· 58 ·

DOI: 10. 13382/j. jemi. B2205968

改进 YOLOv5 的新能源电池集流盘缺陷检测方法*

陈彦蓉高刀吴文欢唐海袁磊

(湖北汽车工业学院电气与信息工程学院 十堰 442002)

摘 要:针对新能源汽车电池集流盘中因目标缺陷分布杂乱、尺寸跨度大和特征模糊而易出现误检、漏检的问题,提出一种基于 多尺度可变形卷积的 YOLOv5 方法(YOLOv5s-4Scale-DCN),以用于汽车电池集流盘缺陷检测。首先,针对不同尺度的缺陷目 标,在 YOLOv5 模型的基础上新增检测层,通过捕获不同尺度缺陷的特征以及融合不同深度的语义特征,提高对不同尺度缺陷 目标的检测率;其次,引入可变形卷积,扩大特征图的感受野,使提取的特征辨析力更强,有效地提高了模型的缺陷识别能力。 实验结果表明,所提的 YOLOv5s-4Scale-DCN 算法可以有效检测新能源汽车电池集流盘缺陷,mAP 达到了 91%,相较原算法提 高了 2.5%,FPS 达到了 113.6,重度不良和无盖缺陷这两种类别的缺陷,检测召回率达到了 100%,满足新能源汽车电池集流盘 缺陷实时检测要求。

Defect detection method for new energy battery collector disc based on improved YOLOv5 network

Chen Yanrong Gao Ren Wu Wenhuan Tang Hai Yuan Lei

(School of Electrical and Information Engineering, Hubei University of Automotive Technology, Shiyan 442002, China)

Abstract: In order to solve the problem of false detection and missing detection in new-energy vehicle battery collector disk due to disarranged target defect distribution, large size span and fuzzy features, a YOLOv5 method based on multi-scale deformations convolution (YOLOv5s-4Scale-DCN) was proposed for defect detection of vehicle battery collector disk. Firstly, for defect targets of different scales, a new detection layer is added based on the YOLOv5 model. By capturing defect features of different scales and integrating semantic features of different depths, the detection rate of defect targets of different scales is improved. Secondly, deformable convolution is introduced to enlarge the receptive field of the feature map, which makes the extracted feature discrimination stronger and effectively improves the defect recognition ability of the model. Experimental results show that the proposed YOLOv5s-4Scale-DCN algorithm can effectively detect the defects of new-energy vehicle battery collection panel, with mAP up to 91%, 2.5% higher than that of the original algorithm, and the FPS reaches 113.6. There are two types of defects, severe defects and uncovered defects. The detection and recall rate reached 100%, meeting the requirements of real-time detection of the defects of the battery collecting disk of new energy vehicles.

Keywords: new energy vehicle battery; defect detection; YOLOv5; multi-scale fusion; deformable convolution

0 引 言

在过去的几十年里,随着中国经济的快速增长,中国 汽车工业发展迅速,截至 2022 年 9 月底,汽车保有量 3.15 亿辆,能源消费出现了前所未有的增长。以此为背景下,新能源汽车应运而生。世界上大多数国家和地区都在推广纯电动汽车(BEV)、插电式混合动力汽车(PHEV)、以可再生能源为主要动力来源的燃料电池汽车等新能源汽车^[1]。电池是新能源汽车的关键组件,目

收稿日期: 2022-11-06 Received Date: 2022-11-06

^{*}基金项目:湖北省教育厅科学技术研究项目(Q20201801)、湖北汽车工业学院博士科研启动基金项目(BK202004)资助

前,全极耳的圆柱形铝壳锂离子电池是目前常用的装配 方式,然而全极耳结构圆柱铝壳电池面临的难题是如何 实现极耳与盖板极柱之间的连接,因此,集流盘成为连接 电池极耳和盖板极柱的关键,目前常见的集流盘为圆柱 或方形,电池装配是将集流盘放置在电池极耳端面中心, 随后采用激光焊接的方式将集流盘和电池极耳焊接成为 一个整体,集流盘另一端通过焊接或铆接的方式与盖板 的极柱连接在一起,进而通过电池极耳、集流盘、极柱的 连接,使得圆柱铝壳锂离子电池的密封和电流回路^[2]。 但在生产过程中,集流盘容易产生焊穿、焊偏、无盖、坏 点、重度不良多种缺陷,传统的人工检测方法无法满足高 效率的检测要求,漏检问题会造成汽车电池短路而产生 自燃、爆炸等严重的后果,因此,对新能源汽车电池集流 盘缺陷检测方法的研究有着重要意义。

随着人工智能和深度学习的快速发展,利用机器视 觉对表面缺陷进行精准定位与准确识别在技术上逐渐成 熟可行[3]。目前,目标检测算法可以分为传统的目标检 测算法和基于深度学习的目标检测算法,在基于深度学 习的目标检测算法中又可以大体上分为基于候选区域框 和回归的目标检测算法两类。简单来说,就是 one stage 和 two stage 的区别^[4]。YOLO^[5](you only look once)是一 种基于回归的单阶段目标检测算法,该方法具有推理速 度快、检测精度高等优点。到目前为止, YOLO 系列算法 共发布了7个版本,包括YOLOv1、YOLOv2^[6]、 YOLOv3^[7]、YOLOv4^[8] 和 YOLOv5, YOLOv6^[9]、 YOLOv7^[10]在 2022 年也相继提出。王淑青等^[11]针对瓷 砖表面缺陷检测,提出了一种改进的 YOLOv5 检测方法, 有效提高了检测速度和识别精度,有很强的实用性; Wang 等^[12]在 YOLOv5 算法的基础上,提出了改进的 MS-YOLOv5 模型,将提出的一种由多尺度卷积^[13](poly-scale convolution, PSConv) 和 ECA^[14] (efficient channel attention)注意力机制相结合的 PE-Neck 算法融入 neck 部分,并在原算法的第1个检测头加入残差连接,改进后 的检测率达到了87.4%,但检测时间过长,精度和召回率 没有明显提升;董召杰[15]使用 YOLOv3 检测算法对电力 关键部位进行检测,相较 Faster R-CNN 算法, mAP 高出 约3%,检测速度约为后者的7倍;Zheng等^[16]针对轴承 盖表面缺陷目标不敏感等问题,提出了一种改进的 YOLOv3 检测算法,改进后算法检测率和识别率明显提 高;Wang等^[17]针对多尺度,尤其是小尺度的缺陷,设计 了一种改进的 YOLOv5 目标检测算法,通过 Mosaic 数据 增强和损失函数,有效提高了小尺度缺陷的识别率;伍济 钢等^[18]提出一种改进 YOLOv4 算法的 PCB 缺陷检测方 法,相比 Faster R-CNN 算法,检测准确度、模型大小和检 测速度提升了均有了大幅提升:桂久琪等^[19]针对传统方 法检测锂电池表面缺陷精度低、速度慢的问题,提出一种

改进的 YOLOv4 算法,为锂电池工业生产实时监测提供 一定参考价值; Sajid 等^[20]针对垃圾分类,使用 YOLOv5 算法,准确率达到了 61%。虽然他们的算法取得了不错 的检测精度,但模型较大、模型参数量较高以及计算量较 大,通常采取的措施大多都是以大幅牺牲检测速度为代 价进而小幅提高检测精度,难以同时满足识别精度和检 测速度的要求。

本文针对新能源汽车电池集流盘缺陷检测算法漏检 率高、速度慢、检测精度低等问题,提出了一种改进 YOLOv5的缺陷检测算法,用于检测新能源汽车电池集 流盘的5种表面缺陷。首先针对新能源汽车电池集流盘 缺陷种类多且缺陷尺寸跨度大的问题,进行多尺度的改 进,新增10×10的检测尺度,扩大算法检测范围,增加了 深层语义和浅层语义的融合,降低了漏检率;其次针对新 能源汽车电池集流盘坏点分布不规则的问题,将骨干网 络中部分位置的传统卷积替代为可变形卷积,扩大感受 野,更好识别到缺陷表面的完整特征。

1 YOLOv5 网络

YOLOv5 延续了 YOLO 系列的基本思想,在 YOLOv4 的基础上进行了进一步的改进,不仅提高了检测精度,而 且相比 YOLOv4 提高了检测和学习的速度,结构也更加 紧凑。YOLOv5 通过数据加载器传输每批训练数据,同 时对训练数据进行增强。该数据加载器采用了图像自适 应缩放、颜色空间调整和 Mosaic 增强 3 种数据增强方法, 提高了小目标的检测精度和检测速度。YOLOv5 包含 5 种网络模型,分别为 YOLOv5s、YOLOv5m、YOLOv5n、 YOLOv51和 YOLOv5x,其网络结构基本相同^[21],模型的 深度和宽度依次增加,特征提取能力也逐渐提高。为节 约存储成本,提高检测速度,本文选择 YOLOv5s 作为电 池集流盘缺陷检测的参考模型。图 1 为 YOLOv5s 的模 型结构图,主要分为 Input、Backbone、Neck、Output 4 个 部分。

Input 部分为输入图像,在这一部分通常进行图像增强预处理,将输入图像按网络的输入大小进行缩放,并进行归一化操作。在训练阶段采用 Mosaic 数据增强、自适应锚框计算和自适应图像缩放方法。Backbone 部分由一系列用于提取图像特征的卷积神经网络组成,主要包括CBS、C3、SPPF 结构。Neck 部分为特征融合网络,采用了PANet 和 FPN, FPN 的结构由上而下传输语义信息, PANet 和 FPN, FPN 的结构由上而下传输语义信息, Output 部分为预测网络,通过卷积运算,输出包含类别预测框、置信度和坐标位置的3 组特征向量,分别在 80× 80、40×40 和 20×20 的尺度下进行预测。



Fig. 1 YOLOv5s frame

2 YOLOv5s 网络改进

虽然 YOLOv5s 目标检测模型在很多目标检测任务 中具有较高的精度,但在检测电池集流盘缺陷方面仍存 在漏检、误检、检测精度低等问题。因此,针对新能源汽 车电池集流盘缺陷尺寸跨度大、成片分布、目标难以区分的特点,对YOLOv5s进行改进,具体改善措施如下。

2.1 新增检测层

YOLOv5s 采用 PANet^[22]结构融合输出多尺度特征 图。PANet 是一种基于 FPN^[23]的自底向上增强结构,是 一种双向融合,由自顶向下融合路径和自底向上融合路 径组成,而不是原来的单一融合。图 2 为 PANet 的网络 结构图,其中图 2(a)是一个 FPN 结构,图 2(b)是 PAN 扩张的自底向上的特征融合层。自顶向下融合如图 3 所 示,通过 2 倍上采样对最近的特征图 X 进行适应性调整, 调整通道后通过 1×1 卷积将其添加到前层特征图 Y 中。 自底向上的融合是与自顶向下融合相反的过程,其中向 上采样被向下采样所取代。YOLOv5s 分别在 80×80、40× 40 和 20×20 尺度下实现对 small、medium、large 3 种尺寸 的目标检测,相比单尺度目标检测算法,有效提高了检 测率。



图 2 PANet 的网络结构 Fig. 2 Network structure of PANet



图 3 自顶向下融合 Fig. 3 Top-down integration

由于新能源汽车电池集流盘的表面缺陷尺寸跨度 大、缺陷种类较多,原 YOLOv5s 算法在检测重度不良这 种超大目标时,20×20 的尺度过小,无法完整覆盖,导致 重度不良这种缺陷类别检测精度不高。所以本文在 3 种 尺度的基础上,增加 10×10 大小的尺度,并使用 10×10 的 特征图与 20×20 的特征图 2 倍上采样进行融合,用于检 测超大尺寸目标,更加契合重度不良缺陷类别的尺寸。 通过改进多尺度,扩大了算法检测尺寸的范围,从而提高 目标检测的准确性,减少漏检和误检的问题。改进的结 构如图 4 所示,其中,Backbone、Neck 部分中,实线框内为 该尺度相对应的特征融合部分;Output 部分中,实线框内 为添加 10×10 的大小的尺度。



2.2 可变形卷积核

卷积层用于提取图像中的特征信息,传统的矩形卷 积通常使用固定的大小和比例的卷积核对特征图的特定 位置进行特征学习和下采样。但在同一特征层的不同位 置对应的是不同尺度和形状的目标,因此,目标检测具有 一定的局限性。为解决在卷积过程中,图像几何变换带 来的影响,将可变形卷积网络^[24]的思想融入到 Backbone 部分中。图5 为普通的卷积和可变形卷积的采样位置示 意图。通过图5(a)可知,传统卷积只有一个固定矩形结 构的采样网络。通过图5(b)可知,卷积核中每个采样点 的位置都添加一个偏移变量,通过这些变量,卷积核可以 在当前位置附近实现随机采样,突破了传统卷积的局限 性。图6 为感受野示意图,由图6 可知,可变形卷积可根 据对象的比例和形状自适应调整,变形卷积网络提出的 不规则卷积核,有效地克服了固定矩形结构采样不足的 缺点,提高了网络对物体变形的模拟能力。





图 5 传统卷积和可变形卷积采样位置示意图 Fig. 5 Schematic diagram of sampling position of traditional convolution and deformable convolution



Fig. 6 Schematic diagram of traditional convolution and deformable convolution receptive fields

2D 卷积包括两个步骤:1) 在输入特征映射 x 上使用 规则网格δ进行采样2) 由 w 加权的采样值的总和。δ定 义了感受野的大小和扩张率,如式(1) 所示,定义了一个 大小为3×3 的卷积核,扩张率为1。

$$\delta = \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\}$$
(1)

$$y(p_0) = \sum_{p_n \in \delta} w(p_n) \cdot x(p_0 + p_n + \Delta p_n)$$
(2)

式中: $y(p_0)$ 表示特征图 y 上的每个位置 p_0, p_n 枚举中 δ 的所有位置, δ 通过设置偏移量 { $\Delta p_n | n = 1, \dots, N$ } 进行 变形,形成可变形卷积。其中 $N = | \delta |$ 。由于偏移量 Δp_n 通常为小数,采用双线性插值实现表达式(3),其表达 式为:

$$x(p) = \sum_{q} g(q_x \cdot p_x) \cdot g(q_y \cdot p_y) \cdot x(q)$$
(3)

式中:p表示任意位置,将式(3)与式(2)结合得到 $p = p_0 + p_n + \Delta p_n \circ q$ 是x上的坐标, $g(q_x \cdot p_x) \exists g(q_y \cdot p_y)$ 分别为 x 和 y 方向上双线性插值核,其中 $g(a,b) = \max(0,1 - |a - b|)$ 。

通过以上分析得出,在 Backbone 部分中 20×20 检测 尺度 Block 中引入可变形卷积可以增强网络的特征学习 能力,使得采样位置更接近缺陷本身的形状和大小,更有 利于缺陷特征的提取。图7为改进后的模型图。



3 实验结果与分析

3.1 数据集

由于新能源汽车电池集流盘还没有标准的缺陷数据 集,本文实验所用的数据集为自行构建,使用从生产线上 收集的真实磷酸铁锂汽车电池集流盘缺陷数据,由高分 辨率巴斯勒工业相机在光线良好的室内环境下进行拍摄 采集。原始图像分辨率为2448×2048,在预处理阶段通 过 Python 以电极孔为中心对原始图像进行裁剪,去除无 关背景,保留有用信息,截取之后的图像分辨率为1250× 1200。使用 Lableme 数据标注工具对图片进行标注,标 注后自动生成 JSON 格式的文件,文件名与图片名始终 保持一致。图 8 为良品图像和常见的5种新能源汽车电 池集流盘缺陷类型:焊穿(weld through)、焊偏(welding offset)、无盖(no cover)、坏点(bad point)、重度不良 (severely bad)。

由于新能源汽车电池集流盘焊穿这类缺陷与电极孔 特征较为相似,为了防止误检,所以将电极孔打标签为定



图 8 良品图像和常见的 5 类缺陷

Fig. 8 Image of good products and common five types of defects

位孔(positioning hole)。为平衡 5 种缺陷的数据,避免产 生不利影响,在打标时去掉了少数不清晰的图片,最终得 到 2 000 张缺陷图像,在训练中,将数据集按照 7 : 1 : 2 的比例随机分为 1 400 张训练集、200 张验证集和 400 张 测试集。

3.2 实验设置

1)实验环境

本文实验采用的操作系统为 Windows10, CPU 型号为 Intel(R) Core(TM) i9-10900KF CPU@3.70 GHz,64 G 运行内存, GPU 为 Nvidia GTX1080ti×2, 共 22 G 显存, 所 有实验均使用 Python 3.9 编程语言完成, 采用 CUDA 11.3 和 Pytorch 1.12.1 深度学习框架。

2)损失函数

为了优化所提出 YOLOv5s-4Scale-DCN 算法的检测 精度,本文使用的损失函数为:分类损失 L_{cls} 、置信度损失 L_{obj} 和边界框回归损失 L_{box} ,总的损失为 $Loss = L_{box} + L_{obj} + L_{cls}$ 。其中, L_{box} 使用 CloU^[25](Complete IoU)损失函数; L_{obj} 和 L_{cls} 使用 BCE 损失函数和 logits 损失函数 (BCEWithLogitsLoss)。 L_{bas} 表达如下:

$$L_{box} = 1 - CIoU = 1 - \left(IoU - \frac{\rho^2}{c^2} - \alpha v\right)$$
(4)

其中, ρ为预测中心点与真实框之间的欧氏距离, c 为覆盖预测框和真实框两者的最小包围框的对角线长 度, α 为权衡参数, 表达如下:

$$\alpha = \begin{cases} 0, IoU < 0.5\\ \frac{v}{(1 - IoU) + v}, IoU \ge 0.5 \end{cases}$$
(5)

v为真实框和预测框之间的长宽比, v表示如下:

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{s^t}}{h^{s^t}} - \arctan \frac{w^p}{h^p} \right)$$
(6)

其中, wst 和 hst 为真实框的宽度和高度, w^p 和 h^p 为 预测框的相应值。

BCEWithLogitsLoss 用于测量模型目标值和输出值之间的二进制交叉熵。表达示如下:

$$L_n = -w_n [y_n \log \sigma(x_n) + (1 - y_n) \log(1 - \sigma(x_n))]$$
(7)

其中, w_n 为类别的损失权重, y_n 为目标值, x_n 为模型的输出值, σ 为 sigmoid 函数。

3)参数配置

实验参数配置如下:本文使用随机梯度下降算法优 化损失函数,输入图像大小为 640×640,批量大小设置为 20,训练批次设置为 300,初始学习率设置为 0.01,动量 被设置为 0.937,权重衰减系数设置为 0.000 5,过滤预测 框的置信阈值设置为 0.001, NMS 的 IoU 阈值设置为 0.6。其他参数设置与默认的 YOLOv5s 设置一致。

3.3 评价指标

本文采用召回率(recall, R)、平均精度(average precision, AP)、均值平均精度(mean average precision, mAP)和每秒传输帧数(FPS)4个指标对模型进行性能评估。计算如下:

$$AP = \int_0^1 p \mathrm{d}R \tag{8}$$

$$mAP = \frac{\sum_{i=1}^{N} AP_i}{N}$$
(9)

$$Recall = \frac{TP}{TP + FN} \tag{10}$$

$$Precision = \frac{TP}{TP + FP} \tag{11}$$

式中: TP (真正例)为模型预测到的正样本的数量, FP (假正例)为模型错误预测的负样本的数量, FN (假反例)为模型没有预测到的正样本的数量。AP 值为 P - R 曲线的面积。缺陷类别数为 5, 即 N = 5, mAP 值为 5 种

缺陷 AP 的平均值,mAP 的值越大,则检测模型的检测效 果越好,识别精度越高。

3.4 实验结果与分析

1)改进多尺度的实验分析

本文基于原 YOLOv5s 算法改进多尺度,提出 YO-LOv5s-4Scale 算法。为验证改进多尺度的有效性,根据 缺陷尺寸特征,增加 10×10 的检测尺度,其他部分不变, 在自制数据集上将提出的 YOLOv5s-4Scale 算法与原 YOLOv5s 算法进行对比,实验结果如表 1 所示。由表 1 可知,通过多尺度的改进,虽然算法模型的体积、参数量 以及计算量都少量增加且 FPS 略微降低,但算法仍保持 良好实时性,与原 YOLOv5s 算法相比,mAP 提高了 0.2%。由表 3 可知,改进后重度不良和焊偏缺陷类型的 检测精度得到提高。实验结果说明,改进后的 YOLOv5s-4Scale 算法通过新增检测层,提高了检测精度。

2)改进可变形卷积模块的实验分析

为了验证可变形卷积的有效性,本文将可变形卷积 结合多尺度的改进,改进后的算法称为 YOLOv5s-4Scale-DCN。为了验证融合可变形卷积的有效性以及寻找要嵌 入的具体位置,本文主要在 Backbone 部分的 4 个特征维 度融合可变形卷积,分别标记为 DCN_S、DCN_M、DCN_ L、DCN_X。其他部分不变,在自制数据集上与提出的 YOLOv5s-4Scale 算法进行对比实验,实验结果如表 2 所 示。"√"表示使用了某种改进方法。

通过表 2 可知,引入可变形卷积之后,mAP 均有提 升,相较于之前改进的 YOLOv5s-4Scale 算法,DCN_S、 DCN_M、DCN_L、DCN_X 的 mAP 分别提高了 1.7%、 0.8%、2.3%、0,且融合多个可变形卷积的效果并没有取 得更好的效果。结果表明,在改进的 20×20 尺度的检测 层融合可变形卷积效果最佳,mAP 达到了 91.0%,相比 YOLOv5s-4Scale 算法,mAP 提高了 2.3%。实验结果说 明,融合可变形卷积在一定程度上扩大了特征图的感受 野,有效提高了检测性能。

本 文 在 YOLOv5s、YOLOv5s-4Scale 和 YOLOv5s-4Scale-DCN 算法上 5 种缺陷的检测结果如表 3 所示。通 过表 3 可知,基于 YOLOv5s 算法将多尺度特征融合可变 形卷积提高了 5 种缺陷的检测精度,有效降低了误检率、 漏检率。

3) 对比实验

为了评估算法性能,将本文提出的 YOLOv5s-4Scale-DCN 改进算法与 YOLOv5s、YOLOv5l、YOLOv5m、 YOLOv5n、YOLOv5x、YOLOv7、YOLOv-tiny、YOLOv7x、 Faster R-CNN^[26]和 SSD^[27]10 种经典算法在自制据集上 进行检测性能比较,所有实验均在相同参数设置下进行。 实验结果如表4所示,由表4可知,改进后的算法,mAP 达到了91.0%,FPS 达到了113.6,相比其他算法综合效 果最佳。本文在 YOLOv5s 和 YOLOv5s-4Scale-DCN 算法 YOLOv5s 检测图、YOLOv5s-4Scale-DCN 检测图。由图可 性能,有效降低了漏检、误检的问题。

以看出,在5种常见缺陷检测中,本文所提出的 上的检测效果如图 9 所示,依次为原图、标签图、 YOLOv5s-4Scale-DCN 算法比原 YOLOv5s 算法有更好的

表1 改进多尺度验证实验

Table 1 Improved multiscale validation experiments									
算法模型	体积/MB	计算量/GFLOPs	参数量/parameters	FPS	Р	R	mAP@ 0. 5/%		
YOLOv5s	14.5	15.8	7 029 004	126.6	87.8	85.0	88.5		
YOLOv5s-4Scale	24	16.2	12 331 312	116.3	89.9	87.3	88.7		

表 2 融合可变形卷积验证实验 Table 2 Fusion deformable convolution verification experiment										
										質汁描刊
异伝侠堂	GFLOPs	parameters	P							
YOLOv5s-4Scale					24	16.2	12 331 312	89.9	87.3	88.7
YOLOv5s-4Scale-DCN_S	\checkmark				25.5	16.5	12 499 906	88.2	89.3	90.4
YOLOv5s-4Scale-DCN_M		\checkmark			26.5	16.3	12 963 394	89.4	86.5	89.5
YOLOv5s-4Scale-DCN_L			\checkmark		28.0	16.2	13 721 794	90.5	88.9	91.0
YOLOv5s-4Scale-DCN_X					30.1	16.2	14 775 106	90.1	87.2	88.7
YOLOv5s-4Scale-DCN_SL			\checkmark		28.3	16.5	13 890 388	89.2	89.8	90.4
YOLOv5s-4Scale-DCN_ML		\sim			28.3	16.5	13 890 388	89.2	89.8	90.0
YOLOv5s-4Scale-DCN_SML	\checkmark	\checkmark	\checkmark		28.2	16.8	14 535 814	89.7	87.2	90.7
YOLOv5s-4Scale-DCN_SMLX	\checkmark	\sim		\sim	34.5	16.7	16 979 096	91.7	85.8	89.8

注:改进后效果好的加粗显示。

表 3 YOLOv5s, YOLOv5s-4Scale 和 YOLOv5s-4Scale-DCN 算法上 5 种缺陷的检测结果

Table 3 Detection results of five defects on YOLOv5s , YOLOv5s-4Scale and YOLOv5s-4Scale-DCN algorithms

测量指标			Р			R			mAP		
算法		5s	5s-4Scale	本文	5s	5s-4Scale	本文	5s	5s-4Scale	本文	
	Positioning hole	97.3	97.7	97.9	100	99.8	100	98.2	99. 0	98.4	
类别	Weld through	78.5	83.3	85.1	75.7	81.0	78.4	79.3	81.1	81.7	
	Welding offset	91.6	94.0	91.5	97.6	94. 7	96.3	97.3	96.2	96. 9	
	No cover	96.6	96.3	97	100	100	100	99.5	99.5	99. 5	
	Bad point	62.8	71.5	75.4	67.8	59.3	59.6	68.3	67.8	69.9	
	Severely bad	100	96.4	96.2	68.8	88.9	100	88.5	88.6	99. 5	
	all	87.8	89.9	90.5	85.0	87.3	88.9	88.5	88.7	91	

注:改进后效果好的加粗显示。

表4 对比实验

Table 4Contrast experiment

算法模型	体积/MB	计算量/GFLOPs	参数量/parameters	FPS	Р	R	mAP@ 0. 5/%
YOLOv5s	14.5	15.8	7 029 004	126.6	87.8	85.0	88.5
YOLOv51	89.2	108.3	46 170 604	49.5	87.3	<u>88. 0</u>	88.4
YOLOv5m	40. 7	48.3	20 895 564	76.9	88.0	84.8	<u>89. 1</u>
YOLOv5n	3.9	4.3	1 773 388	137.0	86.2	85.6	88.4
YOLOv5x	173.2	203.9	86 213 788	28	87.6	83.2	84.5
YOLOv7	75	105.2	37 228 920	47.6	88.6	82.1	86.7
YOLOv7-tiny	<u>12.3</u>	<u>13. 2</u>	<u>6 031 224</u>	<u>135. 1</u>	<u>89. 7</u>	85.4	88.3
YOLOv7x	142. 2	189.0	70 855 520	29.6	86.0	86.5	88.0
Faster R-CNN	108.9	—	—	22.3	65.8	84.9	84. 7
SSD	100.3	—	—	34.5	<u>89. 7</u>	64.4	72.4
本文	28.0	16.2	13 721 794	113.6	90.5	88. <i>9</i>	91. 0

注:第一和第二好的效果分别用加粗斜体和加粗下划线突出显示,Faster R-CNN和 SSD 模型参数量和计算量无法统计。



图 9 检测结果图 Fig. 9 Test result diagram

综上所述,改进后的 YOLOv5s-4Scale-DCN 算法漏检 率低、误检率低、识别精度高、检测速度快,综合性能更 强,有效降低了误检率、漏检率。

4 结 论

本文针对新能源汽车电池集流盘的 5 种缺陷检测问题,提出一种改进的 YOLOv5 目标检测算法(YOLOv5s-4Scale-DCN)。首先,在模型的特征提取部分改进多尺度,新增10×10尺度的检测层,提高了算法对超大目标特征的学习能力;其次,融入可变形卷积,替换了传统卷积, 扩大感受野,增强了特征提取能力。通过实验结果可以 看出,本文提出的 YOLOv5s-4Scale-DCN 算法在自制的新 能源汽车电池集流盘缺陷数据集上的检测精度相比原 YOLOv5s 算法提高了 2.5%,FPS 达到了 113.6,平均精 度提高了 2.7%,召回率提高了 3.9%,增强效果显著。相 较于当前主流的目标检测算法,综合性能更强,完全满足 工业检测任务的实施要求。

参考文献

- ZHANG L, LIU Y, PANG B. China's development on new energy vehicle battery industry: Based on market and bibliometrics [C]. OP Conference Series: Earth and Environmental Science. IOP Publishing, 2020, 581(1): 012003.
- [2] 周翠英,陈英龙,路荣彬,等. 一种圆形锂离子电池的集 流盘结构及焊接方法:天津, CN114473210A [P]. 2022-05-13.
 ZHOU C Y, CHEN Y L, LU R B, et al. The utility model relates to a collecting plate structure and welding method of a circular lithiumion battery: Tianjin, CN114473210A [P]. 2022-05-13.
- [3] 于海涛,李福龙,刘亚姣,等.改进注意力机制的型 钢表面微小缺陷检测方法 [J].计算机工程与应用, 2022,58(11):250-259.
 YUHT,LIFL,LIUYJ, et al. Micro-defect detection

第37卷

algorithm with improved attention mechanism in section steel surface [J]. Computer Engineering and Applications, 2022, 58(11): 250-259.

[4] 张培培, 王昭, 王菲. 基于深度学习的图像目标检测 算法研究 [J]. 国外电子测量技术, 2020, 39(8): 34-39.

ZHANG P P, WANG ZH, WANG F. Research on image target detection algorithm based on depth learning [J]. Foreign Electronic Measurement Technology, 2020, 39(8): 34-39.

- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [6] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [7] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. arXiv preprint arXiv: 180402767, 2018.
- [8] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. arXiv preprint arXiv:200410934, 2020.
- [9] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. arXiv preprint arXiv:220902976, 2022.
- [10] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-theart for real-time object detectors [J]. arXiv preprint arXiv:220702696, 2022.
- [11] 王淑青,顿伟超,黄剑锋,等基于 YOLOv5 的瓷砖表 面缺陷检测 [J]. 包装工程,2022,43(9):217-224.
 WANG SH Q, DUN W CH, HUANG J F, et al. Ceramic tile surface defect detection based on YOLOv5 [J]. Packaging Engineering, 2022, 43(9):217-224.
- WANG T, SU J, XU C, et al. An intelligent method for detecting surface defects in aluminium profiles based on the improved YOLOv5 algorithm [J]. Electronics, 2022, 11(15): 2304.
- LI D, YAO A, CHEN Q. Psconv: Squeezing feature pyramid into one compact poly-scale convolutional layer [C]. European Conference on Computer Vision. Springer, Cham, 2020: 615-632.
- [14] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020, 2020.
- [15] 董召杰. 基于 YOLOv3 的电力线关键部件实时检测 [J].

电子测量技术, 2019, 42(23): 173-178.

DONG ZH J. Real-time detection of power transmission line key components based on YOLOv3 [J]. Electronic Measurement Technology, 2019, 42(23): 173-178.

- ZHENG Z, ZHAO J, LI Y. Research on detecting bearing-cover defects based on improved YOLOv3 [J].
 IEEE Access, 2021, 9: 10304-10315.
- [17] WANG K, TENG Z, ZOU T. Metal defect detection based on YOLOv5[C]. Journal of Physics: Conference Series, IOP Publishing, 2022, 2218(1): 012050.
- [18] 伍济钢,成远,邵俊,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测研究 [J]. 仪器仪表学报, 2021, 42(10):171-178.
 WU J G, CHENG Y, SHAO J, et al. A defect detection method for PCB based on the improved YOLOv4 [J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 171-178.
- [19] 桂久琪,李林升,毛晓,等. 基于改进 YOLOv4 的锂 电池缺陷检测方法 [J]. 电子测量技术, 2022, 45(15):144-150.
 GUI J Q, LI L SH, MAO X, et al. Lithium battery defect detection method based on improved YOLOv4 [J]. Journal of Electronic Measurement and Instrumentation, 2022, 45(15):144-150.
- [20] SAJID M, MEDAGEDARA N T. A new paradigm for waste classification based on YOLOv5 [J]. Instrumentation, 2021, 8(4): 9-17.
- [21] 王浩然,李廷会,曹玉军,等.改进YOLOv5s 网络在缺陷检测中的应用[J].网络新媒体技术,2022,11(2):58-65.
 WANG H R, LI T H, CAO Y J, et al. Application of improved YOLOv5s network in defect detection [J]. Network New Media Technology, 2022, 11(2): 58-65.
- [22] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [23] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017; 2117-2125.
- [24] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 764-773.
- ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C].
 Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [26] REN S, HE K, GIRSHICK R, et al. Faster R-CNN:

Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2015, 28.

[27] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision, Springer, Cham, 2016; 21-37.

作者简介



陈彦蓉,现为湖北汽车工业学院硕士研 究生,主要研究方向为网络通信、图像处理。 E-mail: balala0307@163.com

Chen Yanrong is a M. Sc. candidate of Hubei Institute of Automotive Technology. Her main research interests include network

communication and image processing.



高刃(通信作者),2002年于中国地质 大学(武汉)获得学士学位,2003年于荷兰 代尔夫特理工大学获得硕士学位,2012年 于武汉大学获得博士学位,现为湖北汽车工 业学院副校长,主要研究方向为智慧供应 链、网络通信。

E-mail: gaoren@huat.edu.cn

Gao Ren (Corresponding author) received his B. Sc. degree from China University of Geosciences (Wuhan) in 2002, M. Sc. degree from Technische Universiteit Delft in 2003 and Ph. D. degree from Wuhan University in 2012. He is now the vice president of Hubei Institute of Automotive Technology. His main research interests include smart supply chain and network communication.