

DOI: 10.13382/j.jemi.B2306487

# 深度学习陶瓷表面缺陷检测算法研究\*

丁伟利 张志鹏 雷子琦 孙朴

(燕山大学 秦皇岛 066004)

**摘要:**传统的陶瓷缺陷检测主要依赖人工目测或放大镜观察,为解决检测效率低、结果主观性强等问题,提出了一种基于深度学习的陶瓷表面缺陷检测算法,针对于陶瓷杯表面的缺陷具体情况,在YOLOv5目标检测模型的基础上,增加小目标检测层,同时使用位置注意力机制进行特征重构提高检测的精确度,实现了高精度的缺陷检测。针对实际生产中的陶瓷双层杯进行数据采集训练,并对于每批数据进行推理,最终平均检测精度达到了95.4%。本文所改进的YOLOv5缺陷检测模型拥有更高的准确率、识别速度快等优点,可以极大地减少陶瓷质检减少人力物力的损耗与时间成本。

**关键词:**陶瓷缺陷检测;YOLOv5;目标检测;注意力机制

**中图分类号:** TP391.4;TN98 **文献标识码:** A **国家标准学科分类代码:** 520.2060

## Deep learning ceramic surface defect detection algorithm research

Ding Weili Zhang Zhipeng Lei Ziqi Sun Pu

(Yanshan University, Qinhuangdao 066004, China)

**Abstract:** Traditional ceramic defect detection mainly relies on manual visual inspection or magnifying glass observation. In order to solve the problems of low detection efficiency and strong subjectivity of results, this paper proposes a ceramic surface defect detection algorithm based on deep learning. According to the specific situation of the defects on the surface of the ceramic cup, a small target detection layer is added on the basis of the YOLOv5 target detection model, at the same time, the position attention mechanism is used for feature reconstruction to improve the detection accuracy, and high-precision defect detection is achieved. According to the actual production of ceramic double-layer cup data acquisition training, and reasoning for each batch of data, the final average detection accuracy reached 95.4%. The improved YOLOv5 defect detection model in this paper has the advantages of higher accuracy and faster recognition speed, which can greatly reduce the loss of human and material resources and time cost in ceramic quality inspection.

**Keywords:** ceramic defect detection; YOLOv5; object detection; attention mechanism

## 0 引言

在现代制造业中,智能化生产线的应用已经成为企业提高效率、降低成本和提高产品质量的必然趋势。在制造过程中,表面缺陷是一种不可避免的问题,如果不及时检测和处理,将会导致产品质量下降、市场信誉受损和生产成本增加。因此,在智能化生产线中,表面缺陷检测技术的应用显得尤为重要。

传统的表面缺陷检测方法主要依赖人工判断或者随

机抽样检查,这种方法效率低、耗时长、容易出错,同时由于人为因素的影响,无法保证长期高效的检测效果。而智能化表面缺陷检测技术的应用可以有效解决这些问题。陶瓷制品通常具有不规则的外部特征,这增加了对其质量的管控难度。同时,制造工艺、产品运输和人工操作等不确定性因素可能导致表面缺陷,如开裂、疙瘩、棕眼、脏点和落渣等。存在这些缺陷的陶瓷产品将极大地影响用户的使用体验。因此,实现对陶瓷制品的智能缺陷检测具有重要意义。

随着计算机视觉技术的发展,越来越多的工业生产

行业开始采用智能缺陷检测方案,取代人工检测。其中,传统视觉主要依靠缺陷的颜色和形状等特征,利用图像处理或机器视觉方法进行检测。对于背景简单的产品,边缘检测<sup>[1-4]</sup>或图像分割<sup>[5-7]</sup>方法可以定位缺陷并对其进行分类。机器视觉缺陷检测<sup>[8]</sup>的步骤包括图像采集、预处理、特征提取和检测,具有高效、准确、可靠等优点。但是传统方法对图像质量要求高,难以检测复杂缺陷,而且需要人工设计缺陷的特征表示方式。

近些年,随着硬件设备的不断发展,算力得到了飞速提升,带动了深度学习技术的发展浪潮,深度学习技术在缺陷检测领域的发展取得了很大的进展。国内外研究人员分别给出了不同的缺陷检测方案。在国外,Vidheesha 等<sup>[9]</sup>研究了 CNN 在刀具的缺陷检测实验效果,准确率达到了 92%。Park 等<sup>[10]</sup>提出了在轧钢表面缺陷检测的算法,使用基于多重分形的算法提取到相应的特征,将其放入神经网络中进行分类,可以达到 97% 的精度。Mujeeb 等<sup>[11]</sup>提出了一种基于自编码器的缺陷检测算法,该算法不依赖于缺陷样本的卷积神经网络(convolutional neural networks, CNN)模型来检测表面缺陷,该算法的优点是不需要太多先验知识的情况下可以检测各种不同类型的缺陷,但对于具有背景纹理的图像仍然需要大量正样本进行训练。Wang 等<sup>[12]</sup>提出了一种通过图像对比的方法来识别缺陷,通过优化深度置信网络,计算出缺陷样本和模板样本的映射函数。在国内,曾文治等<sup>[13]</sup>针对车灯零部件缺陷提出了基于改进 YOLOv3 的算法,模型准确率可达 82%,检测速度比人工检测速度提升了 3~4 倍。顾海军等<sup>[14]</sup>使用 Mask R-CNN 对轮胎缺陷进行检测,缺陷检测准确率可达 96%。哈尔滨工业大学的 Zhu 等<sup>[15]</sup>提出了一种基于深度学习的轮胎缺陷检测算法,该算法采用了 Zeiler 和 Fergus 卷积神经网络,针对轮胎表面各类缺陷准确率达到 96% 的效果。黄允等<sup>[16]</sup>研究了一种基于深度学习的 PCB 缺陷检测方法,基于 Inception v3 搭建了图像识别模型,该模型的识别率达到了 93.83%。陈仁祥等<sup>[17]</sup>提出了一种基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测算法,针对不同噪声干扰下的印刷电路板,检测精度达到 92.4%。马燕婷等<sup>[18]</sup>研究了一种基于 YOLOv5s 的带钢表面缺陷检测,该模型的识别率达到了 82.4%。

在实际生产中,陶瓷表面缺陷质检对缺陷本身的边框的精度要求不高,但是对检测速度和准确率有较高的要求。而现有的算法例如 Fast RCNN 和 SSD 等两阶段的目标检测算法,在检测精度上有着很大的问题,尤其是算法针对小目标检测的准确率较低,基于以上几个问题,本文提出了一种基于改进 YOLOv5 的陶瓷表面缺陷检测算法,针对陶瓷表面缺陷特有的特征小难识别的问题,提出了增加小目标检测层和注意力机制的方法,可以准确

地检测出陶瓷杯表面缺陷并判断陶瓷样本是否为次品,并对缺陷的种类进行分类。

本文将深度学习技术率先应用于双层杯生产质检环节,极大地提高了质检效率和精度,同时实现了无接触检测,避免了人工目检过程中对陶瓷件可能造成的二次损伤。

## 1 基于 YOLOv5 改进的算法模型

### 1.1 原始模型

YOLOv5 和 YOLO 系列一阶段网络结构类似,主要分为输入端、骨干网络、Neck 和 Head 4 部分。YOLOv5 系列主要包含 YOLOv5s、YOLOv5l、YOLOv5m 和 YOLOv5x 这 4 种网络模型。为了便于将算法部署到边缘端,本文选择参数量最小的 YOLOv5s 作为基础模型。图 1 为 YOLOv5 的网络结构图。

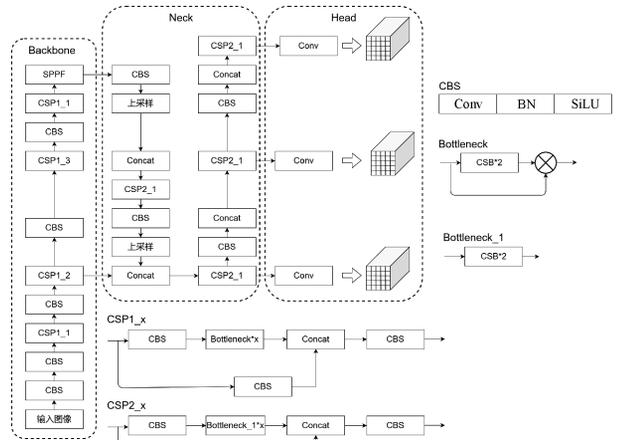


图 1 YOLOv5 网络结构

Fig. 1 YOLOv5 network structure map

输入端主要包括 Mosaic 数据增强、图像尺寸处理和自适应锚框计算等模块。

骨干网络主要负责从输入数据提取到高质量特征。骨干网络采用 CSPDarknet53 架构,该架构包含 1 个基础网络和 3 个阶段,使用 CSP 模块将前后卷积层的特征图连接起来,可以更好地利用特征。此外,该部分还包含 Focus 和 SPPF 模块,Focus 结构对输入图片进行切片操作,避免了图片在下采样过程中信息丢失,如图 2 为 Focus 结构示意图。SPPF<sup>[19]</sup>结构实现局部特征和全局特征的融合,它可以在不增加计算成本的情况下显著提高模型检测不同尺度和大小的对象的能力,如图 3 为 SPPF 的结构示意图。

YOLOv5 和 YOLO 系列基于 Anchor 的算法类似,使用先验框的思想。具体做法是将输入的图像划分为 S×S

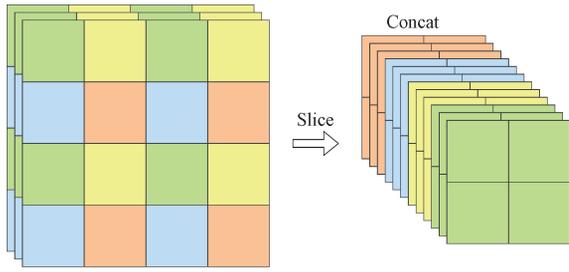


图 2 Focus 结构示意图

Fig. 2 Focus structure diagram

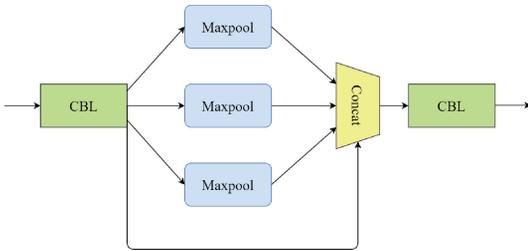


图 3 SPPF 结构示意图

Fig. 3 SPPF structure diagram

个网格,并为每个网格预测边界框的结果<sup>[20]</sup>。具体而言,每个网格负责预测该网格内是否存在目标物体的分类预测结果,以及目标物体的位置信息,包括中心点坐标和边界框的宽高。分类预测结果表示物体所属类别的概率,置信度表示物体是否在边界框之内的概率。通过 Neck 层即一系列混合和组合图像特征的网络层,并将图像特征传递到预测层。通过预测层对图像特征进行预测,生成边界框和并预测类别。

### 1.2 基于 YOLOv5 改进的检测模型

本文提出了一种基于 YOLOv5 算法改进的检测模型,改进后的 YOLOv5 网络结构图如图 4 所示。该网络结构在原始 YOLOv5 结构上增加了小目标检测层和注意力机制。具体添加方式为:首先在 Neck 部分在两次上采样基础上增加新的上采样层,与骨干网络中 CSP1\_1 模块引出特征层进行融合,然后通过 CoordAtt 模块和 CSP2\_1 模块引出小目标检测层。

#### 1) 增加小目标检测层

YOLOv5 将输入图像通过骨干网络和 Neck 映射到 3 个不同尺寸特征图,对于输入尺寸为 640×640、RGB 三通道图像,将会得到尺寸分别为 20×20、40×40、80×80 的特征图,不同尺寸特征图的感受野大小不同,分别负责大型物体、中型物体和小型物体预测。YOLOv5 采用自适应锚框计算方式,根据训练集中目标的尺寸和分布自动计算合适的锚框大小和比例,但需设置初始先验框尺寸,以 COCO 数据集为例,3 种不同尺寸的特征图先验框尺寸如

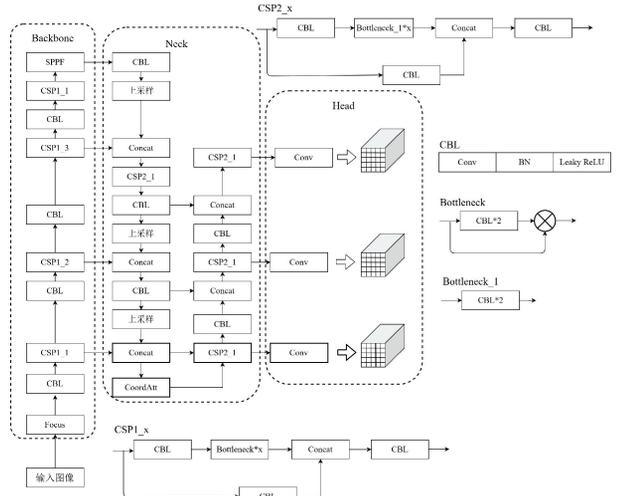


图 4 改进 YOLOv5 网络结构

Fig. 4 Improved YOLOv5 network structure diagram

表 1 所示。

表 1 感受野尺寸表

Table 1 Feel the wild size table

特征图	感受野	先验框尺寸
		10×13
80×80	大	16×30
		33×23
		30×61
40×40	中	62×45
		59×119
20×20	小	116×90
		156×198
		373×326

预测边界框的位置是通过模型预测的输出来计算的。假设在图像第  $i$  行第  $j$  列的网格预测到某个边界框,则该预测的边界框位置信息可以表示为:

$$b_x = \delta(t_x) + j \tag{1}$$

$$b_y = \delta(t_y) + i \tag{2}$$

$$b_w = p_w \times \exp(t_w) \tag{3}$$

$$b_h = p_h \times \exp(t_h) \tag{4}$$

式中:  $(b_x, b_y)$  表示中心坐标;  $b_w, b_h$  分别表示预测框的宽和高;  $\delta$  表示 Sigmoid 函数;  $t_x, t_y, t_w, t_h$  分别表示预测框的中心坐标偏移量和宽高的缩放系数;  $p_w, p_h$  表示 Anchor 框的宽和高。

获取到若干预测框之后,使用非极大值抑制 (non-maximum suppression, NMS) 算法对其进行筛选,即选取最佳的检测结果。选取置信度得分最高的目标框并与其重叠的目标框去除,最终保留最准确的预测框,从而实现陶瓷表面缺陷的准确定位。

本文根据实际采集情况与缺陷情况,选择在原模型

的基础上添加小目标层。因此特增加了  $160 \times 160$  的检测特征图,用于检测采集图像中及其细小的藏点缺陷。小目标检测层可以增加在原始图像上的单元格,进而增加 anchor 数量,增加预测结果的准确率。如图 5 所示,图 5(a) 表示中间检测层生成的 anchor 在原图上的示意图,图 5(b) 表示小目标检测层生成的 anchor 在原图上的示意图。

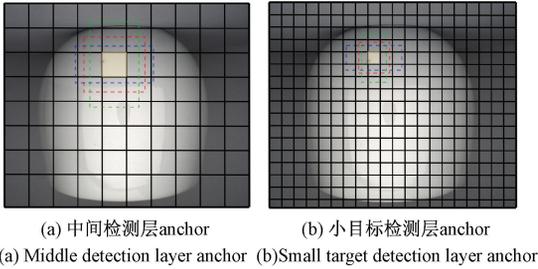


图 5 不同特征层生成的 anchor 示意图

Fig. 5 Schematic diagram of the anchor generated by different feature layers

### 2) 添加 CA 注意力机制

注意力机制本质上是学习出权重分布,然后作用到特征上,使网络模型更加关注目标信息,降低对无用信息的作用。在深度学习中,常用的注意力机制模块有 SE<sup>[21]</sup>、CBAM<sup>[22]</sup> 和 CA<sup>[23]</sup> 模块,SE 是最流行的注意力机制,但其只考虑了通道间信息的编码而忽略了位置信息,CBAM 采用减少通道数的方式,利用大尺寸卷积来融合位置信息,但由于大尺寸卷积只能捕捉局部相关性,因此其范围受到限制。针对长程依赖的视觉任务不太友好,CA 同时考虑了通道信息和方向相关的位置信息,而且它使用起来非常灵活,能够在轻量级网络中即插即用。

因此,本文在 YOLOv5 网络结构中引入 CA 注意力机制,将其加入到第 3 次上采样特征和 CSP1\_1 特征 Concat 操作之后,在一定程度上可以提高陶瓷表面缺陷特征提取能力,可以提升特征不明显缺陷的检测精度。

CA 通过对通道注意力拆分成两个一维特征编码,然后将位置信息添加到生成的特征图中,具体实现为:使用两个一维全局池化操作来整合输入特征,分别在水平和垂直方向上,生成两个方向特征图,如式(5)和(6)所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \quad (5)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w) \quad (6)$$

式中:  $z_c^h(h)$  表示垂直方向特征;  $z_c^w(w)$  表示水平方向特征;  $H$  表示输入特征图高;  $W$  表示输入特征图宽。

然后对这两个特征图分别被编码为两个注意力图,首先对这两个特征图进行 concat 操作并进行 F1 操作(利用  $1 \times 1$  卷积进行降维)和激活操作生成新的特征图,如

式(7)所示。

$$f = \delta(F_1([\mathbf{z}^h, \mathbf{z}^w])) \quad , f \in \mathbb{R}^{C/r \times (H+W) \times 1} \quad (7)$$

式中:  $f$  表示新生成的特征图;  $[\ ]$  表示 concat 操作;  $F_1$  表示卷积降维操作;  $\delta$  表示激活函数。

然后对新生成的特征图进行 split 操作,利用卷积升维和 sigmoid 激活操作得到注意力图,如式(8)和(9)所示。

$$g^h = \delta(F_h(f^h)) \quad , f^h \in \mathbb{R}^{C/r \times H \times 1} \quad , g^h \in \mathbb{R}^{C \times H \times 1} \quad (8)$$

$$g^w = \delta(F_w(f^w)) \quad , f^w \in \mathbb{R}^{C/r \times 1 \times W} \quad , g^w \in \mathbb{R}^{C \times 1 \times W} \quad (9)$$

式中:  $g^h, g^w$  表示注意力图;  $f^h, f^w$  表示 split 之后的特征图;  $F_h, F_w$  表示卷积升维操作;  $\delta$  表示 sigmoid 激活函数。

最后将这两个注意力图包含输入特征图在某一空间方向上的长程依赖,如式(10)所示。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (10)$$

式中:  $y_c$  表示输出特征图;  $x_c$  表示输入特征图;  $g_c^h, g_c^w$  表示注意力图。

这样位置信息被包含在注意力图中了,注意力图与输入特征图进行相乘增加了特征图的表达能力。CA 注意力机制的结构图如图 6 所示。

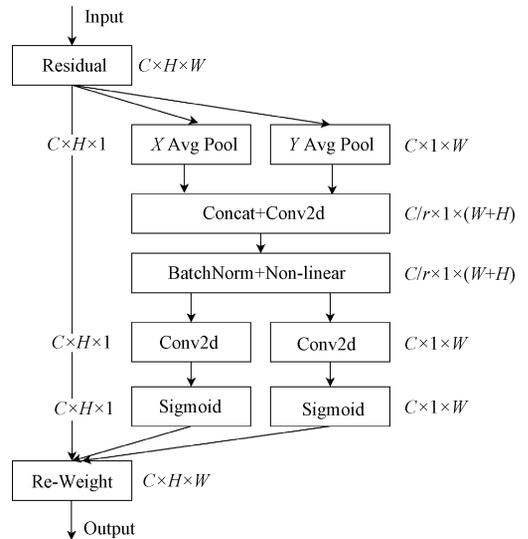


图 6 CA 注意力机制结构

Fig. 6 CA attention mechanism structure map

## 2 实验过程和结果

基于 YOLOv5 的改进模型使用 Python 语言,操作系统为 Ubuntu18.04,处理器为 E5-2680 V4@ 2.40 GHz、内存为 16 GB 和显卡 NVIDIA RTX 4090。

### 2.1 实验准备

根据实地考察与项目需求,使用计算机视觉技术解决陶瓷件工业质检中存在的诸多问题。在深度学习领

域,需要大量的数据进行模型的训练,目前网络上未有双层杯的公开数据集,因此,需要采集适用于陶瓷双层杯表面缺陷数据集,来进行训练与测试。

1) 图像数据集制作

陶瓷样本表面缺陷主要以开裂、黑点、落渣、脏点为主。如图 7 所示,为不同类型缺陷的形状。将黑点、脏点和落渣 3 类缺陷归为一类。因此获得的数据集主要以开裂和黑点两类缺陷为主。总共采集了原图图像 931 张,其中各种缺陷的分布情况如表 2 所示。

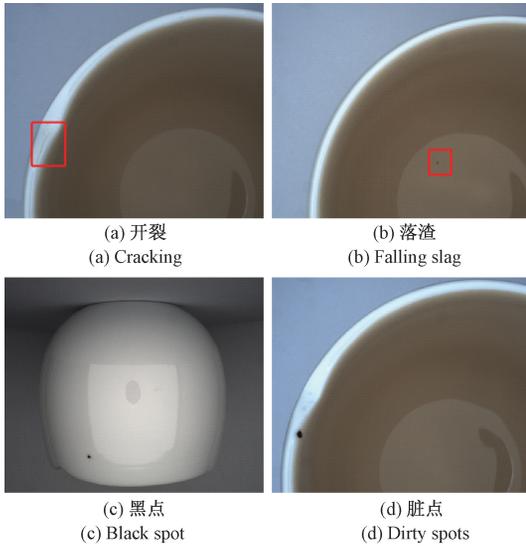


图 7 各类缺陷示意图

Fig. 7 Various types of defects diagram

表 2 数据集缺陷分布情况

Table 2 Distribution of defects in the dataset

缺陷类别	数量/张	占比/%	标签
开裂	203	22	KL
脏点	728	78	zangdian
总计	931	100	—

2) 图像数据集制作

本文采用的数据增强技术主要以水平翻转和对角线翻转为主。在图像采集过程中,光照环境固定,因此不对图像的亮度做数据增强。如图 8 为图像数据增强效果图。

通过数据扩充,在原有数据量的基础上,开裂和脏点缺陷都扩充了两倍。扩充之后找出不合格的图像,最终创建陶瓷表面缺陷数据集。如表 3 所示,展示了扩充之后数据集分布情况。

3) 数据集划分

通过图像采集系统获取到陶瓷表面缺陷图像,下一步需要对图像打标签。使用 LabelImg 工具在样本图像上框出缺陷位置并标明缺陷类别,然后对标签文件保存成

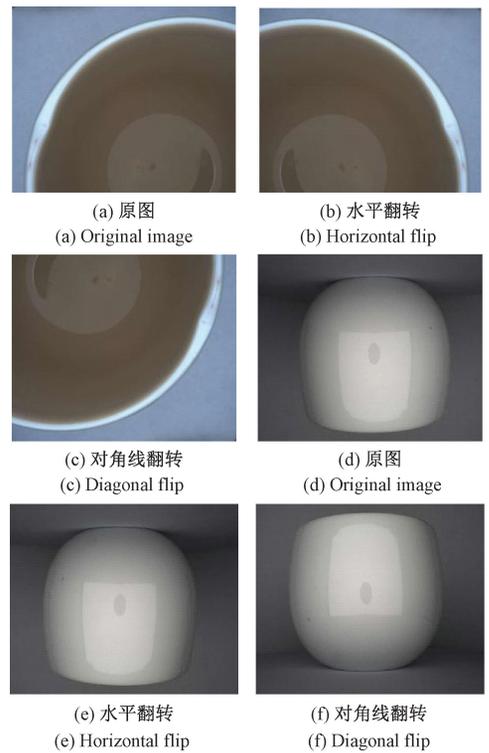


图 8 数据增强效果图

Fig. 8 Data enhancement effect

TXT 文件形式,这样就可以通过标签文件对缺陷进行分类和定位。如图 9 所示。

表 3 数据增强后数据集缺陷分布情况

Table 3 Distribution of defects in the data set after data enhancement

缺陷类别	数量/张	占比/%	标签
开裂	609	21.8	KL
脏点	2 184	78.2	Zangdian
总计	2 793	100	—

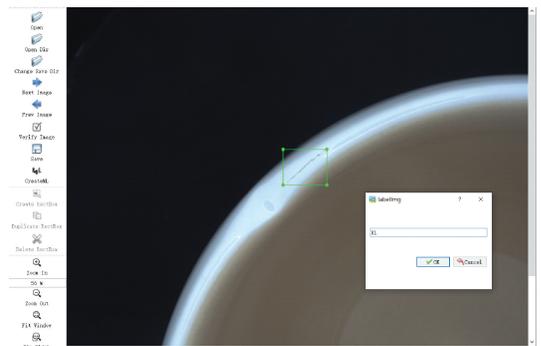


图 9 LabelImg 打标签示意图

Fig. 9 LabelImg labeling map

待所有图像标签制作完成,通过 Python 脚本将图像

和标签文件以 8 : 2 的比例随机划分成训练集和测试集,这样可以确保训练集和测试集的分布均匀,从而更好地训练和评估模型的性能,进而陶瓷表面缺陷数据集制作完成。表 4 所示为数据集分布情况。

表 4 训练集、测试集分布情况

Table 4 Distribution of training set and test set data sets

数据集	数量/张	占比/%
训练集	2 229	80
测试集	564	20
总计	2 793	100

### 2.2 模型训练和测试

在模型训练前设置相关配置和参数,设置学习率为 0.01, Epoch 为 120 时结束训练,设置 Batch\_size 为 32, IoU 训练阈值为 0.2, 锚倍阈值为 0.4, 输入图像尺寸为 800×800, 使用占比 80% 的训练集进行训练, 使用数据集剩下的 20% 的数据作为测试集, 具体参数含义与数值如表 5 所示。

表 5 部分实验参数表

Table 5 Partial experimental parameters table

参数名	参数含义	参数值
Epoch	迭代次数	120
Learning_rate	学习率	0.01
Batch_size	单次训练样本	32
momentum	SGD 动量	0.937
iou_t	Iou 训练阈值	0.2
Anchor_t	锚倍阈值	0.4

### 2.3 实验结果

实验评价指标采用平均准确率 (mean average precision, mAP) 分别评价训练模型的精度, params 表示模型的整体参数量。原始 YOLOv5 模型实验结果如表 6 所示。经过验证后得出原 YOLOv5 模型的 mAP 值为 0.924%。

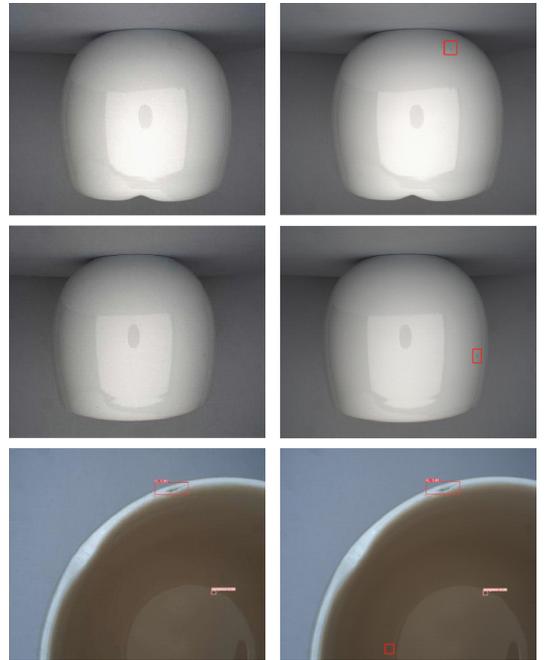
表 6 YOLOv5 实验结果

Table 6 YOLOv5 experimental results

缺陷类别	AP	mAP@0.5
开裂	0.926	0.924
脏点	0.922	

从实验结果可以看出,在不该改变原始网络结构和参数的情况下, YOLOv5 模型能够在陶瓷表面缺陷检测任务中达到不错的效果,开裂的 AP 值达到了 92.6%,脏点的 AP 值达到了 92.2%,模型整体的 mAP@0.5 达到了 92.4%。通过观察测试集推理结果,可以看出有些脏点缺陷并未检测到,如图 10 所示,这是因为脏点本身缺陷尺寸小,现有模型很难检测出来,同时根据表格 3 缺陷占

比发现因此本文改进的方向主要也依据与脏点来进行改进,由于脏点占比较小因此增加小目标层和注意力机制来进行网络结构的改进。



(a) 缺陷检测结果图 (a) Defect detection results map  
(b) 漏检图 (b) Leakage map

图 10 缺陷漏检结果展示

Fig. 10 Defect leakage detection results show

通过在 YOLOv5s 网络结构基础上添加小目标检测层和 CA 注意力机制来进行消融实验结果验证。在实验中,初始参数和原网络结构保持一致。如图 11 所示为添加小目标检测层和注意力机制与原网络的损失函数损失图。

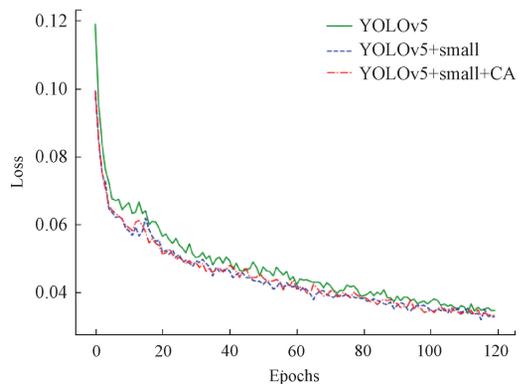


图 11 损失下降对比图

Fig. 11 Loss decline comparison map

如表 7 所示为不同网络模型的实验结果,分别为原始网络结构、添加小目标检测层、添加注意力机制、与同

时添加小目标层和注意力机制的实验结果。

表 7 不同改进网络模型的消融实验结果

Table 7 Experimental results of ablation using different improved network models

网络结构	mAP@0.5	GFLOPs	Params/M
YOLOv5s	0.924	16.3	13.7
YOLOv5s+small	0.949	17.6	10.9
YOLOv5s+small+CA	0.954	17.7	10.9

如表 8 所示为改进后的最终脏点和开裂的实验结果。

表 8 改进后的实验结果

Table 8 Improved experimental results

缺陷类别	AP	mAP@0.5
开裂	0.960	0.954
脏点	0.948	

从上述消融实验结果可以看出添加小目标检测层后, mAP@0.5 从原来的 0.924 提升到了 0.949, 再次添加注意力机制之后 mAP@0.5 从 0.949 提升到了 0.954, 准确率较原算法提升了 3%。表示小目标检测层和注意力机制提升了模型精度, 同时模型参数 Pa 也进一步得到下降。通过可视化结果可以看出图 10 所示的漏检情况得到了进一步改善, 如图 12 所示。在进行改进网络模型之后, 整体的缺陷检测准确率得到了提升, 同时之前在图 10 中说明的脏点漏检情况也得到缓解, 脏点的 mAP 值由原来的 0.922 提高到了 0.948, 达到了较高的水平, 符合工厂实际生产需求。

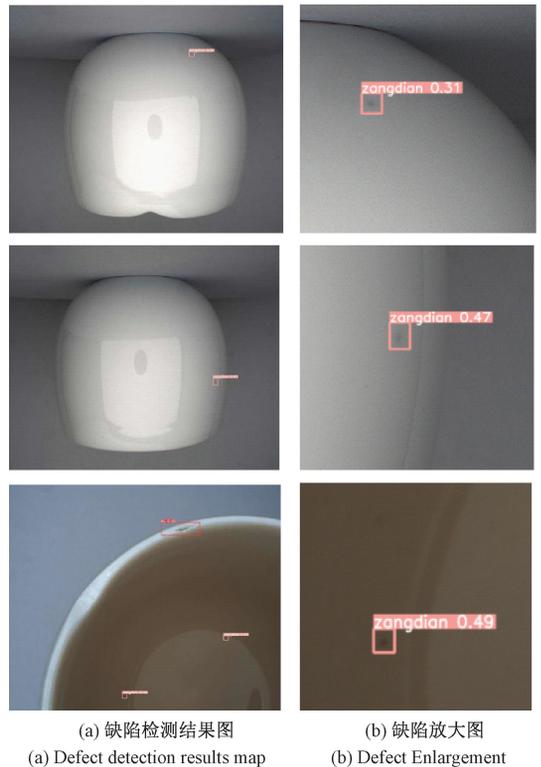
将改进后的检测算法与其他的通用的目标检测算法进行对比试验, 保持试验参数相同如图 5 所示, 对比结果如表 9 所示。

表 9 对比实验检测结果

Table 9 Comparison of experimental detection results

网络结构	mAP@0.5	GFLOPs	Params/M
SSD300-vgg16	0.852	87.7	103.9
FasterRcnn-resnet50	0.896	117.8	105.4
YOLOv3	0.917	155.3	61.5
YOLOv5s	0.924	16.3	13.7
YOLOv5s+small+CA	0.954	17.7	10.9

从上对比实验结果可以看出, 改进后的算法由于加入了小目标层和注意力机制之后, 相较于原 YOLOv5s 算法准确率提高; 改进后的算法与其他常用的目标检测算法如 YOLOv3、SSD300 和 FasterRcnn 相比较, 该算法保持准确率较高的同时还保持了相当低的模型参数量, 便于将算法部署在边缘端。



(a) 缺陷检测结果图 (b) 缺陷放大图  
(a) Defect detection results map (b) Defect Enlargement

图 12 漏检缺陷检测图

Fig. 12 Defect leakage detection

### 3 结 论

本文针对陶瓷双层杯表面缺陷检测问题, 提出了基于 YOLOv5 改进的缺陷检测模型, 可对陶瓷双层杯表面进行高效准确的缺陷检测。在 YOLOv5 模型基础上, 添加小目标检测层和 CA 注意力机制, 有效提升了算法精度。在测试中, 平均精度达到了 93.2%。相比原始 YOLOv5, 精度提高了 3.6%。通过可视化结果和样本分析可知缺陷检测位置准确, 可以很好地投入生产实践中。接下来在此基础上将继续研究如何在保证速度快速的情况下进一步提高缺陷检测的精度, 以及在复杂背景下适应于其他类型的陶瓷制品。同时, 可以配合现有的多目标模型分类模型, 对多种陶瓷制品同时进行表面缺陷检测。这将极大提高陶瓷生产效率, 节约了人力成本, 有利于陶瓷产业的发展。

### 参考文献

- [1] 高佳文, 费树岷. 基于边缘检测的芒果表面缺陷检测研究[J]. 电子测试, 2022, 36(20): 42-44.  
GAO J W, FEI SH M. Research on surface defect detection of mango based on edge detection [J]. Electronic Testing, 2022, 36(20): 42-44.
- [2] 石冬阳, 张俊林, 杨欣, 等. 一种基于 Canny 边缘检测算法的零件缺陷图像处理方法[J]. 重庆科技学院学

- 报(自然科学版), 2022, 24(3): 52-56.
- SHI D Y, ZHANG J L, YANG X, et al. A part defect image processing method based on Canny edge detection algorithm[J]. Journal of Chongqing Institute of Science and Technology (Natural Science Edition), 2022, 24(3): 52-56.
- [ 3 ] 范峥, 刘刚. 基于机器视觉和改进形态学边缘检测算法的钢球缺陷检测技术研究[J]. 工具技术, 2019, 53(9): 102-106.
- FAN ZH, LIU G. Research on steel ball defect detection technology based on machine vision and improved morphological edge detection algorithm [ J ]. Tool Technology, 2019, 53(9): 102-106.
- [ 4 ] 关静, 楼飞. 基于边缘轮廓的管道裂纹缺陷检测算法研究 [ J ]. 计算机与数字工程, 2022, 50 ( 5 ): 1103-1108.
- GUAN J, LOU F. Research on pipeline crack defect detection algorithm based on edge contour[J]. Computer and Digital Engineering, 2022, 50(5): 1103-1108.
- [ 5 ] 沈杰, 陈玉权, 吴媚, 等. 基于图像分割技术的玻璃绝缘子缺陷检测[J]. 信息技术, 2022, 366(5): 165-170, 176.
- SHEN J, CHEN Y Q, WU M, et al. Image segmentation-based defect detection of glass insulators[J]. Information Technology, 2022, 366(5): 165-170, 176.
- [ 6 ] 董懿飞, 舒胜文, 陈诚, 等. 基于红外图像分割与 SSA-SVM 的复合绝缘子缺陷检测方法 [ J ]. 电气技术, 2021, 22(11): 73-79.
- DONG Y F, SHU SH W, CHEN CH, et al. Infrared image segmentation and SSA-SVM-based defect detection method for composite insulators [ J ]. Electrical Technology, 2021, 22(11): 73-79.
- [ 7 ] 陈哈彬, 刘祚时. 基于改进型 PCNN 图像分割技术的金属表面检测[J]. 制造业自动化, 2021, 43(4): 43-46, 62.
- CHEN H B, LIU Z SH. Metal surface detection based on improved PCNN image segmentation technique [ J ]. Manufacturing Automation, 2021, 43(4): 43-46, 62.
- [ 8 ] 邓少鹏, 欧阳纲, 李立新, 等. 机器视觉在同轴芯棒端面缺陷检测中的应用 [ J ]. 轻工科技, 2023, 39(1): 95-98, 101.
- DENG SH P, OUYANG G, LI L X, et al. Application of machine vision in coaxial core filter rod end face defect detection [ J ]. Light Industry Science and Technology, 2023, 39(1): 95-98, 101.
- [ 9 ] VIDHEESHA P K, JERIN K, JOBYMOL J. Deep learning based edge defect detection [ C ]. 2018 International Conference on Emerging Trends and Innovations in Engineering and Technological Research (ICETIETR). Ernakulam, India, 2018: 1-3.
- [ 10 ] PARK J K, KWON B K, PARK J H, et al. Machine learning-based imaging system for surface defect inspection [ J ]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2016, 3(3): 303-310.
- [ 11 ] MUJEEB A, DAI W, ERDT M, et al. Unsupervised surface defect detection using deep autoencoders and data augmentation [ C ]. 2018 International Conference on Cyberworlds (CW). Singapore, 2018: 391-398.
- [ 12 ] WANG X B, LI J, YAO M H, et al. Solar cells surface defects detection based on deep learning [ J ]. Pattern Recognition and Artificial Intelligence, 2014, 27 ( 6 ): 517-523.
- [ 13 ] 曾文治, 王疆瑛, 蔡晋辉. 基于深度学习的车灯零部件缺陷检测系统设计 [ J ]. 中国计量大学学报, 2022, 33(2): 228-234.
- ZENG W ZH, WANG J Y, CAI J H. Design of a deep learning-based defect detection system for headlight components [ J ]. Journal of China University of Metrology, 2022, 33(2): 228-234.
- [ 14 ] 顾海军, 陈胜. 一种基于深度学习的轮胎缺陷检测系统 [ J ]. 计算机与数字工程, 2022, 50 ( 7 ): 1463-1467.
- GU H J, CHEN SH. A deep learning based tire defect detection system [ J ]. Computer and Digital Engineering, 2022, 50(7): 1463-1467.
- [ 15 ] ZHU Q, AI X. The defect detection algorithm for tire X-ray images based on deep learning [ C ]. 2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC). Chongqing, China, 2018: 138-142.
- [ 16 ] 黄允, 徐海达, 张健滔. 基于深度学习的 PCB 缺陷检测 [ J ]. 工业控制计算机, 2022, 35(11): 76-77.
- HUANG Y, XU H D, ZHANG J T. Deep learning-based PCB defect detection [ J ]. Industrial Control Computer, 2022, 35(11): 76-77.
- [ 17 ] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测 [ J ]. 仪器仪表学报, 2021, 42 ( 12 ): 167-174.
- CHEN R X, ZHAN Z, HU X L, et al. Defect detection of printed circuit boards under noise interference based on multi attention Faster RCNN [ J ]. Chinese Journal of Scientific Instrument, 2021, 42(12): 167-174.
- [ 18 ] 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.
- MA Y T, ZHAO H D, YAN CH, et al. Improved YOLOv5

- network for surface defect detection of strip steel [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (8): 150-157.
- [19] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [20] HE Y, ZHU C, WANG J, et al. Bounding box regression with uncertainty for accurate object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, CA, USA, 2019: 2883-2892.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018: 7132-7141.
- [22] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany, 2018: 3-19.
- [23] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming [C]. Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy, 2017: 2755-2763.

### 作者简介



丁伟利(通信作者),2003年于辽宁工业大学获得学士学位,2008年于中国科学院沈阳自动化研究所获得博士学位,现为燕山大学教授,主要研究方向为模式识别。

E-mail: weiy51@ysu.edu.cn

**Ding Weili** (Corresponding author)

received her B. Sc. degree from Liaoning University of Technology in 2003, and Ph. D. degree from Shenyang Institute of Automation, Chinese Academy of Sciences in 2008, respectively. Now she is a professor in Yanshan University. Her main research interest includes pattern recognition.