

基于改进 YOLOv5 的太阳能电池板缺陷检测算法^{*}

朱 栋 贺 森

(常州大学微电子与控制工程学院 常州 213159)

摘要:为提高太阳能电池板缺陷的检测精确,提出了一种改进的 YOLOv5 网络,对太阳能电池板常见的划痕、叉隐、黑斑、黑边以及无电等 5 类主要缺陷进行检测和分类。首先,使用改进后的 ODConv 模块对主干提取网络中的普通卷积模块进行替换,减少网络模型的参数量;其次,将 C3 模块中的 Bottleneck 结构替换成包含 ParNet 模块的 Res2Net 以增加感受野,从而提升了探测物体缺陷的能力和检测精确;最后,在预测网络前引入自适应特征融合结构,以融合不同特征图的位置与类别信息,增强特征表达并提高模型的鲁棒性。对自建的数据集进行训练、验证以及测试,实验结果表明,改进后的模型能够成功识别和定位 5 类常见缺陷。与原 YOLOv5 算法相比,在保持原网络高效性的同时,平均检测精确提升了 6.2%。

关键词:缺陷检测;ODConv;ParNet 模块;Res2Net;特征融合

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.2

Defect detection algorithm for solar panels based on improved YOLOv5

Zhu Dong He Sen

(School of Microelectronics and Control Engineering, Changzhou University, Changzhou 213159, China)

Abstract: To enhance the accuracy of detecting defects in solar panels, an improved YOLOv5 network is proposed for the detection and classification of five common types of defects: scratches, cross hatching, dark spots, black edges, and no electricity. Firstly, the conventional convolutional modules in the backbone network are replaced with an improved ODConv module to reduce the model's parameter count. Secondly, the Bottleneck structure in the C3 module is replaced with a Res2Net containing the ParNet module to increase the receptive field, thereby improving the capability to detect object defects and the overall detection accuracy. Lastly, an adaptive feature fusion structure is introduced before the prediction network to fuse the position and category information of different feature maps, enhancing feature representation and improving the model's robustness. The model is trained, validated, and tested on a custom dataset, and experimental results demonstrate that the improved model successfully recognizes and locates the five common defects. Compared to the original YOLOv5 algorithm, the average detection accuracy is increased by 6.2%, while maintaining the efficiency of the original network.

Keywords: defect detection; ODConv; ParNet Block; Res2Net; feature fusion

0 引言

由于太阳能电池板制作工艺复杂,在制作流程过程中极易出现各种缺陷,而缺陷的存在极大降低了太阳能电池板转换效率并缩短其使用年限。因此出厂前对太阳能电池板表面的缺陷进行检测尤为重要。

目前,基于深度学习的目标检测算法包括两种,一种

是两阶段目标检测算法,首先通过算法来生成一些样本候选框,之后通过卷积神经网络(convolutional neural networks, CNN)进行样本分类。常见的两阶段目标检测的算法有 R-CNN^[1]、Faster-R-CNN^[2]等。另一种是一阶段目标检测算法,此算法直接将目标定位的问题转化成回归问题,与两阶段目标检测的区别在于不需要候选框,比较常见的一阶段目标检测算法有 YOLO 系列^[3-7]、SSD^[8]等。

收稿日期:2023-08-18

^{*} 基金项目:江苏省科技支撑项目(DFJH202131)资助

YOLO 系列算法受到更多关注, Lu 等^[9]对 YOLOv3 进行改进, 在特征金字塔网络 (FPN)^[10] 部分引入 PaNet 结构^[11], 同时引入 SimOTA^[12]。因此不仅提高了算法的速度, 也提高了检测的精确度。Chen 等^[13]对 YOLOv5 结构进行改进, 在 C3 的结构中加入 Ghost 模块^[14]改进成 C3Ghost 模块至于骨干网络中。其次添加 CA 注意力机制^[15]。最后将 ECIU_Loss 作为整体结构的损失函数。经过以上改进实现了检测速度和准确率共同优化。Li 等^[16]在 YOLOv5 的框架中引入 BottleneckCSP 模块; 然后加入 Ghost 卷积; 最后添加 FPN 和路径聚合网络 (PAN)^[17]。通过对比其检测速度与精确度都有很大的提升。胡欣等^[18]在 YOLOv5 上将 MBAM 进行融合, 有效的提升了对于 PCB 板上的小目标缺陷检测能力, 相较于原网络提升了 2%。朱宏禹等^[19]提出一种改进型的 YOLOv5s 对瑕疵缺陷进行检测, 用小目标检测层替换掉大目标检测层; 将 PANet 网络调整成加权双向特征金字塔 (BiFPN); 最后将 SENet 融入到 C3 模块中。经过改进其误检、漏检率有一定的降低, 对于精确度以及召回率也有提升。王振等^[20]在通过 YOLOv5s 减少 C3 的数量减少内部的卷积核; 以及将传统的 Conv 替换成为 GhostConv。最后通过对比改进后的网络在参数量以及计算量上有很大的减少, 同时对于检测的精确度有很大的提升。以上的研究大部分是对 YOLO 相关算法进行改进, 从而对检测的精确度进行提升。

现有相关改进算法能够实现对缺陷检测精确度的提升并取得满意的效果, 但对于通过增加感受野来提升缺陷检测精确度的改进相对较少。本文通过增加网络模型的感受野进一步提升缺陷检测的精确度, 并采集实际流水线上的相关数据自制数据集, 最后在自制数据集上通过实验验证了改进的可行性与有效性。

首先基于 YOLOv5 将改进后的全维动态卷积 (omni-dimensional dynamic convolution, ODConv)^[21] 替换掉主干网络中的 Conv 模块。其次将 Res2Net^[22] 与 ParNet 模块^[23] 进行融合, 将融合后的结构替换 C3 模型中相应部分。最后在预测层前添加自适应特征融合机制 (adaptively spatial feature fusion, ASFF)^[24]。综合以上改进, 提升算法对太阳能电池板缺陷检测的精确度。

1 改进 YOLOv5 算法结构

1.1 改进全维动态卷积

ODConv 是一种更广义但更优雅的动态卷积设计, 其主要思想是将其他卷积所忽略的 3 个维度 (空间大小、输入通道数和输出通道数) 充分利用起来。其网络结构如图 1 所示。ODConv 对于学习到的这 4 种注意相互补充, 本文为了充分利用其较高的特征提取能力, 将其替换掉主干网络部分的 Conv 模块。增强特征提取能力的, 有利于卷积网络对太阳能电池板缺陷信息的提取, 从而提高检测的精确度。

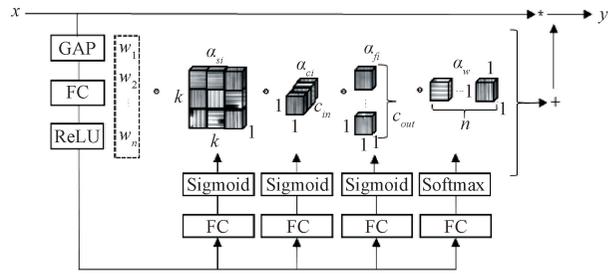


图 1 ODConv 结构

图 1 中 ODConv 利用一种新的多维注意机制, 以并行的方式沿核空间的所有 4 个维度计算 4 种类型的关注 a_{si} 、 a_{ci} 、 a_{fi} 和 a_{wi} , a_{si} 在 $k \times k$ 空间位置处为卷积参数 (每个滤波器) 分配不同的关注量; a_{ci} 为每个卷积滤波器 W_i^m 的 c_{in} 信道分配不同的关注标量; a_{fi} 为 c_{out} 卷积滤波器分配不同的注意标量; a_{wi} 将注意力标量分配给整个卷积核。ODConv 计算过程如下:

$$y = (a_{w1} \odot a_{f1} \odot a_{c1} \odot a_{s1} \odot W_1 + \dots + a_{wn} \odot a_{fn} \odot a_{cn} \odot a_{sn} \odot W_n) \times x \quad (1)$$

原有的 YOLOv5 中所使用的是普通的卷积, 现将结构上的卷积替换成 ODConv 能够很好的提升对于相关缺陷检测的准确性。本文将 ODConv 中的激活函数分别替换成 RReLU、ELU、Hardswish 和 Sigmoid 这 4 类激活函数, 实验结果如表 1 所示。经过对比将原网络中的 ReLU 激活函数更换成 RReLU 激活函数。

表 1 ODConv+各种激活函数对比 (%)

算法	Precision	mAP@0.5
YOLOv5	70.6	76.9
YOLOv5+ODConv	72.8	73.0
YOLOv5+ODConv(RReLU)	75.2	77.9
YOLOv5+ODConv(ELU)	74.4	73.6
YOLOv5+ODConv(Hardswish)	74.0	73.7
YOLOv5+ODConv(Sigmoid)	72.5	71.7

1.2 改进 Res2Net

Res2Net 的改进是将原 ResNet 中间的 3×3 卷积 (图 2(a)) 替换成 (图 2(b)) 中的结构, 此结构是经过 1×1 的卷积之后, 将特征图分成 4 部分, 第 1 条线路很简单, x_1 不做任何处理直接传输到 y_1 ; 第 2 条线路是 x_2 经过 3×3 卷积之后会有两条线路进行选择, 一条路线继续向下传播给 y_2 , 另一条会被传给 x_3 , 这样第 3 条线路就可以得到第 2 条线路的信息; 第 3 条、第 4 条以此类推。由图 2(b) 能够看出这种拆分并且混合的连接结构使 Res2Net 模块的输出包含不同的感受野大小的组合。

本文对此结构进行改进, 在最后一个 1×1 卷积后加上 ParNet 模块。图 3(a) 是 ParNet 模块结构图, 图 3(b)

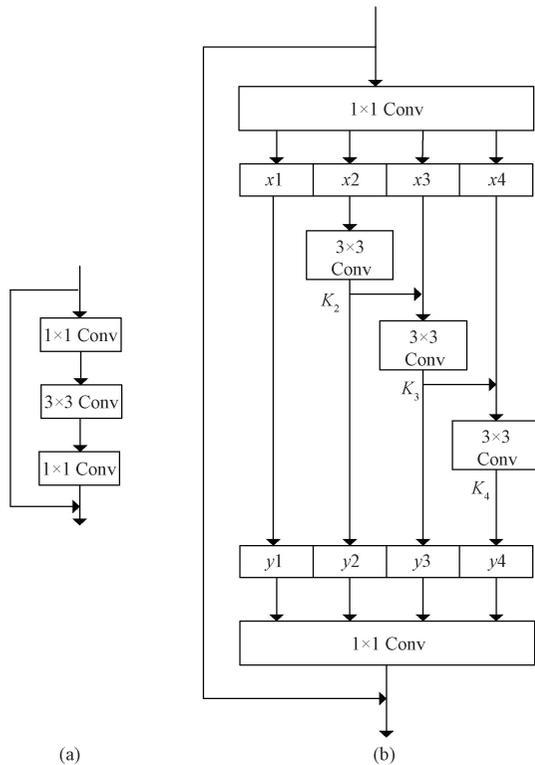


图2 (a) ResNet 结构;(b) Res2Net 结构

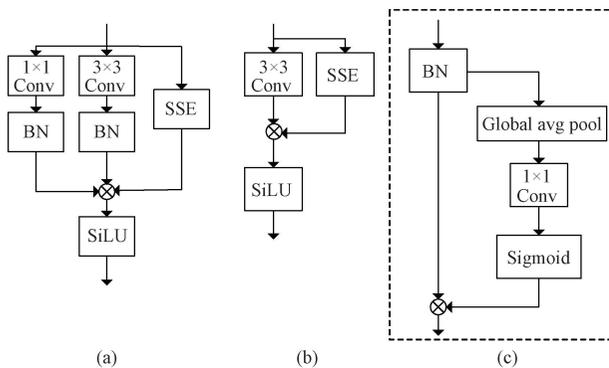


图3 (a)ParNet 模块;(b)推理时的结构;(c)SSE 模块结构

是其推理时的结构,图3(c)是 ParNet 模块中的 SSE 模块结构,改进后的模块在参数量上会有一些的增加,但感受野也会进一步增加,继而对缺陷检测精确度有一定的提升。

改进之后的结构如图4所示,图4(a)是C3的结构,图4(b)虚线框中是在 Res2Net 的最后一个卷积后面添加 ParNet 模块的结构。在最后一个卷积后面加上此模块之后将继续进行卷积操作。将其替换在原 YOLOv5 结构中 C3 模块 BottleNeck 部分。替换后的模块称为 C3_H。改进后的感受野相较于原网络有很大的增加,从而优化了卷积神经网络探测目标的能力,增加感受野可以帮助网络捕捉到更广泛的信息,使模型能够识别更大范围的特征和模式。进而提高了算法对缺陷检测的精确度。

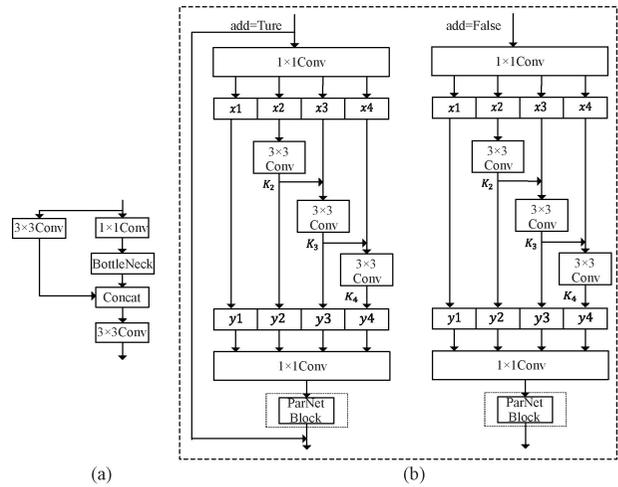


图4 (a)C3 结构;(b)改进的 Res2Net

1.3 添加自适应特征融合

已有的众多目标检测算法为了充分利用高层特征的语义信息和底层特征的线力度特征,通常会采用 FPN 架构,该架构具有较好的特征融合能力。而本文所使用的 ASFf 在训练过程中能够使每个空间位置自动学习不同尺寸特征间的融合权重,从而更加合理地利用多尺度的特征信息。

ASFf 的思想主要分成两部分,恒等缩放和自适应融合。将 Level 1、Level 2、Level 3 的语义特征与来自不同层的权重 α 、 β 、 γ ,按照式(2)的方式相乘并进行相加,融合后为 ASFf 的输出。这样的设计对学习不同特征尺度在预测特征图的贡献方面效益最佳。

$$y_{ij}^l = \alpha_{ij}^l \times x_{ij}^{l-1} + \beta_{ij}^l \times x_{ij}^{2-l} + \gamma_{ij}^l \times x_{ij}^{3-l} \quad (2)$$

式中: α_{ij}^l 、 β_{ij}^l 、 γ_{ij}^l 表示不同层的权重; x_{ij}^{l-1} 、 x_{ij}^{2-l} 、 x_{ij}^{3-l} 表示不同特征图的输出。 α_{ij}^l 、 β_{ij}^l 、 γ_{ij}^l 的计算如下:

$$\alpha_{ij}^l = \frac{e^{\alpha_{ij}^l}}{e^{\alpha_{ij}^l} + e^{\beta_{ij}^l} + e^{\gamma_{ij}^l}} \quad (3)$$

$$\beta_{ij}^l = \frac{e^{\beta_{ij}^l}}{e^{\alpha_{ij}^l} + e^{\beta_{ij}^l} + e^{\gamma_{ij}^l}} \quad (4)$$

$$\gamma_{ij}^l = \frac{e^{\gamma_{ij}^l}}{e^{\alpha_{ij}^l} + e^{\beta_{ij}^l} + e^{\gamma_{ij}^l}} \quad (5)$$

1.4 改进后的网络结构

改进后的 YOLOv5 结构如图5所示,为了更好的提高对于太阳能电池板缺陷检测的精确度,在 Backbone 处的第1层、第3层、第5层、第7层分别加入 ODCConv,其多维注意力机制对卷积沿位置、通道、滤波器以及核4个维度进行学习,进而捕获丰富的上下文信息,从而可以大幅提升卷积的特征提取能力。并将 Backbone 中的 C3 模块替换成改进后的 C3_H 模块,对于网络的感受野进行提升,增加感受野可以帮助网络捕捉到更广泛的信息。进而

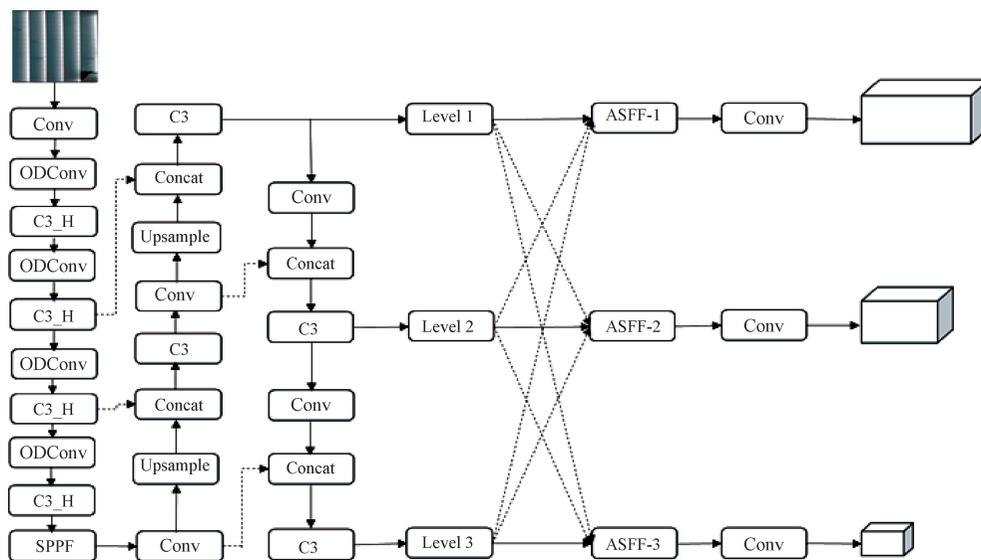


图5 改进后的算法框图

提升算法对太阳能电池板缺陷检测精确度。最后,在预测网络前引入 ASFF,通过对每张融合的特征图设置自学习的权重来进行加权融合,从而更加合理的利用高层次的语义信息和低层的特征。

2 实验结果及分析

介绍数据集的各项分类以及前期的预处理,然后对训练的各项数据进行讨论分析,将对对比试验与消融实验与检测基线进行比较。

2.1 数据集

实验数据集使用的是某公司现场采集到的图像样本,对其进行裁剪并进行打标签处理。该数据集由专用相机进行拍摄,原始图像尺寸为 $4\,043 \times 643$ pixels 的太阳能电池板模块图像,因原图像是长方形长度较长,并且图片内容中存在一些不需要的部分,对图片进行手动裁剪将需要进行检测的缺陷部分单独裁剪出来,裁剪出的大小统一为 600×600 pixels,总共图片有 7 377 张。按照 7 : 2 : 1 的比例进行划分为训练集、验证集和测试集,划分检测的缺陷分别为划痕共有 4 675 张、叉隐共有 354 张、黑点共有 3 420 张、黑边共有 230 张和无电共有 112 张(总数会超过数据集是因有些照片中有多种缺陷)这 5 类如表 2 所示。

2.2 实验平台与评价指标

实验在 YOLOv5 的基础上进行,实验平台使用的 CPU 型号为 AMD Ryzen7 5800H 3.2 GHz,内存 16 GB, GPU 型号为 NVIDIA GeForce RTX 3060。采用 64 位 Window11 操作系统,以 Pycharm 作为开发平台,Pytorch 作为深度学习框架,Python 为编程语言,并使用 CUDA11.2 版本为并行计算框架。

本文采用精确度(precision)、召回率(recall)和平均精度均值(mean average precision, mAP)作为模型的评价

表 2 缺陷数据

名称	相关图片
划痕	
叉隐	
黑点	
黑边	
无电	

指标。

2.3 消融实验

为了验证改进后算法在太阳能电池板缺陷检测的有效性,在消融实验的过程中,均保持相同的参数设置,本节使用的数据根据某公司提供图片自建的数据集。通过实验来验证各个模块的有效性,其结果如表 3 所示。

算法	Precision	Recall	mAP@0.5
YOLOv5	73.6	74.8	77.3
YOLOv5+ODConv	75.4	76.7	77.9
YOLOv5+C3_H	76.6	77.1	78.0
YOLOv5+ASFF	76.8	77.9	78.4
YOLOv5+ODConv+C3_H	77.3	79.2	81.3
YOLOv5+ODConv+ASFF	78.2	79.0	80.5
YOLOv5+C3_H+ASFF	77.5	76.8	80.3
本文	79.8	83.9	84.7

1)改进的 ODConv 网络的有效性。

为了能够更多的提取到图片中的各种特征信息,将原网络 Backbone 结构处的 Conv 网络替换成改进后的 ODConv 网络,精确度相较于原 YOLOv5 提升了 1.8%,这是因为其同时考虑了位置、通道、滤波器以及核等维度,进而能够更好地捕获丰富的上下文信息。

2)改进的 C3_H 模块的有效性。

将改进后的 Res2Net 替换原 C3 中 BottleNeck 部分,在增加卷积神经网络感受野的同时使检测精确度有一定的提升,精确度相较于原 YOLOv5 提升了 3.0%。

3)添加 ASFF 自适应特征融合的有效性。

为了能够高效地利用太阳能电池片图像中的各种特征信息,在最后的预测层前添加 ASFF,精确度相较于原 YOLOv5 提升了 3.2%,添加 ASFF 后能够通过每张融合的特征图设置自学习权重来进行加权融合,从而更加合理地利用高层的语义信息和低层的特征。

2.4 实验结果分析

不同网络结果数据如表 4 所示,可知,在自制太阳能电池片的数据集上,本文改进的网络模型比当前主流网络 YOLOv3、YOLOv5、YOLOv7 和 YOLOv8 在精确度、召回率和平均精度均值上都有着较好的表现。实验结果表明,改进的模型检测精确度分别比 YOLOv3 提高了 4.1%、比 YOLOv5 提高了 6.2%、比 YOLOv7 提高了

算法	Precision	Recall	mAP@0.5
YOLOv3	75.7	71.7	75.1
YOLOv5	73.6	74.8	77.3
YOLOv7	70.0	71.7	72.6
YOLOv8	78.6	80.4	81.1
本文	79.8	83.9	84.7

9.8%、比 YOLOv8 提高了 1.2%,与上述主流网络模型相比,改进后的模型 mAP@0.5 最高比 YOLOv7 提高 12.1%了。

2.5 检测效果对比

改进前后部分样本检验结果如图 6 所示,可以看出,改进后的网络能够检测出原网络中漏检的缺陷以及一些不明显的缺陷。图 6(a)改进前的网络检测出原网络未检测出的黑点缺陷,图 6(b)改进后的网络将不太明显的黑边缺陷进行检测出来。可以看出,改进后的网络对于各种缺陷的检测在同样的环境下检测的准确性有一定的提升,而且缺陷边框回归准确性比原网络也有提高。

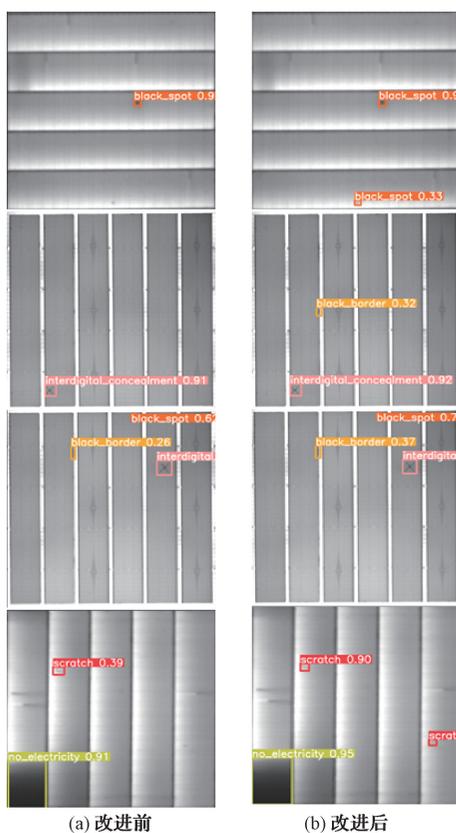


图 6 改进前后部分样本检验结果

3 结论

本文提出了一种改进的目标缺陷检测算法。首先,在 YOLOv5 算法的基础上,将骨干网络上的卷积网络替换成 RReLU 激活函数的 ODConv,更换卷积之后增加了网络的通道数。因此对于缺陷的特征提取能力有很大的提升。其次,本文将 C3 结构进行改进,将 ParNet 模块融合到 Res2Net 模块中,最后整合到 C3 模块中从而增大检测网络的感受野,进一步提高了探测缺陷目标的能力。最后,在检测前添加上 ASFF 自适应特征融合,从而能够更加合理地利用多尺度特征信息。增加了模型的鲁棒性。

实验结果表明,改进后的算法在数据集上表现良好,在保持原算法高效性的同时,缺陷检测的精确度提高了6.2%。

参 考 文 献

- [1] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2014: 580-587.
- [2] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137-1149.
- [3] REDMON J, FARHADI A. YOLOv3: An incremental improvement [EB/OL]. (2018-04-08) [2023-08-10]. <https://arxiv.org/abs/1804.02767>.
- [4] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [EB/OL]. (2020-04-23) [2023-08-10]. <https://arxiv.org/abs/2004.10934>.
- [5] JOCHER G, STOKEN A, BOROVEC J, et al. Ultralytics/YOLOv5: V3. 1—Bug fixes and performance improvements [EB/OL]. (2020-10-29) [2021-01-19]. <https://zenodo.org/record/4154370>.
- [6] LI C, LI L, JIANG H, et al. YOLOv6: A single-stage object detection framework for industrial applications [EB/OL]. (2022-09-07) [2023-08-10]. <https://arxiv.org/abs/2209.02976>.
- [7] WANG C, BOCHKOVSKIY A, LIAO H. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [EB/OL]. (2022-07-06) [2023-08-10]. <https://arxiv.org/abs/2207.02696>.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, 2016: 21-37.
- [9] LU Z Y, LIU B L. Remote sensing image object detection method based on improved YOLOv3 [J]. International Journal of Advanced Network, Monitoring and Controls, 2022, 7 (4): 1-8.
- [10] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 2117-2125.
- [11] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2018: 8759-8768.
- [12] GE Z, LIU S T, LI Z M, et al. OTA: Optimal transport assignment for object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2021: 303-312.
- [13] CHEN X L, LIAN Q W, CHEN X L, et al. Surface crack detection method for coal rock based on improved YOLOv5 [J]. Applied Sciences, 2022, 12(19): 9695.
- [14] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 1580-1589.
- [15] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobilenetwork design [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2021: 13713-13722.
- [16] LI L L, WANG Z F, ZHANG T T. GBH-YOLOv5: Ghost convolution with bottleneck CSP and tiny target prediction head incorporating YOLOv5 for PV panel defect detection[J]. Electronics, 2023, 12 (3): 561.
- [17] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 11534-11542.
- [18] 胡欣,胡帅,马丽军,等.基于融合 MBAM 与 YOLOv5 的 PCB 缺陷检测方法[J/OL].图学学报,1-9[2024-03-07]. <http://kns.cnki.net/kcms/detail/10.1034.T.20231107.1108.002.html>.
- [19] 朱宏禹,韩建宁,徐勇.基于改进型 YOLOv5s 的印刷线路板瑕疵检测 [J]. 国外电子测量技术, 2023, 42(3):152-159.
- [20] 王振,方海峰,曹晋,等.基于 YOLOv5s 的轻量化可回收饮料瓶颜色识别 [J]. 国外电子测量技术, 2023, 42(3):160-166.

- [21] LI C, ZHOU A J, YAO A B. Omnidimensional dynamic convolution[EB/OL]. (2022-01-29) [2023-08-10]. <https://arxiv.org/pdf/2209.07947>.
- [22] GAO S H, CHENG M M, ZHAO K, et al. Res2Net: A new multi-scale backbone architecture [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652-662.
- [23] GOYAL A, BOCHKOVSKIY A, DENG J, et al. Non-deep networks [J]. Advances in Neural Information Processing Systems, 2022, 35: 6789-6801.
- [24] LIU S T, HUANG D, WANG Y H. Learning spatial

fusion for single-shot object detection [EB/OL]. (2019-11-21) [2023-08-10]. <https://arxiv.org/abs/1911.09516>.

作者简介

朱栋,副教授,硕士生导师,主要研究方向为图像处理、计算电磁学(FDTD)、微纳光子学、数字信号处理等。
E-mail:zhudong@cczu.edu.cn

贺森,硕士研究生,主要研究方向为图像处理、计算机视觉等。
E-mail:s22060858006@smail.cczu.edu.cn