

doi: 10.3969/j.issn.2095-0411.2022.05.009

基于优化深度学习的电动桥铸件 表面瑕疵识别方法

吴 鹏^{1,2}, 陈信华², 马宇超¹, 王 鼎¹, 陈 帅¹

(1. 常州大学 机械与轨道交通学院, 江苏 常州 213164; 2. 溧阳市新力机械铸造有限公司, 江苏 常州 213300)

摘要: 针对传统电动桥铸件瑕疵检测方法普遍存在效率低、检测精度低、人工成本高等问题, 文章将优化深度学习方法应用于铸件表面瑕疵检测中, 实现瑕疵自主精确检测识别。依据铸造厂待检测铸件表面特征, 对铸件图像进行了前期图像预处理; 同时, 基于优化网络模型结构, 采用残差网络(Res-Net)与特征金字塔网络(FPN)构成的骨干结构, 进行全图特征提取; 采用区域建议网络(RPN)生成大量特征建议区域, 经非极大值抑制(NMS)处理后, 分别输入全连接层与全卷积完成检测任务; 运用TensorFlow深度学习框架搭建模型, 并采用迁移学习提高模型的泛化能力, 实验结果显示, 优化后的模型整体性能优于原始模型。

关键词: 瑕疵检测; 深度学习; 特征提取; 迁移学习

中图分类号: TP 271

文献标志码: A

文章编号: 2095-0411(2022)05-0065-07

Research on Casting Surface Defects of Electric Bridge Identification Method Based on Optimal Deep Learning

WU Peng^{1,2}, CHEN Xinhua², MA Yuchao¹, WANG Ding¹, CHEN Shuai¹

(1. School of Mechanical Engineering and Rail Transit, Changzhou University, Changzhou 213164, China; 2. Liyang Xinli Machinery Casting Co., Ltd., Changzhou 213300, China)

Abstract: Traditional electric bridgecasting defect detection methods are of low efficiency, low detection accuracy, and high labor cost. Thus the optimal deep learning method is presented for the detection of the casting surface defect of electric bridges, and it can implement automatic accurate detection and identification of defects. Image preprocessing of the castings is done based on surface feature of

收稿日期: 2022-05-31。

基金项目: 江苏省产学研合作资助项目(BYBY2021221); 2021年江苏省研究生科研与实践创新资助项目(SJCX21_1277); 溧阳市科技资助项目(培育创新项目)(XMSB20210001)。

作者简介: 吴鹏(1987—), 男, 江苏常州人, 博士, 研究员。通信联系人: 陈信华(1967—), E-mail: xlcxh2016@126.com

引用本文: 吴鹏, 陈信华, 马宇超, 等. 基于优化深度学习的电动桥铸件表面瑕疵识别方法[J]. 常州大学学报(自然科学版), 2022, 34(5): 65-71.

castings. Feature extraction is done by Res-Net and FPN based on optimal model. A large number of feature recommended areas are generated by RPN. It is inputted into FC layer and FCN after NMS, then the defect detection is completed. The model is conducted by TensorFlow and the generalization ability of the model is improved by transfer learning. The experimental result shows that the whole performance of the optimized model is superior to the original model.

Key words: defect detection; deep learning; feature extraction; transfer learning

近年来,国内外针对机器视觉表面瑕疵检测技术方面的问题,进行了大量的研究工作^[1-4]。随着计算机视觉技术的不断发展,基于深度学习的瑕疵检测方法得到广泛研究,比传统的图像处理方法和基于人工特征提取的机器学习方法具有更强的检测能力^[5-6]。LE等^[7]提出了一种包括迁移学习和多模型集成框架的瑕疵检测方法,对焊接接头的瑕疵进行检测实验,该方法相比传统视觉方法能有效提高检测的准确率。而传统图像处理算法用于解决特定场景的图像任务,针对性强,但泛化性弱,图像处理过程繁琐^[8-9]。SAAD等^[10]针对半导体芯片瑕疵问题,采用改进中值滤波算法对图像进行降噪,利用多阈值算法增强图像,实验结果表明检测效果更优。GILBLAS等^[11]研究了微型裂纹瑕疵自动检测方法,根据镜面反射器的多层且半透明的特性,提出针对光学太阳反射镜瑕疵的有效检测方法。JIAN等^[12]针对手机屏幕玻璃的瑕疵检测问题,提出了一种优化的模糊C均值聚类算法,并开发了一套检测系统,能有效的检测出各种瑕疵。YU等^[13-14]针对木材表面瑕疵的识别检测问题,研究了一种结合红外光谱的机器视觉检测方法,以红外光谱仪采集落叶松的图像,应用反向传播神经网络模型进行训练与测试,实验结果表明检测方法高效可行。高雅等^[15-16]针对编织线表面黑斑、色差、毛球等瑕疵,在前期图像处理的基础上,通过对比形状、面积等方面的差异特征区域、差异阈值进行识别。刘晓杰等^[17]提出分段灰度算法与灰度共生矩阵结合的检测算法,解决了具有光学反射性的金属零件表面细小瑕疵检测精度较低的问题。钱基德等^[18]针对液晶屏图像亮度不均,特征不突出等问题,提出了基于最大稳定极值区域(MSER)的阈值分割法,进行准确检测定位,实验证明该检测方法效率较高、鲁棒性好。宋辉等^[19]针对轮毂表面瑕疵检测效

率低的问题,利用工业机器人移动待检测工件,实现各种规格轮毂的全方位表面瑕疵检测。李超等^[20-21]提出了薄壁金属罐表面焊缝的视觉检测方法,该方法在混合高斯模型的基础上,改进了背景差分法,依据表面特征(外形、亮度)分类检测。

综上所述,虽然相关研究工作在一定程度上提高了表面瑕疵检测的效率,但有关铸件表面瑕疵检测的研究相对较少,尤其是引入深度学习方法,考虑其在模型训练方面效率问题上的研究更少。因此,文章研究采用优化深度学习模型,提高铸件表面瑕疵检测的整体效果,实验整体流程如图1所示。

1 模型分析

文章对深度学习网络结构进行分析,并在此基础上,构建铸件表面瑕疵检测的优化模型。如图2所示,深度学习网络可分为两阶段:①由残差网络

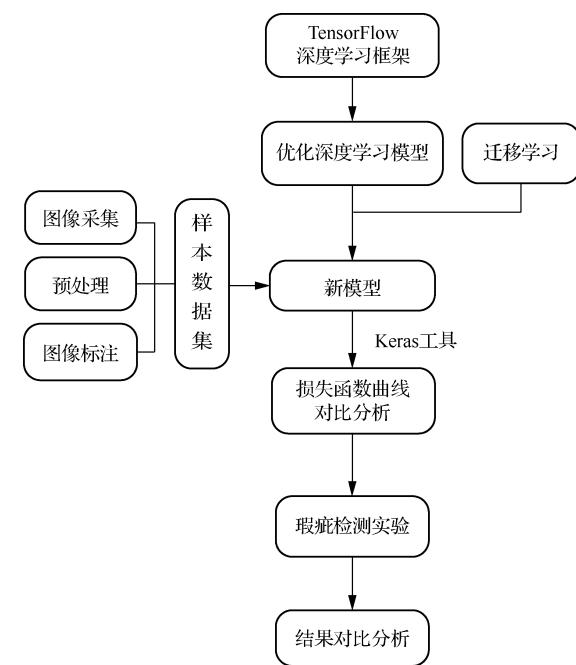


图1 实验整体流程

Fig.1 Overall experimental process

(Res-Net) 与特征金字塔网络 (FPN), 组成主干结构作为特征提取器, 扫描全图、提取特征, 再由区域建议网络 (RPN) 生成建议区域; ② 特征经校正后, 进行建议区域框的回归与分类, 利用 mask 掩模实现分割。

优化的深度学习网络模型和其他检测网络相比, 拥有更高的检测精度和更好的实例分割效果, 其关键在于 ROI Align (Region of Interest Align) 技术。为了满足后面网络的输入要求, 对比的检测网络中使用的 ROI Pooling (Region of Interest Pooling) 技术, 对图像的像素值进行了 2 次量化操作, 每次操作都会产生量化误差, 从而影响最后的检测性能。而 ROI Align 技术为了避免量化误差, 采用双线性插值算法, 利用原图中虚拟点周围真实存在的 4 个点的像素值来估算出虚拟点对应的像素值, 双线性插值法计算方程为

$$\begin{cases} f(R_1) \approx \frac{x_2-x}{x_2-x_1}f(Q_{11}) + \frac{x-x_1}{x_2-x_1}f(Q_{21}) & R_1 = (x, y_1) \\ f(R_2) \approx \frac{x_2-x}{x_2-x_1}f(Q_{12}) + \frac{x-x_1}{x_2-x_1}f(Q_{22}) & R_2 = (x, y_2) \end{cases} \quad (1)$$

$$f(P) \approx \frac{y_2-y}{y_2-y_1}f(R_1) + \frac{y-y_1}{y_2-y_1}f(R_2) \quad (2)$$

式中: Q_{ij} 为点 P 周围已知的 4 个点; R_1 和 R_2 为沿 x 方向线性插值得到的点; 点 P 为 R_1 和 R_2 沿 y 方向线性插值得到的点。

此外, 优化后模型的损失函数与其他检测网络的也不同, 对每一个 ROI 来说, 优化模型定义的多任务损失函数表示为

$$L = L_c + L_b + L_m \quad (3)$$

式中: L_c 为分类损失; L_b 为回归损失; L_m 为新增的 mask 部分的损失。这样做不会导致类间竞争, 能有效提高分类效果。

2 模型训练

2.1 训练条件

模型训练硬件环境配置为 Intel core i7-6500U 的 CPU, GPU 为处理速度 6 GB 的 Nvidia GTX1060, 软件环境为 Ubuntu 操作系统, 采用

Python 编程语言, 模型搭建平台为 TensorFlow 深度学习框架与 Keras 高阶 API (Application Programming Interface) 工具。同时, 为了解决样本数据较少的问题, 模型训练采用已知的迁移学习策略, 训练过程中分析测试结果, 针对发现的问题提出应对的优化方法, 再将改进后的模型进行训练与测试及实验结果分析。图像采集共有 223 张图像, 由于采集到的原始图像像素为 5496×3672 , 像素过大会影响模型训练的速度, 因此在进行训练前采用 resize 处理, 将样本图像缩放至 640×480 , 并使用 Labelme 图像标注工具 (CSAIL 研发), 对铸件表面瑕疵图像进行标注 (图 3), 实现基于语义分割的数据标记。

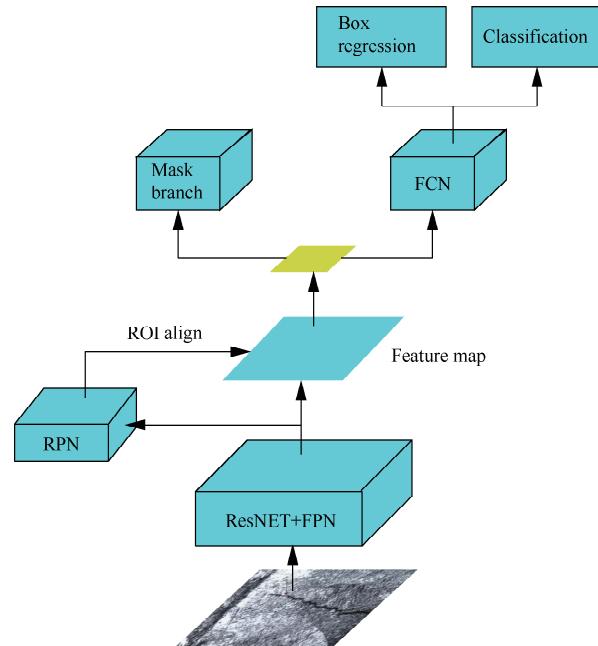
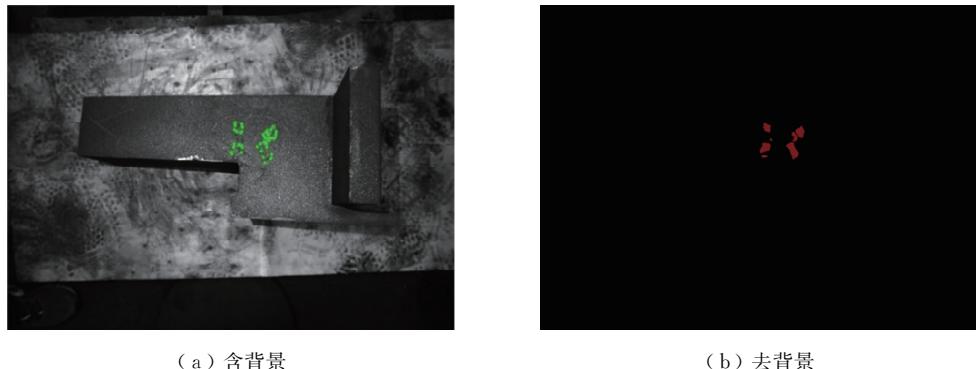


图 2 模型结构

Fig.2 Model structure



(a) 含背景

(b) 去背景

图 3 图像标注结果

Fig.3 Result of image annotation

2.2 迁移学习的应用

大量的样本数据集，是训练建立深度学习网络模型和保证训练准确度的基础，而样本形成训练数据集的过程，包括图像采集、预处理、标注等多个阶段，要获得一个表现良好的学习模型，需要大量的训练数据量和消耗大量的训练时间。因此，为了降低训练时长，文章用迁移学习的方法，在优化模型预训练（MS-COCO 数据集）基础上，将部分预训练网络模型参数迁移至目标网络中，再进行微调（Fine-tune），最后将铸件表面图像样本输入目标网络进行训练，这样既减少对数据集的训练时长还有助于提升迁移效果。其中，Fine-tune 是最简单的深度迁移形式，但是它无法解决两种数据分布不同的问题，通过自适应优化方法能够进一步弥补前者的不足，当前大部分深度迁移学习采用的网络损失定义方式为

$$l = l_c(D_s, y_s) + \lambda l_A(D_s, D_t) \quad (4)$$

式中： l 为网络的最终损失； $l_c(D_s, y_s)$ 为网络在标注数据上的常规分类损失； $l_A(D_s, D_t)$ 为网络的自适应损失； λ 为权重参数。

DDC (Deep Domain Confusion) 是采用深度网络自适应的一种迁移学习方法，其损失函数为

$$l = l_c(D_s, y_s) + \lambda D_M^2(D_s, D_t) \quad (5)$$

式中 D_M 为最大均值差异，用于度量两种数据分布的距离，其定义为

$$D_M^2(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^m \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_H^2 \quad (6)$$

式中： n 和 m 分别为两种数据的样本个数； $\phi(x_i)$ 和 $\phi(y_i)$ 为映射函数。

采用 Keras 工具输出经过 30 轮 (epoch)、3 600 次迭代后的网络训练集 loss 数据，并绘制成损失函数曲线图，如图 4 所示。图 4 (a) 为优化网络总的 loss 曲线，图 4 (b) ~ 图 4 (f) 分别为 RPN 网络的分类 loss 曲线与回归 loss 曲线、比对网络的分类 loss 曲线、回归 loss 曲线及 mask 掩模分支网络的 loss 曲线。总的 loss 曲线、RPN 网络的分类 loss 曲线、回归 loss 曲线以及比对网络的分类 loss 曲线在前 5 个 epoch 中收敛速度较快，在随后的 5~30 个 epoch 中收敛速度减缓且逐渐趋于收敛，而比对网络的回归 loss 曲线收敛速度相对较慢，mask 掩模分支网络的 loss 曲线则呈现较大的波动。从模型总的 loss 曲线的下降趋势可知，通过迁移学习有效降低了模型对小规模样本数据集的训练时间。

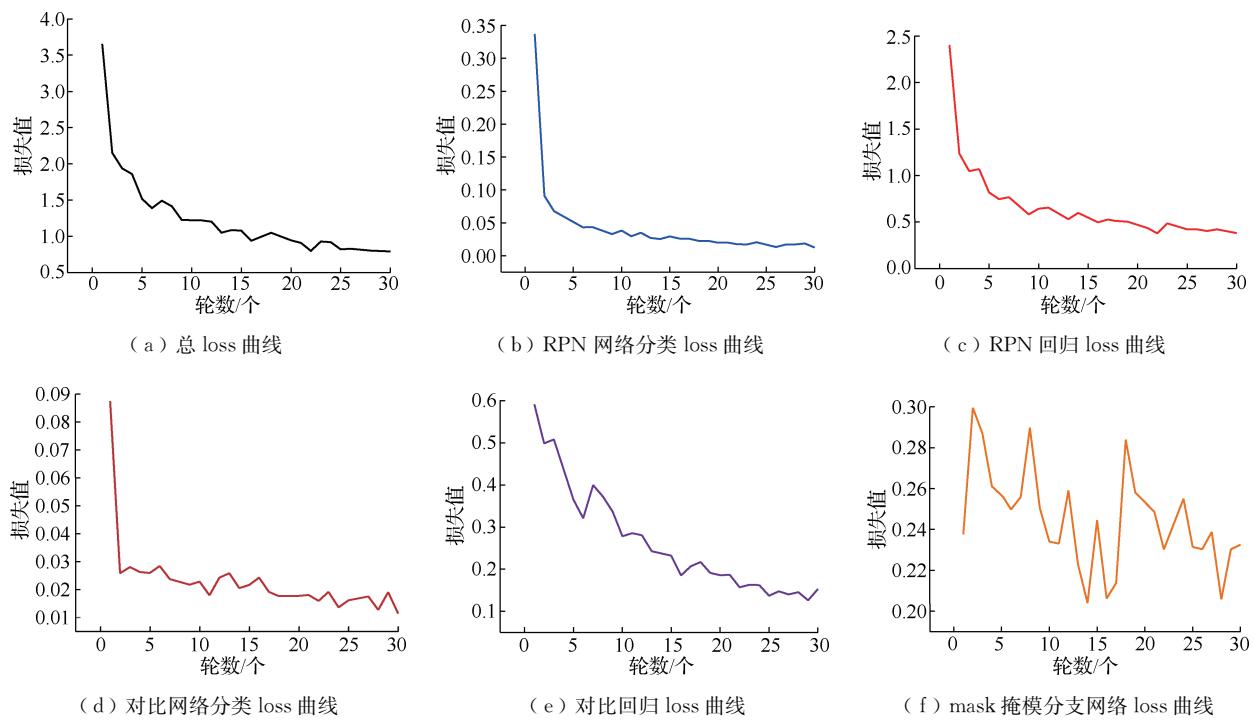


图 4 损失函数曲线

Fig.4 Loss function curve

3 检测实验

为了验证文中提出的检测方法，在团队研发的基于深度学习的铸件表面瑕疵在线检测系统上，进行了现场实验。如图 5 所示，实验系统主要由深度学习工作站、工业相机、平行光源、传送平台组成。系统软件采用 MATLAB2020 进行开发，如图 6 所示。

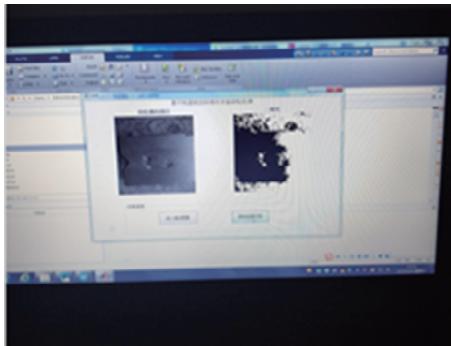


图 5 检测平台

Fig.5 Testing platform

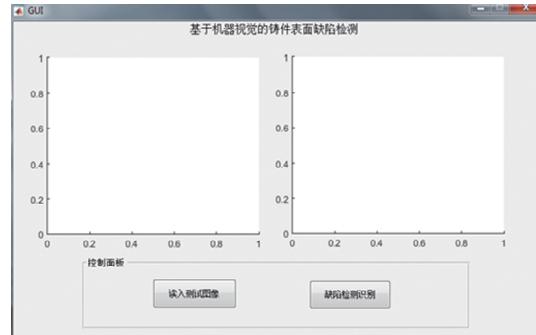


图 6 检测系统软件界面

Fig.6 Software interface of detection system

在实验结果分析中，选用正检率 (R_{TP})、漏检率 (R_{LP}) 以及误检率 (R_{FP}) 3 个检测指标来评估优化后的模型检测效果。在相同情况下，实验数据集为 30 张铸件表面图像（含 42 个待检目标）进行检测实验，实验结果对比分析见表 1。

表 1 实验结果对比分析

Table 1 Comparative analysis of experimental results

网络模型	瑕疵总数/个	检出数目/个	正检数目/个	漏检数目/个	误检数目/个	$R_{TP}/\%$	$R_{LP}/\%$	$R_{FP}/\%$
优化前	42	39	37	4	2	88.1	9.52	4.76
优化后	42	40	40	2	0	95.2	4.76	0

从表 1 中可以看出, 优化前的网络模型检测存在较高的漏检率和误检率, 优化后网络模型漏检数目明显减少, 且没有出现误检的情况, 正检率达到了 95.2%, 检测效果得到了明显的提升, 优化后网络模型的检测结果如图 7 所示。

模型对铸件表面瑕疵进行检测与分割后输出的结果包括瑕疵区域预测矩形框、部分的 mask 掩模以及 mask 掩模与真实目标的交并比(IoU)数值。由于输出的结果图上可能会出现多个部分重叠的矩形预测框, 需要通过非极大值抑制来抑制那些冗余的框。选出重叠部分 IoU 得分最高的预测框, 并遍历剩余框, 去除其中与选出的预测框重叠率很高的框, 最后只保留最优的预测框。IoU 数值表示定位准确度, 当 IoU 数值越接近于 1, 定位准确度就越高。测试结果图中显示 IoU 得分高于 0.97, 可见对 RPN 网络输出的锚框尺寸与长宽比进行调整过后, 铸件表面瑕疵的分割结果也得到了较大的改善, 进而验证了文中提出的优化方法有效改善了原始网络模型对铸件表面的检测性能。

4 结 论

目前, 基于深度学习的检测技术由于其优异的检测性能在多个领域广泛应用。文章针对电动桥铸件表面瑕疵检测精度低等问题, 提出一种基于优化深度学习网络模型的铸件表面瑕疵识别方法。利用迁移学习策略对模型进行训练, 冻结主干网络, 调整网络模型参数, 减少了数据集训练的时间。通过实验结果和对比分析, 文章研究的深度学习检测方法有效解决了误检和漏检问题, 相比于传统检测方法提高了检测的精度和效率。虽然文章研究的优化后深度学习网络模型已能较准确地检测出电动桥铸件表面的瑕疵, 但由于研究的深度学习网络模型是一种 two-stage 检测算法, 其训练和计算速度与 one-stage 检测算法相比较慢。下一步的改进方向是在原有网络结构的基础上进行结构优化, 加快目标检测的速度。

参考文献:

- [1] 吕继东, 王艺洁, 夏正旺, 等. 基于改进的 Mask R-CNN 自然场景下苹果识别研究[J]. 常州大学学报(自然科学版), 2022, 34(1): 68-77.
- [2] 徐建东. 基于最小二乘法拟合的 Otsu 快速图像分割方法[J]. 常州大学学报(自然科学版), 2021, 33(1): 70-76.
- [3] 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.
- [4] 李维刚, 叶欣, 赵云涛, 等. 基于改进 YOLOv3 算法的带钢表面缺陷检测[J]. 电子学报, 2020, 48(7): 1284-1292.
- [5] AO X, ZHANG D, MA W, et al. Automatic metallic surface defect detection and recognition with convolutional neural networks[J]. Applied Sciences-Basel, 2018, 8(9): 123-138.

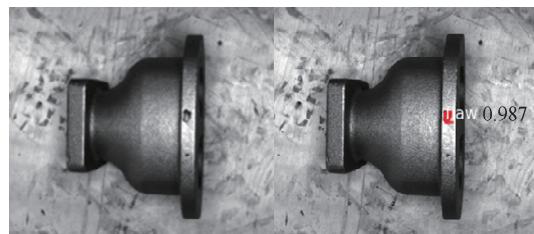


图 7 实例分割结果

Fig.7 Instance segmentation result

- [6] 程婧怡,段先华,朱伟.改进YOLOv3的金属表面缺陷检测研究[J].计算机工程与应用,2021,57(19):252-258.
- [7] LE X Y, MEI J H, ZHANG H D, et al. A learning-based approach for surface defect detection using small image datasets[J]. Neurocomputing, 2020, 408: 112-120.
- [8] 罗菁,董婷婷,宋丹,等.表面缺陷检测综述[J].计算机科学与探索,2014(9):1041-1048.
- [9] 严琴,赵全育.高频噪声下的螺栓表面缺陷检测[J].测控技术,2021,40(5):75-79.
- [10] SAAD N H, AHMAD A E, SALEH H M, et al. Automatic semiconductor wafer image segmentation for defect detection using multilevel thresholding[J]. MATEC Web of Conferences, 2016, 78: 01103.
- [11] GILBLAS R, SENTENAC T, ORTEU J J, et al. Detection of micro-cracks on highly specular reflectors: dimensioning a vision machine based on optical properties[J]. IEEE Sensors Journal, 2017, 17(23): 7901-7907.
- [12] JIAN C X, GAO J, AO Y H. Automatic surface defect detection for mobile phone screen glass based on machine vision[J]. Applied Soft Computing, 2017, 52: 348-358.
- [13] YU H L, LIANG Y L, LIANG H, et al. Recognition of wood surface defects with near infrared spectroscopy and machine vision[J]. Journal of Forestry Research, 2019, 30(6): 2379-2386.
- [14] LI Z L, DONG M H, WEN S P, et al. CLU-CNNs: object detection for medical images[J]. Neurocomputing, 2019, 350: 53-59.
- [15] 高雅,朱秦岭,王珑.基于机器视觉的护套编织线缺陷检测系统设计[J].测控技术,2017,36(9):31-34.
- [16] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [17] 刘晓杰,罗印升,张曼,等.基于机器视觉的零部件表面缺陷检测方法研究[J].现代电子技术,2017,40(24):181-183.
- [18] 钱基德,陈斌,钱基业,等.基于机器视觉的液晶屏Mura缺陷检测方法[J].计算机科学,2018,45(6):296-300,313.
- [19] 宋辉,李钊.基于工业机器人的汽车轮毂表面缺陷的视觉检测系统设计[J].计算机测量与控制,2018,26(9):13-16,22.
- [20] 李超,孙俊.基于机器视觉方法的焊缝缺陷检测及分类算法[J].计算机工程与应用,2018,54(6):264-270.
- [21] 马永福.基于机器视觉的H型钢表面缺陷检测[J].冶金与材料,2019,39(6):13-14.

(责任编辑:李艳,周安迪)