割模型 WLNet,如图 1 所示。WLNet 由 Backbone、Neck 和 SegHead 三个部分组成。其中,本文在 WLNet 模型中使用了 NWDloss 损失函数,并在 Neck 中的 Semantic Scattering 部分引入了 VoVGSCSP 模块,在图 1 中用红色虚线框标注。

1.1 VoVGSCSP 模块

为了降低模型计算复杂度和网络结构的复杂性,本文在 WLNet 模型的 Neck 中的 Semantic Scattering 部分引入了 VoVGSCSP 模块,其结构如图 2 所示。

VoVGSCSP 模块由轻量级的 VoVNet^[18]与 CSPNet^[19]构成,VoVGSCSP 模块结构如图 2 所示。该网络结合了一次性聚合技术和 GSBottleneck,可以有效地融合不同阶段的特征图之间的信息。GSBottleneck 通过堆叠多个 GSConv 提高网络处理能力,增强特征的非线性表达并改善信息的重复使用。GSConv 可在不同通道之间进行信息交换和特征重组,重用特征语义信息。

GSConv 结构如图 3 所示,首先利用 1×1 Conv 操作处理通道数为 C_1 的输入特征图,对特征图进行特征降维,将通道数降至 $C_2/2$ 。随后,利用深度可分离卷积 DWConv 处理各个通道特征,这个过程中通道数保持不变,通道数仍然为 $C_2/2$ 。接下来,将 1×1 Conv 操作处理后的特征图与深度可分离卷积处理后的特征图通过 Concat 操作拼接起来。最后利用 Shuffle 混洗操作对所有特征通道进行重新排列,输出通道数为 C_2 的特征信息。增强语义信息,提升特征表征能力。

1.2 NWD loss 损失函数

由于基于 IoU 的损失函数对小目标尺寸变化敏感,当目标位置发生偏移时,IoU 易大幅波动致样本误判,常出现边界框不重叠或相互包含情况,IoU 对此无法有效度量目标在图像空间的定位偏差。针对上述问题,引入 NWD loss^[20]用以取代传统基于 IoU 的损失函数,NWD loss 对于小目标位置偏差敏感度低,可增强模型对小目标缺陷的定位性能。

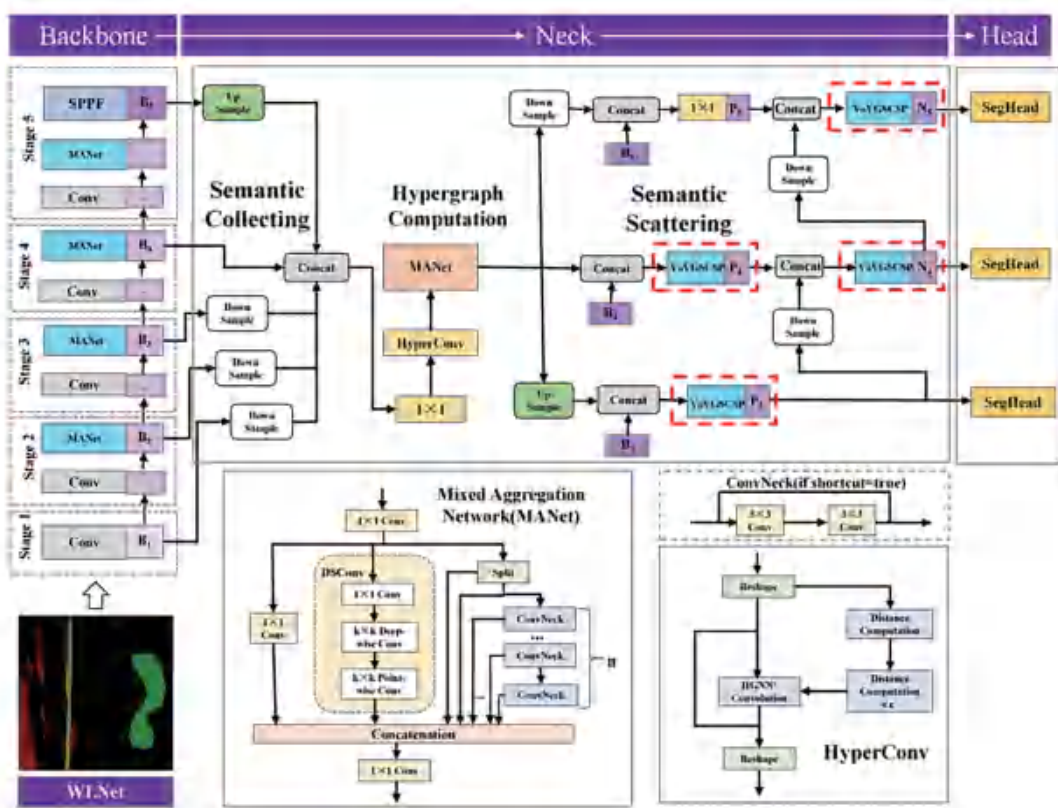


图 1 WLNet 模型框架图

Fig. 1 Framework diagram of the WLNet model

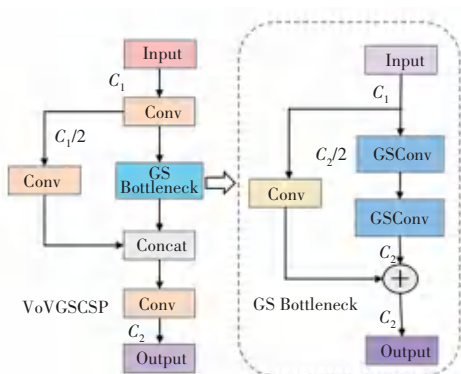


图 2 VoVGSCSP 结构图

Fig. 2 Structure diagram of VoVGSCSP




图 3 GSConv 结构图

Fig. 3 Structure diagram of GSConv

为了更好地为边界框中的缺陷与背景像素分配不同的权重, NWD loss 将真实框和预测框建模为二维高斯分布, 将边界框和框之间的相似性转换为 2

个高斯分布之间的分布距离。然后利用归一化 Wasserstein 距离来计算边界框和预测框预测之间的相似性。旨在将最高的权重值分配给框中的缺陷中心像素, 对于缺陷中心像素至边界权重依次递减。从而增强模型对缺陷的特征提取能力。具体而言, 对于中心坐标为 (c_x, c_y) , 宽度和高度分别为 w 和 h 的水平边界框 $R = (c_x, c_y, w, h)$ 。2D 高斯分布的概率密度函数的定义公式为:

$$f(x | \mu, \Sigma) = \frac{\exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right)}{2\pi |\Sigma|^{\frac{1}{2}}} \quad (1)$$

其中, x 表示像素坐标; $\mu = \begin{pmatrix} c_x \\ c_y \end{pmatrix}$ 表示均值向

量; $\Sigma = \begin{pmatrix} \omega^2 & 0 \\ 0 & h^2 \end{pmatrix}$ 表示协方差矩阵。

接下来, 又利用归一化 Wasserstein 距离来计算边界框 A 和 B 之间的高斯分布距离, 将边界框 $A = (c_x, c_y, \omega, h)$ 和 $B = (c_x, c_y, \omega, h)$ 建模为 N_a

和 N_b 。则其度量距离计算公式如下所示:

$$W_2^2(N_a, N_b) = \left\| \left(\begin{matrix} \omega_a x_a, cy_a, \frac{\omega_a}{2}, \frac{h_a}{2} \mathbf{1}^T \\ \omega_b x_b, cy_b, \frac{\omega_b}{2}, \frac{h_b}{2} \mathbf{1}^T \end{matrix} \right) \right\|_2^2 \quad (2)$$

然而, $W_2^2(N_a, N_b)$ 属于距离度量,并且不能直接用作相似性度量,因此使用其指数形式进行归一化,并获得归一化 Wasserstein 距离计算公式为:

$$\text{NWD}(N_a, N_b) = \exp\left(-\frac{\sqrt{W_2^2(N_a, N_b)}}{C}\right) \quad (3)$$

其中, C 表示与数据集相关的常数。因此,基于 NWD 的回归损失函数为:

$$l_{\text{NWD}} = 1 - \text{NWD}(N_a, N_b) \quad (4)$$

最终损失函数为:

$$l_{\text{total}} = \alpha \cdot \text{IoU}_{\text{loss}} + (1 - \alpha) \cdot l_{\text{NWD}} \quad (5)$$

其中,“ \cdot ”表示相乘, α 表示 NWD 损失函数的权重,本文将其设置为 0.6; IoU_{loss} 表示位置损失函数。

2 实验设置与结果分析

2.1 实验设置

为了验证研究中提出的 WNet 的有效性,在东

北大学公开数据集 NEU-Seg^[21]上进行实验。其中, NEU-Seg 数据集包含 4 432 张具有掩码标签的图像,具有夹杂物(Inclusion)、斑块(Patches)和划痕(Scratches)三种不同类型的缺陷。数据集按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集。

实验中的所有模型均在 Linux 操作系统平台上实现。其中,实验硬件环境为 A100-PCIE-40 GB, 40536 MiB,编程语言为 Python,并以 Torch-2.0.1 作为深度学习框架。

2.2 评价指标

本文使用精度(P)、召回率(R)、平均准确率均值(mAP)作为评价指标衡量模型的分割性能,使用浮点数操作(GFLOPs)和参数量(Params)作为度量指标衡量模型对计算资源的消耗情况。

2.3 消融实验

为了验证 WNet 中所有集成组件之间的相互影响以及有效性,本文在 NEU-Seg 数据集上对 WNet 进行消融实验评估。本文将消融实验分为 3 组。第 1 组表示基线模型,第 2 组表示在基础模型中添加 NWD Loss,第 3 组实验表示在基础模型中添加 NWD Loss 和 VoVGSCSP 模块,实验结果见表 1。

表 1 消融实验结果

Table 1 Results of ablation experiment

Models	Box/%				Mask/%				Params	GFLOPs
	P	R	mAP50	mAP50 : 95	P	R	mAP50	mAP50 : 95		
1	90.1	88.5	93.3	70.4	88.4	87.2	91.0	53.6	14.17	47.8
2	90.5	90.5	93.6	69.4	89.2	88.8	91.1	53.8	14.17	47.8
3	92.9	88.9	93.9	70.5	91.5	86.8	91.2	54.1	12.57	39.8

由表 1 可知,实验结果展示了 WNet 在整合各组件模块之后各指标的改善情况。实验 2 和实验 3 分别展示了各组件模型的实验结果,每一组实验均在实验 1 的基础上获得了不同程度的改善。具体来说,对于实验 2,在 Box 预测分支,模型的 P 、 R 、mAP50 指标均获得不同程度的提升;在 Mask 预测分支,模型的 P 、 R 、mAP50 和 mAP50 : 95 指标分别提升了 0.8%、1.6%、0.1%和 0.2%,验证了 NWD Loss 损失函数在 WNet 中的有效性。对于实验 3,模型的参数量约降低了 11%,计算量约降低 16%,Box 预测分支中的 mAP50 提升了 0.6%,Mask 预测分支中的 mAP50 提升了 0.2%,验证了 VoVGSCSP 模块在 WNet 中的有效性,且模型的参数量和计算量分别降低了 11%和 16.7%。综上所述,所提出的 WNet 模型不仅降低模型计算量与参数量,还在一定程度上提升了对金属表

面缺陷的检测与分割性能。

2.4 模型 WNet 与经典模型对比试验

为了进一步评估 WNet 的检测与分割性能,本文将所提出的 WNet 模型与经典模型 MaskRCNN、SOLO、SOLOV2、YOLACT、Mamba-YOLO 和 YOLO12s 在 NEU-Seg 数据集上进行实验,以验证 WNet 模型的有效性和可行性。对比实验结果见表 2。

由表 2 可知,WNet 在 Box 与 Mask 预测分支均取得了最好的结果。尽管 WNet-L 的计算量大于 YOLACT,但在分割精度上远超 YOLACT。其中,与主干网络为 ResNet50 的 YOLACT 相比,mAP50 和 mAP50 : 95 分别提升了 23.7%和 22.7%;与主干网络为 ResNet101 的 YOLACT 相比,mAP50 和 mAP50 : 95 分别提升了 23.6%和 22.0%。与最经典的实例分割模型 Mask-RCNN 相比,分割精度分别提升了 20.4%、

20.7%和 16.7%、19.2%。与 SOLO 相比, mAP50 和 mAP50 : 95 则分别提升了 11.5% 和 13.8%。与 SOLOV2 相比, mAP50 和 mAP50 : 95 分别提升了

10.9%、10.9%和 10.1%、8.8%。与经典实例分割模型对比试验表明, WNet 在实例分割效果上远超经典模型, 进一步表明 WNet 的优越性。

表 2 所提方法与经典模型对比试验

Table 2 Comparative experiments between WNet-L and classic models

Models	Backbone	Box/%		Mask/%		Model Efficiency Metrics	
		mAP50	mAP50 : 95	mAP50	mAP50 : 95	Prams	GFLOPs
Mask-RCNN	ResNet50	80.5	48.6	72.9	37.4	43.98	186.00
Mask-RCNN	ResNet101	82.5	50.4	74.7	38.9	62.97	233.00
SOLO	ResNet50	—	—	81.8	44.3	36.12	238.00
SOLOV2	ResNet50	—	—	82.4	47.2	46.24	178.00
SOLOV2	ResNet101	—	—	83.2	49.3	68.37	109.00
YOLOACT	ResNet50	76.1	43.7	69.6	35.3	34.74	61.61
YOLOACT	ResNet101	75.9	45.0	69.7	36.1	53.73	84.87
Mamba-YOLO	CSPNet	91.3	61.6	87.8	48.4	56.33	175.90
YOLO12s	CSPNet	79.2	44.5	76.6	38.0	22.41	122.40
WNet	—	93.9	70.5	91.2	54.1	12.57	39.80

2.5 可视化分析

为了能够更加直观展现 WNet 对各类缺陷的分割效果, 将基线模型与 WNet 对各类缺陷的分割效果进行可视化展示。效果如图 4 所示。

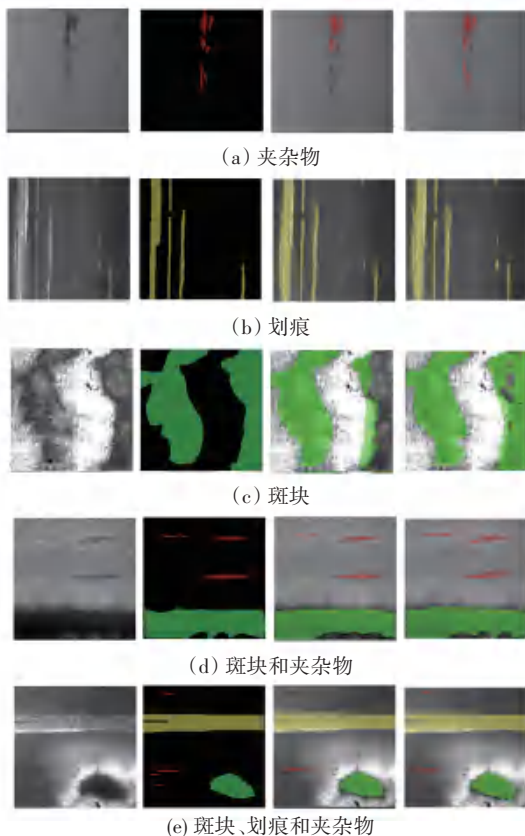


图 4 基线模型与 WNet 对各类缺陷的分割效果

Fig. 4 Segmentation results of baseline model and WNet for various defect types

图 4 (a) ~ (e) 中, 从左至右依次为: Original、Labels、Baseline 和 WNet。由图 4 可知, 所提出的 WNet 在各类缺陷中均取得了最好的分割效果。由图 4 中可以看出, 基线模型对夹杂物和斑块这 2 种缺陷的分割效果明显存在欠分割的问题, 所提出的 WNet 的分割结果更加接近于缺陷的标签图, 表明 WNet 具有较好的分割性能。当一张图中包含多种缺陷时, WNet 仍然可以准确地分割出缺陷所在位置, 并且在一些细节部分处理效果优于基线模型。例如, 图 4 (d) 中包含着斑块和夹杂物两种缺陷, 但基线模型在对于斑块这种缺陷的细节处理效果不如 WNet。图 4 (e) 中包含着斑块、夹杂物和划痕三种缺陷, 从图 4 中可以明显看出, 基线模型对夹杂物这种缺陷存在明显的欠分割情况, 而 WNet 的分割效果明显更加接近缺陷标签。综上所述, 所提出的 WNet 具有良好的分割效果, 尤其是对不规则缺陷的分割效果明显优于基础模型, 进一步验证了所提出模型 WNet 在解决金属表面不规则缺陷特征难以捕获问题的优势。

3 结束语

本文针对现有模型对金属表面缺陷模型检测精度低的问题, 提出融合归一化 Wasserstein 距离损失的轻量化金属表面缺陷分割模型。首先, 在预测阶段进一步采用归一化 Wasserstein 距离损失函数 NWD loss, 缓解边界框不重叠场景下的误判问题。其次, 在特征融合阶段引入 VoVGSCSP 轻量化模

块,在降低模型计算复杂度的同时,有效保持缺陷特征的表达能。最后,在 NEU-Seg 数据集上验证了 WNet 模型的有效性,兼顾检测精度与运行效率,为工业质量控制领域的金属表面缺陷检测提供了高效解决方案。未来将考虑将模型部署到终端设备中,从而将模型应用至工业生产领域。

参考文献

- [1] TANG Bo, CHEN Li, SUN Weilin, et al. Review of surface defect detection of steel products based on machine vision [J]. IET Image Processing, 2023, 17 (2): 303-322.
- [2] HUANG Liming, GONG Aojun. Surface defect detection for no-service rails with skeleton-aware accurate and fast network [J]. IEEE Transactions on Industrial Informatics, 2023, 20 (3): 4571-4581.
- [3] LIU Li, FENG Xuefeng, LI Feng, et al. Surface defect detection of industrial components based on improved YOLOv5s [J]. IEEE Sensors Journal, 2024, 24 (15): 23940-23950.
- [4] 汤华椿,谭棉,王前,等. 基于亚像素边缘搜索的气门几何参数检测 [J]. 智能计算机与应用,2024, 14 (1): 49-55.
- [5] 罗太维,汪小梅,李志玲,等. 基于多尺度特征融合的钢材表面缺陷检测 [J]. 智能计算机与应用,2024, 14 (6): 197-200.
- [6] 王岳继,罗太维,吴瑞瑾,等. 基于自适应权重下采样的带钢表面缺陷检测 [J]. 工业控制计算机,2025, 38 (3): 88-89.
- [7] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39 (4): 640-651.
- [8] CHEN L C, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham; Springer, 2018: 801-818.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]// Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham; Springer, 2015: 234-241.
- [10] YIN Zhenyu, QIN Li, HAN Guangjie, et al. DDSNet: Deep dual-branch networks for surface defect segmentation [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 2525316.
- [11] LI Mingxu, PENG Bo, LIU Jian, et al. RBNet: An ultrafast rendering-based architecture for railway defect segmentation [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2512808.
- [12] ZHOU Jiaming, ZHU Qing, WANG Yaonan, et al. Toward TR-PCB bubble detection via an efficient attention segmentation network and dynamic threshold [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2506712.
- [13] HE Kaiming, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ; IEEE, 2017: 2961-2969.
- [14] BOLYA D, ZHOU Chong, XIAO Fanyi, et al. Yolact: Real-time instance segmentation [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ; IEEE, 2019: 9157-9166.
- [15] WANG Xinlong, KONG Tao, SHEN Chunhua, et al. Solo: Segmenting objects by locations [C]// Proceedings of the 16th European Conference on Computer Vision. Cham; Springer, 2020: 649-665.
- [16] XU Yingying, LI Dawei, XIE Qian, et al. Automatic defect detection and segmentation of tunnel surface using modified Mask R-CNN [J]. Measurement, 2021, 178: 109316.
- [17] 王九鑫,吴鑫,杜雨蓉,等. 基于改进 YOLOv5 的金属表面缺陷分割 [J]. 组合机床与自动化加工技术, 2024 (5): 171-176.
- [18] LEE Y, HWANG J W, LEE S, et al. An energy and GPU-computation efficient backbone network for real-time object detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway, NJ; IEEE, 2019: 752-760.
- [19] WANG C Y, LIAO H Y M, 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. Piscataway, NJ; IEEE, 2020: 1571-1580.
- [20] WANG Jinwang, XU Chang, YANG Wen, et al. A normalized Gaussian Wasserstein distance for tiny object detection [J]. arXiv preprint arXiv, 2110.13389, 2021.
- [21] DONG Hongwen, SONG Kechen, HE Yu, et al. PGA-Net: Pyramid feature fusion and global context attention network for automated surface defect detection [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (12): 7448-7458.