

DOI:10.19651/j.cnki.emt.2211835

基于改进 YOLOv5 的电子粉涂覆不均检测^{*}

戴思璇 何青 唐琼霜 洪巍

(长沙理工大学电气与信息工程学院 长沙 410114)

摘要: 放电管生产过程中,电极表面电子粉涂覆是否均匀是影响放电管产品质量的关键,目前主要依赖于人工目检,针对人工检测效率低、精度差等问题,提出一种基于改进 YOLOv5 的电子粉涂覆不均检测算法。首先,采集电极表面电子粉涂覆的图像制作数据集,并进行数据增强;其次,引入 STDC 模块优化主干特征提取网络,提高对难以辨认的金属电极表面缺陷不均的检测精度,并生成两个特征图以适应数据集;最后使用 K-means++聚类优化自适应锚框计算。实验结果表明:改进 YOLOv5 算法对电子粉涂覆不均检测的 mAP@50 达到 99.22%,与原 YOLOv5 网络相比提升了 6.84%,大大提升了检测精度,相较于人工检测其效率更高。

关键词: 放电管;缺陷检测;YOLOv5;STDC 模块;K-means++聚类

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 510.1050

Improved YOLOv5-based for detection of uneven coating of electronic powders

Dai Sixuan He Qing Tang Qiongshuang Hong Wei

(School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: In the process of gas discharge tube production, the uniformity of electronic powder coating on the electrode surface is the key to the quality of gas discharge tube products, it is mainly detected by human eyes now. Aiming at the problems of low efficiency and poor accuracy of manual detection, an uneven electronic powder coating detection algorithm based on improved YOLOv5 is proposed. Firstly, the collected images of electron powder coating on the electrode surface are made into data sets, and data enhancement was performed. Secondly, the STDC module is used to optimize the backbone feature extraction network, to improve the detection accuracy of uneven surface defects of hard-to-recognize metal electrodes, and two feature layers are generated for adapting to the dataset size. Finally, Kmeans++ clustering is used to optimize the computation of adaptive anchor boxes. The experimental results show that the mAP@50 of the improved YOLOv5 algorithm proposed reaches 99.22%, which is 6.84% higher than that of the original YOLOv5 network, greatly improving the detection accuracy, and is more efficient than manual detection.

Keywords: gas discharge tube; defect detection; YOLOv5; STDC Block; K-means++ clustering

0 引言

陶瓷气体放电管是一种浪涌保护元器件,广泛应用于防雷工程中,由陶瓷管和两个或两个以上金属电极构成密闭空间,电极表面涂有电子发射材料电子粉,电子粉的涂覆是否均匀是影响气体放电管性能的关键。目前实际生产中对于电极表面的电子粉涂覆不均检测主要依靠人工,传统人工检测存在效率低、耗时长、成本高、劳动强度大、人眼的分辨率有限并带有主观意识等问题^[1]。目前电子粉涂覆相关自动检测及智能评阅机制的研究鲜有报道,尚未形成高

效标准化的检测方法。为实现电子粉涂覆检测的智能化,可以将其作为缺陷检测问题进行研究。目前主流的缺陷识别方法主要有传统方法和深度学习方法^[2]。

传统的图像处理方法先对样本图像进行预处理,人为从图像中提取特征进行图像检测,克服了人工检测的效率低下、易受主观因素影响的缺点。Zhou 等^[3]提出了一种基于稀疏表示的瓶盖表面缺陷快速检测的方法,在瓶盖表面提取圆形区域作为感兴趣区域,通过构建模板字典与缺陷字典进行匹配,利用稀疏因子对盖面缺陷进行定位。Zhang 等^[4]将 curvelet 变换和 Canny 边缘检测相结合,对轮廓

收稿日期:2022-10-25

*基金项目:国家自然科学基金(62103063)项目资助

胎激光剪切图像进行分割和分析。

随着计算机视觉技术的不断发展,基于深度学习的检测方法得到广泛应用。深度学习算法主要分为单阶段和两阶段两大算法,其中单阶段检测算法以 SSD(single shot MultiBox detector)^[5]、YOLO(you only look once)系列^[6-7]算法为代表,两阶段检测算法以 R-CNN(regions with CNN features)^[8],Fast R-CNN^[9],Faster R-CNN^[10]为代表。相较于两阶段检测算法将目标检测任务分为特征提取和特征回归两个步骤,单阶段检测算法将目标的分类和位置定位当成一个整体,大大减少计算量,同时在检测速度上表现出不凡实力。彭伟康等^[11]提出采用 ResNet101 改进 Faster R-CNN 特征提取网络检测气泡水平尺中的核心部件水准泡缺陷,并融合递归特征金字塔(recursive feature pyramid, RFP)进行多尺度特征输出,增强模型检测能力。伍济钢等^[12]使用改进二分 K-means 聚类算法确定锚框,引入轻量化网络改进 YOLOv4 算法,提升对 PCB 缺陷小目标的检测。马燕婷等^[13]将 Transformer 层与 BiFPN 网络结构相结合,并使用轻量化网络 RepVGG 增强网络特征提取能力,实现了带钢表面缺陷检测的精度提升。

在工业生产中,YOLOv5 算法在缺陷检测领域中表现较为出色,王年涛等^[14]采用 Ghost 模块替代 YOLOv5 主干网络中的残差块,并引入 GIoU 损失函数,提高绝缘子缺陷的检测精度。颜学坤等^[15]在 YOLOv5 的主干网络中加入 CBAM(convolutional block attention module)注意力机制模块,并修改网络检测层,实现了对印花图案疵点检测精度与速度的优化。可以看出基于 YOLOv5 的改进主要在于主干网络的改进,但是金属电极表面光学特性非常多样,并且在生产环境中背景复杂,使这些改进算法应用于电子粉涂覆检测中效果不佳,存在漏检现象。所以本文对 YOLOv5 模型进行针对性改进,以适用于检测电极表面电子粉涂覆是否均匀。首先,将工业生产现场环境下的电极表面电子粉涂覆图像样本制作成电子粉涂覆数据集,并进行数据增强实现样本的扩充,提升样本的多样性;其次借鉴实时语义分割特征提取网络中的短期密集级联模块(short-term dense concatenate, STDC)^[16]模块优化主干特征提取网络,减少计算量并融合多尺度信息,为适应电子粉涂覆样本调整网络的检测模块,生成两个特征图层;最后使用 K-means++ 算法分析电子粉涂覆样本,重新聚类生成优化 Anchor Boxes 进行训练。改进后的网络对电子粉涂覆不均有更好的检测效果。

1 YOLOv5 模型

YOLOv5 算法融合了 YOLO 系列算法之前各版本的优点,目前已经发展到 V7.0 版本,并且持续在更新,根据网络深度与宽度的不同可分为 x,l,m,s,以及更小的 Nano 版本。

YOLOv5 主要由 Input、Backbone、Neck 和 Prediction4

个部分构成。Input 端的输入采用 Mosaic 数据增强方法,对 4 张图片进行随机缩放、随机裁剪和随机排布拼接起来,丰富数据集检测目标背景,同时大大提升网络训练速度。并使用自适应锚框计算初始锚框参数,再将图片统一缩放至标准尺寸送入检测网络。Backbone 由 Focus 结构、CSP1 结构和空间金字塔池化(spatial pyramid pooling, SPP)结构进行特征提取,Neck 网络部分则分别通过自上而下和自下而上的路径构成特征金字塔网络(feature pyramid network, FPN)和路径聚合网络(path aggregation network, PAN)结构,获取更多上下文的语义信息。最后由 Prediction 端输出 3 个特征层,使用加权非极大值抑制(non-maximum suppression, NMS)处理冗余预测框。

2 改进的 YOLOv5 模型设计

本文使用的数据集样本为电极表面的电子粉涂覆图像,对获取的原始图像进行缺陷标注时发现,由于电极材质是金属,金属表面缺陷特征具有照明不均匀、强反光和产生背景噪声等问题,对其难以辨认,从而影响检测精度。语义分割网络中的 STDC 模块更关注浅层的细粒度信息,满足电子粉涂覆不均检测精度。

2.1 改进主干网络

本文保留输入的 Focus 操作,在 YOLOv5 的主干特征提取网络中添加 STDC 模块代替 CSP1 结构和 SPP 结构,改进后的整体算法结构如图 1 所示。

网络的输入图片尺寸为 $640 \times 640 \times 3$,首先进行 Focus 操作,经过 slice 切片后输出 $320 \times 320 \times 12$ 的特征映射,后接 32 个 1×1 的卷积核获得 $320 \times 320 \times 32$ 的特征映射,使用 Focus 操作对输入图片进行裁剪堆叠可以减少计算量和参数量。Focus 操作后再利用卷积核为 3×3 、步长为 2 的 CBL 模块进行低层特征的提取,其中 CBL 模块由“Conv 层 + BN 层 + LeakyReLU 层”构成,得到输出特征为 $160 \times 160 \times 64$ 。

Stage1、stage2 和 stage3 分别使用若干个 STDC 模块进行网络调整,其中每个阶段中的第一个 STDC 模块均以 2 的步长进行下采样操作,实现下采样率为 $1/8, 1/16, 1/32$ 的特征映射,其空间分辨率分别为 80、40、20,通道数分别为 128、256、512。然后再重复使用步长为 1 的 STDC 模块进行特征提取,stage1 中重复 3 次,stage2 中重复 4 次,stage3 中重复 2 次。

改进后的主干网络结构如表 1 所示,表中 S 表示卷积步长,R 表示 STDC 模块重复的次数,C 表示输出的通道数。STDC 模块的显著优点是降低计算复杂度,保留丰富的尺度信息,更加关注浅层细节信息。通常随着网络加深卷积通道数逐渐增加,通道信息也逐渐增强,而 STDC 模块则通过足够的通道数进行浅层细节特征的提取,在深层逐渐降低特征维数,再将浅层与深层的特征进行融合,丰富特征信息。

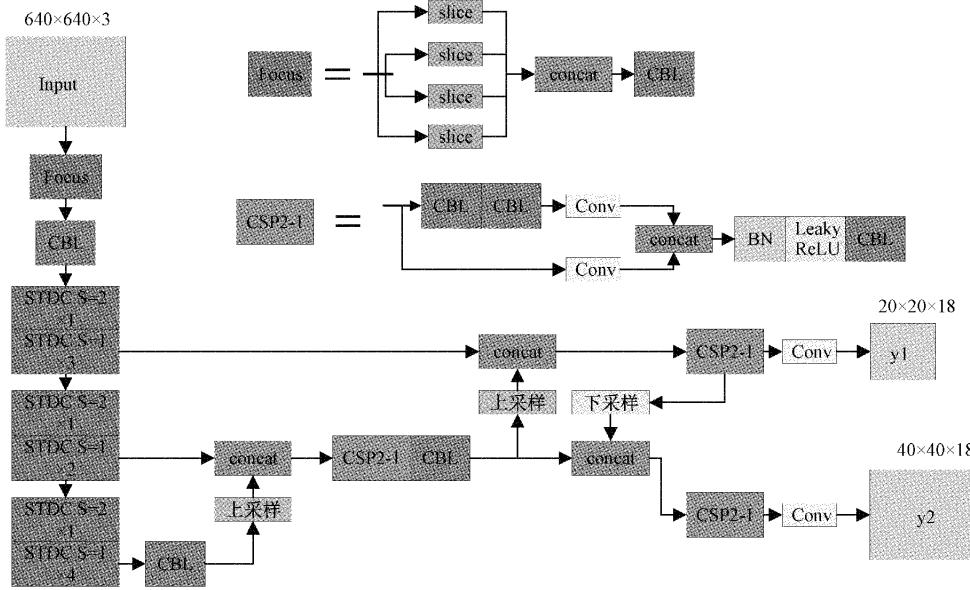


图 1 改进 YOLOv5 算法结构

表 1 改进主干网络结构

Stage	Output Size	STDC		
		S	R	C
Input	640×640			3
Focus	320×320		1	32
CBL	104×104	2	1	64
stage 1	80×80	2	1	128
	80×80	1	3	
stage 2	40×40	2	1	256
	40×40	1	4	
stage 3	20×20	2	1	512
	20×20	1	2	

改进主干网络中的关键组件 STDC 模块的结构如图 2 所示, STDC 模块通过增加浅层特征通道数, 减少深层特征通道数, 增强网络细节信息的学习, 避免由于网络中深层特征通道数过多而导致的信息冗余。其中 M 表示输入特征的通道数, N 表示输出特征的通道数, 图 2(a)表示步长为 1 的 STDC 模块, 图 2(b)表示步长为 2、进行下采样的 STDC 模块。

一个 STDC 模块被分为几个 Block, 每个 Block 均由不同卷积核大小的 CBL 模块进行操作, 除第一个块的卷积核设置为 1×1 进行维度匹配外, 其余设置为 3×3 进行特征信息的提取, Block 数量选取 4。输入特征的通道数 M 依次经过 Block1、2、3、4 后, 输出特征通道数变为 $N/2, N/4, N/8, N/8$, 最后一个 Block 的特征通道数和前一个 Block

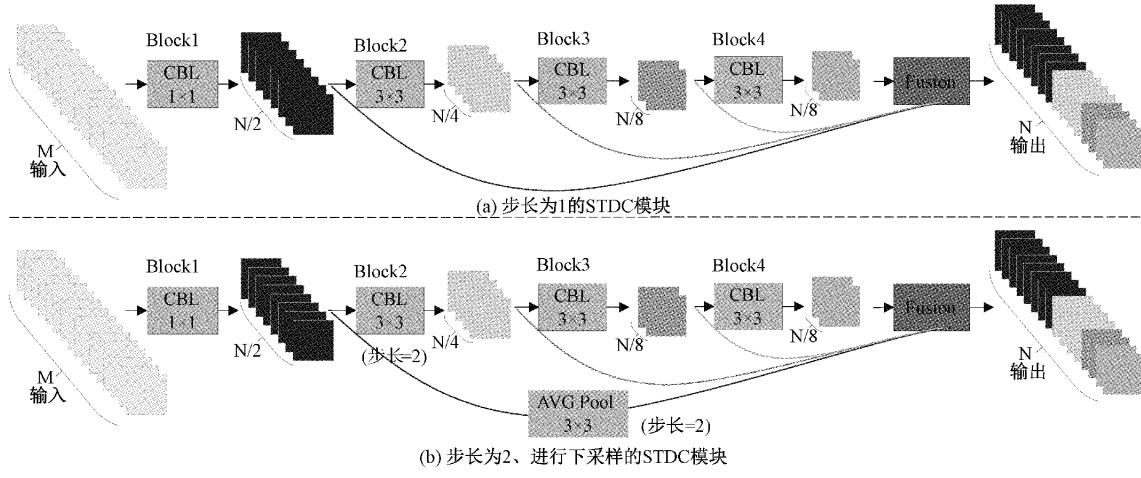


图 2 STDC 模块结构

的相同, 逐渐减小输出特征通道数可以显著降低计算复杂度, 加快模型收敛速度。将每个 Block 的输出特征映射通

过 concat 操作进行连接, 得到最终的 STDC 模块的输出为 4 个 Block 输出特征的融合。

对于图 2(b)的 STDC 模块,在 Block2 处以步长为 2 的卷积层代替最大池化层进行下采样运算,将特征尺寸降低一倍,以防止信息丢失,同时为保证融合特征时尺寸匹配对特征图进行步长为 2、卷积核为 3×3 的平均池化操作。

2.2 改进特征层

原始 YOLOv5 网络有大、中、小 3 个尺寸的特征图,在自制的电子粉涂敷不均数据集中,样本图片的缺陷大小适应原始网络的中尺寸和大尺寸特征图,为建立缺陷框与网络预测值的科学对应关系,使网络获取合理的样本标签值去计算损失,能够针对数据输入得到正确的目标,高效训练网络,本文保留两个特征层。由 stage1、stage2 和 stage3 输出的特征图进行 Neck 网络的 FPN 和 PAN 操作,分别输出 $40 \times 40 \times 18$ 维和 $20 \times 20 \times 18$ 维的张量进行预测,其中 18 是由 $(3 \times (5+1))$ 计算得到的,3 表示每个尺度的 3 组先验框,5 表示先验框中的预测物体的置信度以及中心点的 $x, y, w, h, 1$ 表示数据集中的不均匀类别。

2.3 改进聚类算法

YOLOv5 算法中自适应锚框使用 K-means 算法随机选择初始聚类中心,而不同的初始聚类中心得到的最终聚类结果相差很大,Anchor 设计得不合理会给模型收敛带来困难,影响模型的检测效果。本文采用 K-means++ 算法进行聚类可以提升检测精度,获得的 Anchor Boxes 更适应本文数据集特征。

K-means++ 算法通过保证初始的聚类中心之间的距离尽可能远来选择较优的聚类中心,具体流程为在数据集中随机选取一个样本作为第 1 个聚类中心,计算每个样本与当前聚类中心的 IoU,选出 IoU 最小的点作为第 2 个聚类中心,迭代以上步骤直到找到 K 个聚类中心,后续步骤与 K-means 算法相同。采用 K-means++ 聚类算法最终产生的 6 个 Anchor Boxes 为 $(41, 41), (34, 74), (51, 51), (57, 57), (66, 71), (74, 76)$, 聚类结果如图 3 所示,横纵轴坐标 box_w 和 box_h 分别表示先验框的宽和高。

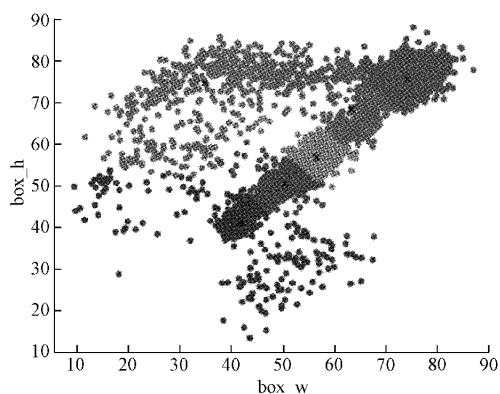


图 3 K-means++聚类结果

3 样本训练

3.1 样本数据集

本文从放电管生产车间获取了一批电子粉涂覆的图片,经过整理得到 6 000 张包含多个缺陷的照片,按照 9 : 1 的比例划分训练验证集和测试集,在训练验证集中按照 9 : 1 划分训练集和验证集,得到训练集 4 860 张,验证集 540 张,测试集 600 张。其中检测的缺陷种类数为 1,利用 labelImg 图像标注工具获取样本信息。在实际生产中,不同环境下采集的图像存在较大差距,可能会影响到模型的检测效果,同时也为了防止网络过拟合,本文采用随机水平、垂直翻转、随机填充与尺度变换等方式扩充数据集,不影响样本特性,增强模型的鲁棒性。

3.2 网络训练

网络训练 400 个 epoch,采用余弦退火学习率衰减^[17]方式,训练过程中学习率以线性增加和余弦函数下降的形式在预设的学习率上限和下限之间重复,从各局部最优点中选取最优值,最大学习率设置为 0.001,最小学习率设置为最大学习率的 10^{-2} 倍,权重衰减系数设置为 0.0005,动量参数设置为 0.937,Batchsize 设置为 8,使用 SGD 优化算法进行参数优化。改进 YOLOv5 算法的迭代损失曲线如图 4 所示,smooth loss 表示对 loss 进行平滑处理。

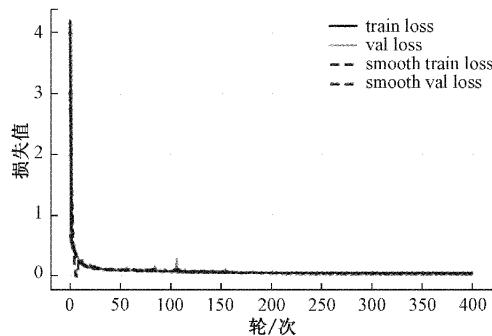


图 4 训练损失下降曲线

4 实验结果分析

4.1 模型复杂度分析

本文对原始 YOLOv5 模型和改进后模型进行复杂度分析,主要采用模型权重大小、参数量以及模型计算量作为分析指标,模型复杂度对比如表 2 所示,可以看出改进后的模型权重大小、参数量和计算量都大大缩减。

表 2 模型复杂度对比

模型	权重大小	参数量	计算量
原始 YOLOv5 模型	27.138 M	7 276 605	17.060 G
改进 YOLOv5 模型	20.144 M	5 210 788	13.903 G

4.2 检测效果

在深度学习常用以下评估指标为实验结果评估,分别

为: 精确度 (Precision)、召回率 (Recall)、平均精度均值 (mean average precision, mAP) 等。其中精确度又称为查准率、准确率, 主要用于衡量模型的检测精度, 表示为预测为真的预测框中预测正确的比例; 召回率也被称为查全率, 用于衡量模型找到所有相关目标的能力, 表示为所有样本目标被正确预测出来的比例, 计算方法如下:

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

其中, TP 表示模型预测为真, 实际也为真的样本数; FP 表示模型预测为真, 但实际为假的样本数; FN 表示预测为假, 但实际为真的样本数。

本文通过设置预测框与真实样本边界框之间的 IOU 阈值大小获得不同的查准率和查回率, 各 IOU 精确度和召回率所组成的 PR 曲线围成的面积为 AP, 常用性能评估指标 mAP 为所有类别的平均检测准确率, 在本文中仅检测不均匀这一项缺陷类别, 计算公式如下:

$$mAP = AP = \int_0^1 P(R)dR \quad (3)$$

针对自制的电子粉涂覆数据集, 使用以上评估指标得到本文算法检测效果如图 5 所示。

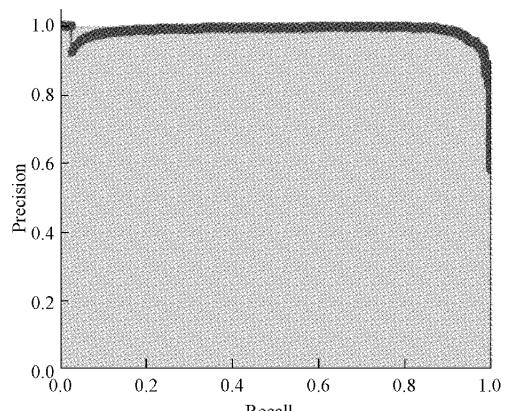
4.3 模型消融实验

本文为验证原始 YOLOv5 网络在添加所提各项改进方法前后对电子粉涂覆不均检测效果的影响, 设计了消融实验。消融实验结果如表 3 所示, 检测效果图如图 6 所示, 其中“√”表示使用对应方法, 表 3 各项评价指标最优加粗表示。为更全面性验证模型, 本文还选取了 mAP@50:5:95 值作为评估指标。

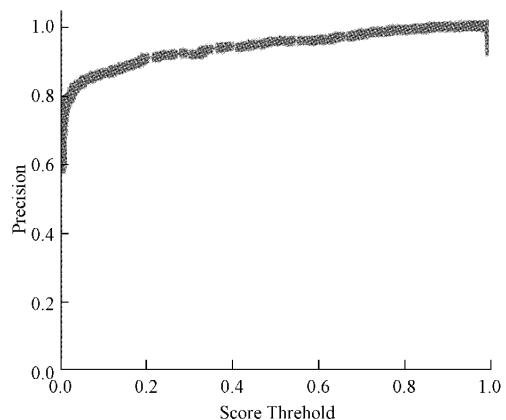
原始 YOLOv5 算法在电子粉涂覆不均数据集的 mAP@50 能达到 92.38%, 其精确度和召回率均在 80% 以上, 但是从检测效果中可以发现存在漏检误检的现象, 同时检测框尺寸也存在误差。

算法 1 表示对原始 YOLOv5 的主干网络进行优化, 添加 STDC 模块改进特征提取网络, 从实验结果可以看出模型检测精度得到大幅度提升, 误检现象减少。此改进方法具有积极影响, 能够获取更细粒度的特征信息, 减少计算量和参数量, 大大提升网络的检测精度。

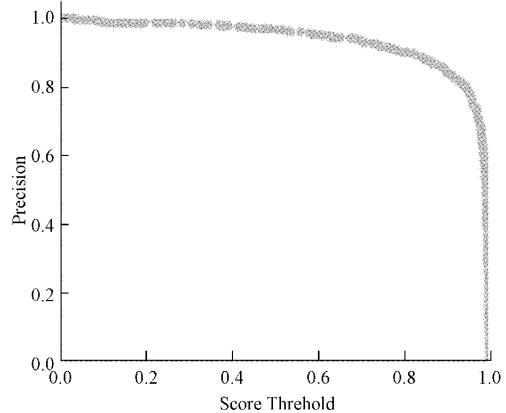
算法 2 表示在优化主干特征网络的基础上保留了



(a) 不均匀缺陷的AP图



(b) 不均匀缺陷的Precision图



(c) 不均匀缺陷的Recall图

图 5 改进 YOLOv5 算法的检测结果

表 3 消融实验结果

检测算法	主干网络 改进	特征图 改进	聚类算法 改进	Precision	Recall	mAP@50	mAP@50:5:95
原始 YOLOv5 算法				85.56	81.91	92.38	68.20
算法 1	√			89.34	89.15	95.45	77.80
算法 2	√	√		91.73	96.81	98.59	80.90
改进 YOLOv5 算法	√	√	√	95.18	96.60	99.22	81.00

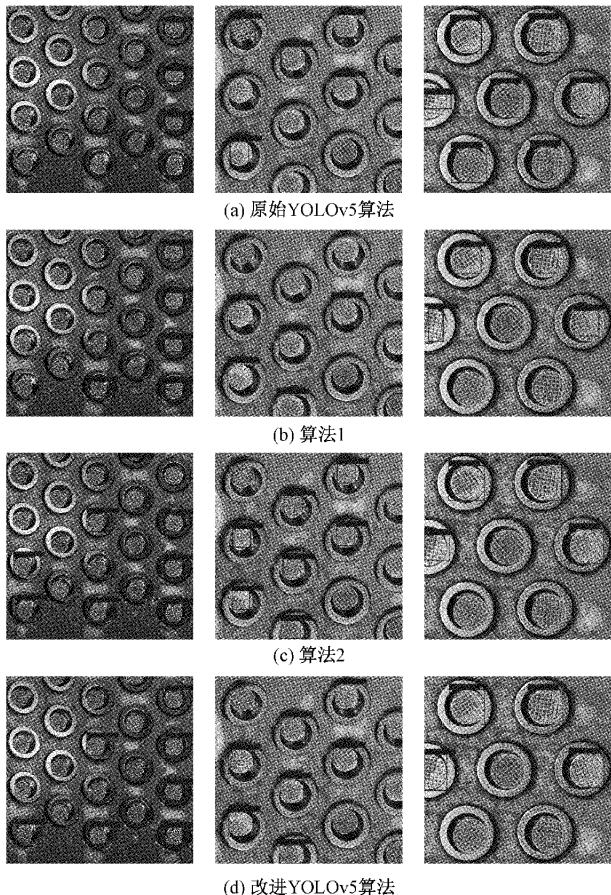


图 6 检测效果对比

$20 \times 20, 40 \times 40$ 两个特征图尺寸, 模型的召回率提升了 7.66%, 此种改进方法有效增加了有缺陷样本被预测出来的概率, 能够有效避免漏检的失误, 在实际生产中要确保放电管制作过程中不使用电子粉涂覆不均匀的电极, 否则影响放电管性能会产生严重后果。

在算法 2 的基础上使用 K-means++ 算法聚类获得先验框再进行训练, 得到本文所提出的改进 YOLOv5 算法。可以看到检测效果优秀, 没有漏检误检现象, 检测框尺寸合适, 同时实验结果显示各项评估指标都表现优异, 与原始 YOLOv5 网络对比, mAP@50 达到了 99.22%, mAP@50:5:95 也提升了可观的 12.8%。

4.4 与主流检测算法对比实验

设置消融实验纵向对比了本文提出的不同改进方法的检测效果, 同时设置 Faster R-CNN、YOLOv3、YOLOv4、YOLOv5、文献[14]及文献[15]的算法对本文数据集进行实验, 实现算法综合检测性能的横向对比, 使用 mAP50 作为评价指标得到实验结果如表 4 所示, 检测效果最优用加粗表示。经典的两阶段检测算法 Faster R-CNN 在检测精度方面比 YOLOv3、YOLOv4 表现更加优异。文献[14]和文献[15]也是基于 YOLOv5 模型的改进, 可以看到其 mAP 较 YOLOv5 有所提升, 但是本文所提出的改进

YOLOv5 算法取得了更高的检测精度。

表 4 与主流检测算法对比

检测算法	mAP50	%
Faster RCNN-VGG16	94.65	
Faster RCNN-ResNet50	98.68	
YOLOv3	90.05	
YOLOv4	91.49	
YOLOv5	92.38	
文献[14]	94.54	
文献[15]	95.58	
本文改进 YOLOv5 算法	99.22	

4.5 鲁棒性对比实验

金属表面具有高表面反射率, 在实际工业环境中, 不同的光学特性会给金属表面的缺陷检测带来困难, 增加误检的可能性。本文增加鲁棒性实验, 验证在不同光照情况下本模型的实用性, 实验结果如图 7 所示, 可以看出改进的 YOLOv5 算法在 3 种不同的光照情况下的检测效果均表现优秀, 没有出现漏检误检现象。

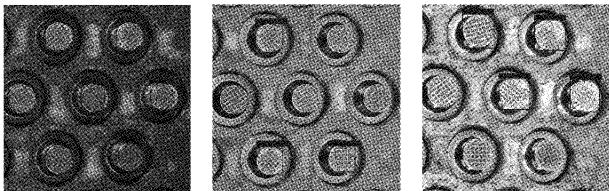


图 7 不同光照下的检测效果

5 结 论

本文针对目前人工检测的效率低下难题, 改进了 YOLOv5 算法应用于检测电极表面的电子粉涂覆均匀情况, 兼顾实用性和高效性完成电子粉涂覆不均的缺陷检测。在自制的电子粉涂覆不均数据集的基础上进行数据增强避免网络过拟合现象; 借鉴 STDC 模块改进特征提取网络, 在减少计算量的基础上又融合了深浅层特征信息; 保留两个适应数据集的尺寸的特征图, 确保检测的查回率, 能够减少漏检现象; 使用 K-means++ 聚类获取较优初始聚类中心, 生成合理 Anchors 优化模型训练。通过与其它算法进行纵向横向对比得出实验结果, 表明本文的算法具有良好的检测性能和实用性。

参考文献

- [1] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.
- [2] 李丹, 王慢慢, 刘俊德, 等. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.
- [3] ZHOU W, FEI M, ZHOU H, et al. A sparse

- representation based fast detection method for surface defect detection of bottle caps[J]. Neurocomputing, 2014, 123: 406-414.
- [4] ZHANG Y, LI T, LI Q. Defect detection for tire laser shearography image using curvelet transform based edge detector[J]. Optics & Laser Technology, 2013, 47: 64-71.
- [5] LIU W, ANGUELOY D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [6] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, 2018, ArXiv: 1804. 02767.
- [7] BOCHKOVSKIY A, WANG C, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv: 2004. 10934.
- [8] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [9] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [10] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards realtime object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [11] 彭伟康, 陈爱军, 吴东明, 等. 基于改进 Faster R-CNN 的水准泡缺陷检测方法[J]. 中国测试, 2021, 47(7): 6-12.
- [12] 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.
- [13] 马燕婷, 赵红东, 阎超, 等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8): 150-157.
- [14] 王年涛, 王淑青, 黄剑锋, 等. 基于改进 YOLOv5 神经网络的绝缘子缺陷检测方法[J]. 激光杂志, 2022, 43(8): 60-65.
- [15] 颜学坤, 楚建安. 基于 YOLOv5 改进算法的印花图案疵点检测[J]. 电子测量技术, 2022, 45(4): 59-65.
- [16] FAN M, LAI S, HUANG J, et al. Rethinking bisenet for real-time semantic segmentation [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 9716-9725.
- [17] LOSHCHILOV I, HUTTER F. Sgdr: Stochastic gradient descent with warm restarts [J]. ArXiv Preprint, 2016, ArXiv: 1608. 039836.

作者简介

戴思璇, 硕士研究生, 主要研究方向为人工智能、目标检测等。
E-mail: 2246735788@qq.com