

DOI:10.11918/202212004

DN-YOLOv5 的金属双极板表面缺陷检测算法

凌强,刘宇,王春举,贺海东,孙立宁

(苏州大学 机电工程学院,江苏 苏州 215137)

摘要:为解决氢燃料电池中金属双极板表面缺陷尺寸小,缺陷对比不明显、种类多造成的难以检测,易误检漏检以及缺陷检测模型复杂度太大难以部署等问题,提出一种改进版的金属双极板缺陷检测算法 DN-YOLOv5,来探究缺陷检测在冲压成形的金属双极板视觉检测工作台场景下进行快速精准检测的可行性,从而实现智能检测,提升检测效率。本研究着重于修改 YOLOv5 主干网络 Backbone 部分,添加网络中模块数量,加入 NAM 注意力机制和使用深度可分离卷积模块来替代原来 CSP/CBS 主干网络卷积模块,并引入 Siou 对损失函数重新进行了定义,极大的提升了主干网络的轻量化程度。结果表明,本算法的 map@0.5 可达 0.988,每秒检测传输帧率为 9.98,模型参数量降低了 52.13%,在测试集 75 张缺陷图像中真检率达到了 99.74%。该方法在保证模型较高检测率的同时,显著降低了模型复杂度和参数计算量。此外,该算法结合新的检测尺度设计特征融合网络,提升网络的小目标、多目标检测能力。该算法具有良好的稳定性和鲁棒性,综合性能较好,满足部署移动端场景进行缺陷检测的轻量化需求。

关键词: 金属双极板;表面缺陷检测;DN-YOLOv5;轻量化网络;注意力机制;特征融合

中图分类号: TP391 **文献标志码:** A **文章编号:** 0367-6234(2023)12-0104-09

DN-YOLOv5 algorithm for detecting surface defects of metal bipolar plates

LING Qiang, LIU Yu, WANG Chunju, HE Haidong, SUN Lining

(School of Mechanical and Electrical Engineering, Soochow University, Suzhou 215137, Jiangsu, China)

Abstract: To solve the problems of small size of metal bipolar plate surface defects in hydrogen fuel cells, indistinct defect contrast and various types of defects that make it difficult to detect, easily cause false and leaky detection and large size of the complexity of defect detection model that makes it difficult to deploy, an improved metal bipolar plate defect detection algorithm DN-YOLOv5 is proposed to explore the feasibility of rapid and accurate defect detection in the scene of metal bipolar plate visual detection workbench formed by stamping, so as to realize intelligent detection and improve detection efficiency. This research focuses on modifying the Backbone part of YOLOv5 backbone network, adding the number of modules in the network and the NAM attention mechanism, using the deeply separable convolution module to replace the original CSP/CBS backbone network convolution module and introducing Siou to redefine the loss function, which greatly improves the lightweight degree of the backbone network. The experimental results show that the algorithm map@0.5 can reach 0.988, the detection transmission frame rate per second is 9.98, the number of model parameters is reduced by 52.13% and the true detection rate of 75 defect images in the test set reaches 99.74%. This method not only ensures the high detection rate of the model, but also significantly reduces the complexity of the model and the amount of parameter calculation. In addition, the algorithm combines the new detection scale to design a feature fusion network, which improves the small target and multi-target detection capabilities of the network. It has good stability, good robustness and good comprehensive performance, meeting the lightweight requirements of deploying mobile end scenarios for defect detection.

Keywords: metal bipolar plate; surface defect detection; DN-YOLOv5; lightweight network; attention mechanism; feature fusion

在双碳大背景下,发展氢能已成为全球主要国家的共识,氢燃料电池产业同样受到了高度重视。近年来,中国有关氢能和燃料电池相关的政策持续加码,积极推进氢能及燃料电池的推广和应用。氢

收稿日期: 2022-12-02;录用日期: 2023-02-27;网络首发日期: 2023-05-18
网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20230517.1654.004>
基金项目: 国防基础科研重点项目(JCKY2020203B056);江苏省高等学校自然科学研究重大项目(20KJA460003);江苏省前沿引领技术基础研究专项(SBK2019060036)
作者简介: 凌强(1999—),男,硕士研究生;王春举(1978—),男,教授,博士生导师;孙立宁(1964—),教授,博士生导师
通信作者: 王春举, cjwang@suda.edu.cn

燃料电池产业链最主要、最核心的是燃料电池系统,微流道双极板作为新能源燃料电池的关键部件,起到均匀分配气体、收集电流、冷却和支撑等作用。其中金属双极板拥有较高的能量密度,并且具有优异的导电、导热性能,低成本、易加工,适合大规模批量生产。因此,研制高性能金属双极板是目前的重要发展方向。金属双极板的技术难点在于成形技术以及金属双极板表面处理技术^[1],在众多成形工艺中,精密冲压成形具有高生产效率、低成本、成形精度高等优点,成为金属双极板主要制造技术。然而,金属双极板冲压成形后双极板表面变形,流道深度不一致对其表面质量造成了重大影响^[2]。同时,受到实验环境、机器磨损以及极板运输操作不当等因素的影响,使得金属双极板的表面留下大量不同种类的缺陷^[3]。这些缺陷有些存在于局部物理形态上的,如划痕、褶皱、凹陷^[4]等,还有一些表面缺陷涉及到化学性质的不均匀,如夹杂、斑点^[5]等大大的影响金属双极板的表面结构及性能优劣。所以,良好的金属双极板表面缺陷检测技术能够保证其表面质量,对其生产方式和保存运输具有重大意义。本文着重研究一种基于深度学习的缺陷检测算法,在保证具有高检测精度的同时能够有高传输效率,且模型足够轻量化能够满足部署移动端的需求。

随着计算机视觉技术的发展,缺陷检测可以分为两个方向。一个是基于传统图像处理的方向,还有一个是基于深度学习的图像检测方向。

在传统图像处理中,Li 等^[6]提出了一种基于直方图特征的缺陷分类算法,用于自动检测图案缺陷。Zhang^[7]提出了一种结合 LBP 和 GLCM 的算法。利用 LBP 和 GLCM 分别提取缺陷图像的局部特征信息和整体纹理信息。Halfawy 等^[8]提出了一种高效的模式识别算法,利用 HOG 和支持向量机(support vector machines,SVM)对管道缺陷进行自动化检测和分类。特征提取方法多种多样,各有优缺点。对于具体的目视检测项目,应考虑特征提取方法是否充分利用全局信息,其计算是否方便,是否能满足实时性需求等。

在深度学习中,主要有 Faster RCNN、YOLO 系列网络、SSD 网络可应用于缺陷检测^[9]。有研究者基于 Faster RCNN 进行缺陷检测,如 Zhou 等^[10]在 Faster RCNN 加入了可变形卷积。Wei 等^[11]在 Faster RCNN 基础上添加了视觉增益机制,通过视觉增益机制增加模型知觉的灵敏程度。Su 等^[12]基于 Faster RCNN 构建了通道注意力网络与空间注意力网络连接的互补注意力网络,用于表面缺陷检测。YOLO^[13]是一种基于深度神经网络的目标识别和定

位算法,通过固定网格回归进行目标检测。它的主要特点是运行速度快,可用于实时系统。YOLO 基于回归的思想,将整个图像作为网络的输入,直接对图像多个位置上的物体边界和物体类别进行回归。Adibhatla 等^[14]采用 YOLO/CNN 模型对 PCB 缺陷进行检测,缺陷检测准确率达到 98.79%。但是,该方法能够检测到的缺陷类型有限,需要进行优化。Lv 等^[15]提出了一种基于 YOLOv2^[16]的钢材表面缺陷检测主动学习方法。该模型实现了高效率,但以牺牲精度为代价。Jing 等^[17]提出了一种改进的 YOLOv3^[18]模型,利用 K-means 算法对标记数据进行聚类。实验结果表明,改进的 YOLOv3 模型在织物疵点检测中具有较好的性能。但是,实时性能还有待提高。YOLOv4^[19]网络作为一种基于回归的检测方法,具有良好的检测速度。但对小目标的检测精度还有待提高。在检测铁片表面裂纹中,Deng 等^[20]提出了一种级联 YOLOv4 (C-YOLOv4)网络。实验结果表明,C-YOLOv4 具有较好的鲁棒性和裂纹检测精度。SSD 结合了 YOLO 和 Faster R-CNN 的一些策略,Zhai 等^[21]提出了一种基于 DenseNet 和特征融合的 DF-SSD 目标检测方法。实验结果表明,所提出的 DF-SSD 方法在小物体和特定关系物体的检测方面具有较高的性能。Li 等^[22]在 SSD 框架基础上将浅层信息与深层特征融合进行缺陷检测,效果优于原 SSD 网络。

本文提出的 DN-YOLOv5 算法对主干网络进行了优化和调整,大大减少了模型参数,提升了网络轻量化程度,能够对金属双极板表面缺陷图像进行快速、精准的检测,另外本文的模型具有良好的鲁棒性且模型较小,完全满足轻量化模型部署到移动端的需求。

1 DN-YOLOv5 网络改进

1.1 轻量化主干网络 DN-YOLOv5 结构

YOLOv5 是由输入端、Backbone、Neck、Head 构成的。而 DN-YOLOv5 是在原 YOLOv5 的基础上通过改进其 Backbone 主干网络结构得到的一种极其轻量化的网络结构。在 DN-YOLOv5 主干网络中,考虑到计算参数量方便后期模型导出和部署,本文去除了头部 Focus 特征提取模块,将第 1 层 CBS 模块采用 16 输出 3×3 卷积核大小代替原先的 64 输出 6×6 卷积核大小的 CBS 模块。然后在接下来若干层中使用显著减少参数数量的深度可分离卷积模块替代原先这种 CSP/CBS 特征提取模块,在主干结构末端添加 NAM^[23]注意力机制并仍以 SPPF 为封口模块作为最终输出。整个 DN-YOLOv5 的主干网络

结构部分如图 1 所示。




图 1 DN-YOLOv5 主干网络结构

Fig. 1 Structure diagram of DN-YOLOv5 backbone network




图 2 深度可分离卷积模块图

Fig. 2 Depth separable convolution block diagram

1.3 主干网络末端处添加 NAM 注意力机制

很多类似于 CBAM^[26] 这样的卷积块注意力模块都嵌入了通道和空间注意力子模块,但是许多这样的工作大多忽略了来自训练的调整权重的信息,所以想要利用训练模型权重的方差测量来突出显著特征。而 NAM 作为一种高效、轻量级的注意力模块,采用 CBAM 的模块集成,并重新设计了通道和空间注意力子模块。在上述可分离卷积模块的输出即主干网络的末端将 NAM 注意力模块嵌入,对于残余网络,它嵌在残余结构的末端。对于通道注意力子模块,使用批量归一化 (batch normalization, BN)^[27] 的比例系数,如下式所示。这个比例系数可以测量通道的方差并体现其重要性。

$$B_{out} = BN(B_{in}) = \gamma \frac{B_{in} - \mu_{\beta}}{\sqrt{\sigma_{\beta}^2 + \varepsilon}} + \beta \quad (1)$$

式中: μ_{β} 、 σ_{β} 分别为小批量 β 的平均值和标准偏差, γ 、 β 分别为可训练的放射变化参数 (尺度和位移)。通道注意力子模块为 (如图 3 所示)

1.2 深度可分离卷积替代 CSP/CBS 模块

一般来说,随着现在的模型特征提取能力的增加以及 FLOP 的数量越来越大,在移动端或 CPU 设备上实现快速推理速度会变得缓慢^[24]。为实现在不增加模型参数计算量和尽可能降低延迟的情况下增强网络特征提取能力。当从 ARM 移动设备切换到 Intel CPU 设备上时,往往大部分的轻量级网络不能满足推理时间较少的要求。为了在不增加推理时间条件下进一步提升模型的性能,选取 MobileNetV1^[25] 轻量化网络中的 DepthSepConv 来作为基本模块,这种深度可分离卷积模块没有 shortcut 操作,也没有 concat 或 elementwise-add 这样的额外操作,经验证这些操作不仅不会提升模型的准确性,还会降低模型的推理速度。由于该模块已被 Intel CPU 加速库深度优化,它的推理速度优于大部分轻量化网络模块。一个深度可分离卷积层可选模块包含关系如图 2 所示。

$$M_c = \text{sigmoid}(W_{\gamma}(\text{BN}(F_1))) \quad (2)$$

式中 M_c 为通道输出特征。




图 3 通道注意力机制

Fig. 3 Channel attention mechanism

γ 是每个通道的比例系数,得到的权重为 $W_{\gamma} = \gamma_i / \sum_j \gamma_j = 0\gamma_j$ 。将 BN 的比例系数应用到空间维度中来衡量像素重要性并将其称为像素归一化。对应的空间注意力子模块为 (如图 4 所示)

$$M_s = \text{sigmoid}(W_{\lambda}(\text{BN}_s(F_2))) \quad (3)$$

式中: M_s 为空间输出特征, λ 为比例系数。




图 4 空间注意力机制

Fig.4 Spatial attention mechanism

1.4 重新定义的损失函数 SIoU

YOLOv5 采用 CIoU 损失函数, 传统的目标检测损失函数依赖于边界框回归指标的聚合, 例如预测框和真实框 (即 GIoU、CIoU、IIoU 等) 的距离、重叠区域和纵横比。然而, 目前使用的方法都没有考虑到所需真实框与预测框间方向的不匹配。这种不足导致收敛速度较慢且效率较低, 因为预测框可能在训练过程中“四处游荡”并最终产生更差的模型。针对上述问题, 采用 SIoU 损失函数替换原损失函数。

本文中的损失函数 SIoU, 考虑了期望回归之间的向量角度, 重新定义了损失指标。应用于传统的神经网络和数据集表明, SIoU 提高了训练的速度和推理的准确性。SIoU 损失函数由 4 个函数组成: Angle cost, Distance cost, Shape cost, IoU cost。

1.4.1 Angle cost

添加这种角度感知 LF 组件背后的想法是最大限度地减少与距离相关的变量数量。基本上, 模型将尝试首先将预测带到 x 或 y 轴 (以最接近者为准), 然后沿着相关轴继续接近, 如图 5 所示。为了实现这一点, 通过下式来引入 LF 组件并评估损失。

$$\Lambda = 1 - 2 \times \sin^2 \left(\arcsin(x) - \frac{\pi}{4} \right) \quad (4)$$

式中: $x = \frac{c_h}{\sigma} = \sin(\alpha)$, $\sigma = \sqrt{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2}$, $c_h = \max(b_{cy}^{gt}, b_{cy}) - \min(b_{cy}^{gt}, b_{cy})$ 。




图 5 损失函数中的角度损失

Fig.5 Angle loss in loss function

1.4.2 Distance cost

考虑到上述定义的角度损失, 重新定义距离损失为

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma \rho^t}) \quad (5)$$

式中: $\rho_x = \left(\frac{b_{cx}^{gt} - b_{cx}}{c_w} \right)^2$, $\rho_y = \left(\frac{b_{cy}^{gt} - b_{cy}}{c_h} \right)^2$, $\gamma = 2 - \Lambda$ 。

图 6 为真实边界框距离计算方法和预测。




图 6 真实边界框距离计算

Fig.6 Calculation of true bounding box distance

1.4.3 Shape cost

形状损失的函数定义为

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega^t})^\theta \quad (6)$$

式中: $\omega_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}$, $\omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}$ 。

1.4.4 IoU cost

定义的损失函数为

$$L_{\text{box}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (7)$$

式中, $\text{IoU} = \frac{|b \cap b^{gt}|}{|b \cup b^{gt}|}$ 。

IoU 组成作用关系如图 7 所示。




图 7 IoU 组成作用关系示意

Fig.7 Schematic relation of IoU component contribution

2 模型训练、评估及对比实验

2.1 缺陷数据集

本文的缺陷数据集使用 500 W 分辨率的 HZ20-GS050GM 的工业 CMOS 黑白全局快门相机以及 FA-25-5MP 的工业镜头来进行图像的采集工作。使用 COP-200B 的同轴光源配合 DBFL-160W120 的直发背光源多角度混合光搭建最佳采集工作台 (尽可

能的减小金属表面反光的影响)。每张采集到的原始图像尺寸大小为 2 448 × 2 048,通过对原始图像椒盐添噪、高斯模糊、翻转、平移、裁剪等多种数据扩增方式,得到了凹凸点、夹杂和划痕三大类缺陷共

600 张的缺陷图集,并用 Labeling 对其进行标注。数据集的部分样本如图 8 所示(由于本文中的检测对象金属双极板流道区域受限于相关协议约束,故已作模糊虚化处理,仅展示金属双极板两端检测区域)。




图 8 缺陷数据集部分图样
Fig. 8 Partial pattern of defect data set

2.2 实验环境与参数配置

本文采用的工作站是在 Win10 操作系统下且显卡为 RTX3080,基于 Pycharm 平台,使用语言为 Python3.9,Pytorch 版本 1.12.1,CUDA 版本 11.3.1 来实现模型搭建以及训练工作。根据 8:1 的比例,将金属双极板缺陷数据集划分为训练集和测试集,见表 1。

表 1 金属双极板缺陷数据集划分

类型	凹凸点	夹杂	划痕	总和 2
训练样本	196	161	168	525
测试样本	28	23	24	75
总和 1	224	184	182	600

对模型参数初始化,设置学习率为 0.01,训练 epoch 为 300,batch-size 为 4,为了使训练图像尺寸与相机实际采集到的图像尺寸相符从而避免特征信息丢失最小化,故将图片输入尺寸设定为 2 240 × 2 240。

2.3 模型评估

为了更加客观精准地评估网络 DN-YOLOv5 在本文缺陷数据集上的检测效果,本实验采用平均精度均值 map@0.5 (IoU = 0.5),混淆矩阵,PR 曲线,Box, Objectness, Classification 训练 Loss 拟合图多重指标来进行模型的评估工作。如图 9 所示是该模型的混淆矩阵图,由图中可知真实值与预测值较接近,其中凹凸点和划痕正类样本比分别为 0.98,0.97,而夹杂达到了 1.00,可见模型精确度较高。

模型的 PR 曲线如图 10 所示,该曲线图反应的是精确率 (Precision) 和召回率 (Recall) 的相互关系,图 10 反应了模型评价标准中的多类别平均精度 map@0.5,凹凸点、划痕以及夹杂的 map@0.5 值分别为 0.979,0.991,0.996,3 种缺陷的平均 map@0.5 值达到了 0.988,模型精准度较高,性能良好。




图 9 模型混淆矩阵
Fig. 9 Model confusion matrix




图 10 模型 PR 曲线图
Fig. 10 Model PR curve

如图 11 所示,3 个指标 Box, Objectness, Classification 在经历 300 个 epoch 训练中能够理想的拟合符合预期,精确率和召回率如下:

$$\text{Precision} = \frac{TP}{TP + FP}$$
(8)

$$\text{Recall} = \frac{TP}{TP + FN}$$
(9)

式中,正类样本占比较高。从图 11 中 Precision 和

Recall 可知,单精确率和召回率都较高,该模型训练良好,具备优异性能。

本文在 NVIDIA GeForce RTX3080 的显卡环境下,对 75 张缺陷测试图像进行检测,部分检测效果

图像如图 12 ~ 14 所示,图 15 为训练过程中多种缺陷的随机混合测试图,经测试,75 张缺陷图像检测共耗时 7.51 s,模型每秒传输帧数为 9.98,所有缺陷的真检率为 99.74%。




图 11 指标 Loss 拟合图
Fig. 11 Index Loss fitting diagram




图 12 凹凸点检测效果图
Fig. 12 Bump point detection renderings




图 13 夹杂检测效果图
Fig. 13 Inclusion detection renderings




图 14 划痕检测效果图
Fig. 14 Scratch detection renderings




图 15 多种缺陷随机混合测试图

Fig. 15 Random mixed test chart of multiple defects

2.4 消融实验

2.4.1 NAM 注意力机制对模型性能的改善

为了验证主干网络中的深度可分离卷积模块和末端添加的 NAM 注意力机制分别在文中具有优化改进作用,同时得出特征融合网络 DN-YOLOv5 具备更佳的性能,本文进行了消融实验。首先,通过对原 YOLOv5 主干网络结构末端添加 NAM 注意力机制和不添加 NAM 的情况进行了消融实验。实验表明,在原 YOLOv5 主干网络中末端添加 NAM 注意力机制,模型参数减少了 17.29%,每秒传输帧数增加了 0.15, map 值提升 0.003,网络轻量化得到改善,检测率以及图像传输效率提升,见表 2。

表 2 NAM 注意力机制消融实验

Tab. 2 NAM attention mechanism ablation experiment				
模型	Parameters/ M	FLOPS/ (10 ⁹ 浮点运算·s ⁻¹)	map@0.5	FPS/ (帧·s ⁻¹)
CBS/CSP	70.59	16.3	0.993	9.46
CBS/CSP + NAM	58.38	14.8	0.996	9.61

2.4.2 DN-YOLOv5 深度可分离卷积模块融合末端 NAM 和 Siou 对模型性能的改善

将深度可分离卷积模块 (DepthSepConv) 替代原 YOLOv5 中的 Backbone 主干网络部分,并在末端层插入 NAM 这种轻量、高效的注意力模块,以 SPPF

为封口模块作为输出,并重新定义 Siou 作为损失函数。在网络中,利用更多浅层特征信息来检测多目标的同时加入 NAM 来增强检测效果并进一步使得模型参数轻量化。本文分别进行了在 DN-YOLOv5 主干网络末端层相同位置处添加 SE、CBAM 模块与 NAM 做消融实验,同时再结合 Siou 损失函数对模型作出最后的完善。实验表明,深度可分离卷积模块在替代原 YOLOv5 主干网络结构后,其模型参数大大减小,网络轻量化程度大幅提升,见表 3。本文的 DN-YOLOv5 (DepthSepConv + NAM + Siou) 相较于在末端添加 SE 模块,其模型参数减小了 29.92%,每秒传输帧数提升 0.07, map 值基本持平,总体轻量化程度提升较高。相较于末端添加 CBAM 模块,模型参数减小 13.40%,每秒传输帧数提升 0.14, map 值略有提升。相较于原 YOLOv5 主干网络结构,模型参数减小了 52.13%,网络轻量化程度得到大幅提升,且每秒传输帧数提升 0.52,这对长时间、多数据的传输效率有很大改善, map 值略有下降影响较小。

2.4.3 主流目标检测模型对缺陷真检性能对比

主流目标检测模型与 DN-YOLOv5 对缺陷图像检测的性能对比见表 4,由表 4 可知,DN-YOLOv5 的

真检率为 99.74%, 误检、漏检数量都小于其他主流目标检测模型, 结合 DN-YOLOv5 中各模块的性能对比可知, DN-YOLOv5 针对该缺陷数据集的 map 值较高, 模型性能较好。

表 3 DN-YOLOv5 各模块的性能对比

Tab.3 Performance comparison of DN-YOLOv5 modules

模型	Parameters/M	FLOPS/(10 ⁹ 浮点运算·s ⁻¹)	map@0.5	FPS/(帧·s ⁻¹)
DepthSepConv	34.61	6.3	0.981	9.84
DepthSepConv + SE	48.22	7.4	0.988	9.91
DepthSepConv + CBAM	39.05	6.7	0.985	9.84
DepthSepConv + NAM	33.84	6.3	0.986	9.82
DepthSepConv + NAM + SiIoU	33.79	6.2	0.988	9.98

表 4 主流检测模型性能对比

Tab.4 Performance comparison of mainstream detection models

算法	缺陷数量	检测数量	误检数量	漏检数量	缺陷真检率/%
SSD	3 152	2 815	45	292	89.31
Faster R-CNN	3 152	2 919	20	213	92.61
YOLOv3	3 152	3 075	9	68	97.55
YOLOv4	3 152	2 968	18	166	94.17
YOLOv5	3 152	3 113	4	35	98.78
DN-YOLOv5	3 152	3 144	0	8	99.74

3 结 论

1) 本文针对氢燃料电池中的金属双极板表面缺陷存在种类多、尺寸小对比不明显、难检、易误检漏检、大参数量模型难部署等问题, 提出了一种 DN-YOLOv5 轻量化网络的缺陷检测算法。

2) 修改原 YOLOv5 主干网络结构和模块数量, 融合深度可分离卷积模块, 在主干网络末端添加 NAM 注意力机制的操作来优化网络结构, 引入了 SiIoU 作为新的损失函数, 提升了网络检测小目标、多目标检测能力, 大大减少了模型参数量, 提升了网络轻量化程度。

3) 实验表明, 在 NVIDIA GeForce RTX3080 的显卡环境下, 75 张缺陷图像检测共耗时 7.51 s, 模型每秒传输帧数为 9.98, 所有缺陷的真检率为 99.74%, 故本文提出的 DN-YOLOv5 网络算法能够快速、准确的检测出金属表面缺陷图像, 满足轻量化模型部署移动端设备的要求。

参考文献

[1] 侯明, 衣宝廉. 燃料电池的关键技术[J]. 科技导报, 2016, 34(6): 52

HOU Ming, YI Baolian. Fuel cell technologies for vehicle applications[J]. Science & Technology Review, 2016, 34(6): 52. DOI: 10.3981/j.issn.1000-7857.2016.06.005

[2] 肖勇, 吴新跃, 贾延奎, 等. 燃料电池金属双极板精密冲压成型缺陷研究[J]. 电源技术, 2019, 43(4): 587

XIAO Yong, WU Xinyue, JIA Yankui, et al. Study on precision stamping defect of metal bipolar plate of fuel cell [J]. Chinese Journal of Power Sources, 2019, 43(4): 587. DOI: 10.3969/j.issn.1002-087X.2019.04.014

[3] 郭政亚, 熊振华. 金属增材制造缺陷检测技术[J]. 哈尔滨工业大学学报, 2020, 52(5): 49

GUO Zhengya, XIONG Zhenhua. Defect detection technology in metal additive manufacturing [J]. Journal of Harbin Institute of Technology, 2020, 52(5): 49. DOI: 10.11918/201905012

[4] 韩芳芳, 段发阶, 张宝峰, 等. 单线阵 CCD 系统的表面凹坑缺陷检测方法[J]. 哈尔滨工业大学学报, 2012, 44(4): 116

HAN Fangfang, DUAN Fajie, ZHANG Baofeng, et al. Study and modeling for surface pit defect detection based on linear array CCD system [J]. Journal of Harbin Institute of Technology, 2012, 44(4): 116. DOI: 10.11918/j.issn.0367-6234.2012.04.023

[5] 周心悦. 基于机器视觉的金属片表面缺陷实时检测与分类研究[D]. 合肥: 中国科学技术大学, 2021

ZHOU Xinyue. Research on real-time detection and classification of metal sheet surface defects based on machine vision [D]. Hefei: University of Science and Technology of China, 2021. DOI: 10.27517/d.cnki.gzkju.2021.001157

[6] LI Min, WAN Shaohua, DENG Zhongmin, et al. Fabric defect detection based on saliency histogram features [J]. Computational Intelligence, 2019, 35(3): 517. DOI: 10.1111/coin.12206

[7] ZHANG Lei. Fabric defect classification based on LBP and GLCM [J]. Journal of Fiber Bioengineering and Informatics, 2018, 8(1): 81. DOI: 10.3993/jfbio3201508

[8] HALFAWY M R, HENGMEETCHAI J. Automated defect detection in sewer closed circuit television images using histograms of oriented gradients and support vector machine [J]. Automation in Construction, 2014, 38: 1. DOI: 10.1016/j.autcon.2013.10.012

- [9] 朱贺, 杨华, 尹周平. 纹理表面缺陷机器视觉检测方法综述[J/OL]. [2022-03-17]. <https://kns.cnki.net/kcms/detail/61.1114.TH.20220316.1246.015.html>
- ZHU He, YANG Hua, YIN Zhouping. Review of machine vision detection methods for texture surface defects [J/OL]. [2022-03-17]. <https://kns.cnki.net/kcms/detail/61.1114.TH.20220316.1246.015.html>
- [10] ZHOU Hao, JANG B, CHEN Yixin, et al. Exploring faster RCNN for fabric defect detection [C]//2020 Third International Conference on Artificial Intelligence for Industries (AI4I). Irvine, CA; IEEE, 2020: 52. DOI:10.1109/AI4I49448.2020.00018
- [11] WEI Bing, HAO Kuangrong, GAO Lei, et al. Detecting textile micro-defects: A novel and efficient method based on visual gain mechanism[J]. Information Sciences, 2020, 541: 60. DOI: 10.1016/j.ins.2020.06.035
- [12] SU Binyi, CHEN Haiyong, CHEN Peng, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network[J]. IEEE Transactions on Industrial Informatics, 2021, 17(6): 4084. DOI:10.1109/TII.2020.3008021
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV; IEEE, 2016: 779. DOI: 10.1109/CVPR.2016.91
- [14] ADIBHATLA V A, CHIH H C, HSU C C, et al. Defect detection in printed circuit boards using you-only-look-once convolutional neural networks[J]. Electronics, 2020, 9(9): 1547. DOI: 10.3390/electronics9091547
- [15] LV Xiaoming, DUAN Fajie, JIANG Jiajia, et al. Deep active learning for surface defect detection[J]. Sensors, 2020, 20(6): 1650. DOI: 10.3390/s20061650
- [16] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI; IEEE, 2017: 6517. DOI: 10.1109/CVPR.2017.690
- [17] JING Junfeng, ZHUO Dong, ZHANG Huanhuan, et al. Fabric defect detection using the improved YOLOv3 model[J]. Journal of Engineered Fibers and Fabrics, 2020, 15: 155892502090826. DOI:10.1177/1558925020908268
- [18] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J/OL]. [2018-04-08]. <https://arxiv.org/abs/1804.02767>. DOI: 10.48550/arXiv.1804.02767
- [19] BOCHKOVSKIY A, WANG C Y, LIAO Hongyuan. YOLOv4: Optimal speed and accuracy of object detection[J/OL]. [2020-04-23]. <https://arxiv.org/abs/2004.10934>. DOI: 10.48550/arXiv.2004.10934
- [20] DENG Huaifu, CHENG Jianghua, LIU Tong, et al. Research on iron surface crack detection algorithm based on improved YOLOv4 network[J]. Journal of Physics: Conference Series, 2020, 1631(1): 012081. DOI: 10.1088/1742-6596/1631/1/012081
- [21] ZHAI Sheping, SHANG Dingrong, WANG Shuhuan, et al. DF-SSD: An improved SSD object detection algorithm based on DenseNet and feature fusion[J]. IEEE Access, 2020, 8: 24344. DOI: 10.1109/ACCESS.2020.2971026
- [22] LI Chuanchang, CUI Guohua, ZHANG Weiwei, et al. Defect detection in vehicle mirror nonplanar surfaces with multi-scale atrous single-shot detect mechanism[J]. AIP Advances, 2021, 11(7): 075202-1. DOI: 10.1063/5.0053851
- [23] LIU Yichao, SHAO Zongru, TENG Yueyang, et al. NAM: Normalization-based attention module [J/OL]. [2021-11-24]. <https://arxiv.org/abs/2111.12419v1>. DOI: 10.48550/arXiv.2111.12419
- [24] CUI Cheng, GAO Tingquan, WEI Shengyu, et al. PP-LCNet: A lightweight CPU convolutional neural network[J/OL]. [2021-09-17]. <https://arxiv.org/abs/2109.15099v1>. DOI: 10.48550/arXiv.2109.15099
- [25] HOWARD A G, ZHU Menglong, CHEN Bo, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [J/OL]. [2017-04-17]. <https://arxiv.org/abs/1704.04861>. DOI:10.48550/arXiv.1704.04861
- [26] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional blockattention module[J/OL]. [2018-07-18]. <https://arxiv.org/abs/1807.06521v2>. DOI: 10.48550/arXiv.1807.06521
- [27] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J/OL]. [2015-02-11]. <https://arxiv.org/abs/1502.03167v1>. DOI: 10.48550/arXiv.1502.03167

(编辑 张 红)