

DOI: 10.13382/j.jemi.B2306576

基于改进 YOLOv7 的液晶面板电极缺陷 视觉检测技术研究*

范先友^{1,2} 过峰³ 俞建峰^{1,2} 化春健^{1,2} 蒋毅^{1,2} 钱陈豪^{1,2}

(1. 江南大学机械工程学院 无锡 214122; 2. 江苏省食品先进制造装备技术重点实验室 无锡 214122;

3. 南京海关纺织工业产品检测中心 无锡 214174)

摘要:电极质量对液晶面板的显示效果极其重要,针对液晶面板电极缺陷种类多、尺度小、背景复杂而导致难以检测的问题,本文提出了一种基于改进 YOLOv7 的液晶面板电极缺陷视觉检测方法。首先,将 CBAM 注意力模块嵌入到 YOLOv7 骨干网络中,抑制背景信息干扰,强化缺陷特征;其次,采用跨层级连接操作,实现浅层网络与深层网络特征信息的融合;然后,将 C2f 模块融入特征金字塔网络中以轻量化模型,提高训练速度;最后,使用 WIoU 替换 YOLOv7 模型的损失函数,减小低质量标注产生的有害梯度,提高对缺陷的定位性能。在自定义的电极缺陷数据集上进行测试,结果表明,该算法对电极大划伤、划伤、磕伤以及脏污 4 类缺陷的平均检测精度达 67.8%,单张检测时间为 5.6 ms。

关键词: 缺陷检测;改进 YOLOv7;液晶面板;电极

中图分类号: TP391;TH89

文献标识码: A

国家标准学科分类代码: 520.2060

Research on visual detection technology for liquid crystal panel electrode defect by improved YOLOv7

Fan Xianyou^{1,2} Guo Feng³ Yu Jianfeng^{1,2} Hua Chunjian^{1,2} Jiang Yi^{1,2} Qian Chenhao^{1,2}

(1. School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China; 2. Jiangsu Key Laboratory of Advanced Food Manufacturing Equipment and Technology, Wuxi 214122, China; 3. Textile Industrial Products Testing Center of Nanjing Customs District, Wuxi 214174, China)

Abstract: The quality of electrode is extremely important for the display effect of liquid crystal panel. To solve the problem of difficult detection due to the variety of electrode defects, small scale and complex background, an electrode defect detection method for liquid crystal panels is proposed based on improved YOLOv7 algorithm. Firstly, the CBAM attention module was embedded into the YOLOv7 backbone network to suppress background information interference and strengthen defect features. Secondly, the feature information of the shallow networks and deep networks was fused by cross-level connection operation. Then, the C2f module was integrated into the feature pyramid network to lightweight the model and improve the training speed. Finally, the WIoU was used to replace the loss function of the YOLOv7 model to reduce the harmful gradient caused by low quality labeling and improve the defect location performance. By a customized electrode defect dataset, the results showed that the proposed algorithm was able to achieve an average detection accuracy of 67.8% for large scratch, scratch, shell and dirt on electrodes with a per-sheet detection time of 5.6 ms.

Keywords: defect detection; improved YOLOv7; liquid crystal panel; electrode

0 引言

电极作为液晶面板中的重要组成部件,由 ITO (Indium tin oxide) 透明导电材料制作,经过光刻工艺形

成。在光刻的过程中,由于光刻胶层和曝光不均匀,会导致电极形状不正确、位置偏移、错位或重叠;在光刻胶剥离的过程中,由于剥离方法和力度不同,会导致电极表面划伤、材料剥离和光刻胶残留。其产生的任何微小缺陷都会对液晶面板的质量造成不利影响^[1]。目前,电极结

构中含有大量的非周期性元件、特征和标识,使得在复杂的背景中难以准确地识别缺陷^[2]。同时,电极呈现出高密度、超细间距和微型化的结构特点^[3],导致某些缺陷在图像中仅为几个像素,显著增大了检测和识别的难度。因此,快速、精准地实现液晶面板电极的缺陷检测迫在眉睫。

目前,液晶面板电极缺陷主要通过人工检测和机器视觉等方法进行检测。人工检测工作量大、检测速度慢,容易因为检测人员的疲劳产生误判和漏判,同时由于每个人的视力和判断标准不同,无法对产品做到标准化检测;机器视觉通过利用计算机视觉技术,避免了人为干扰和人工疲劳等问题,具有快速、精确、稳定等特点。机器视觉检测法分为传统图像处理方法和深度学习方法^[2]。传统图像处理方法是通过对模板匹配法对特征进行提取,但是随着电极缺陷特征复杂性和差异性的增加,已经难以满足现今电极检测对于精度和稳定性的要求^[4-5]。针对传统图像处理方法难以检测复杂目标缺陷的问题, Li 等^[5]提出了一种结合传统图像处理方法和深度学习的检测方法,但因其是利用模板匹配法对特征进行提取,不适用于复杂背景下的检测任务。 Yao 等^[6]提出了一种基于空间注意力模块和扩张卷积模块的 YOLOv3 网络,但是其扩张卷积模块会导致小尺寸的特征信息丢失,不利于检测小尺寸目标。

为解决电极缺陷种类多、尺度小、背景复杂而导致难以检测的问题,本文提出了一种基于改进 YOLOv7 的液晶面板电极缺陷视觉检测算法。通过将 CBAM 注意力模块嵌入到骨干网络中,抑制背景信息的干扰,使模型更加关注缺陷特征;采用跨层级连接的操作,实现浅层网络与深层网络特征信息的融合,提高了检测小目标的能力;在特征金字塔网络中融入 C2f 模块以轻量化模型,提高了训练速度;使用 WIoU 替换 YOLOv7 模型的损失函数,可以减弱低质量标注产生的有害梯度,提高对缺陷的定位性能。在自定义的电极缺陷数据集上进行测试,结果表明,本文方法可以快速、准确的检测出液晶面板电极缺陷,具有一定的应用价值。

1 液晶面板电极缺陷检测算法

目标检测算法分为 One-stage 和 Two-stage 两种。Two-stage 方法需要先先生成所有可能存在目标的候选框,再对候选框进行选择,此方法检测速度慢,不能满足实时检测的需求,常见的有 R-CNN 系列算法。One-stage 方法则不需要预先生成候选框,可以直接在图片中生成目标的预测框,其检测速度快,常见的有 SSD、YOLO^[7] 系列算法。

1.1 YOLOv7 网络模型

YOLOv7 是基于 YOLOv5 的改进版本,在 5 ~ 160 fps/s 的范围内,检测速度和精度超过之前的 YOLO 版本和 Two-stage 目标检测算法。此外,YOLOv7 在检测细粒度物体方面表现更为出色^[8-9]。其结构分为 Input、Backbone、Neck、Head 这 4 个部分。Input 部分负责数据预处理,包括图片尺寸缩放、Mosaic 和 Mixup 数据增强技术以及自适应锚框计算。Backbone 部分负责特征提取,主要包括 ELAN 和 MPCConv 结构,其中 ELAN 结构有两种,分别为 ELAN1 和 ELAN2。Neck 部分负责多尺度特征图的信息融合^[10],主要由 FPN^[11] 和 PAN^[12] 结构组成。Head 部分负责进行损失函数计算,包括完全交并比损失函数 (complete intersection over union, CIoU)^[13] 和二元交叉熵损失函数,最终生成目标的边界框并预测类别。

1.2 改进的 YOLOv7 网络模型

1) 注意力模块

液晶面板电极缺陷种类多、尺度小且易于背景图案相混淆。为了抑制复杂背景特征对检测的干扰,增强重要特征,提升模型的检测精度,在 YOLOv7 的 Backbone 部分嵌入卷积块注意力模块注意力模块 (convolutional block attention module, CBAM)^[14-15]。CBAM 由通道注意力和空间注意力模块组成,结构如图 1 所示。

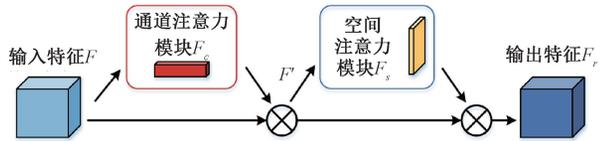


图 1 CBAM 的基本结构

Fig. 1 Structure of CBAM

由于采集到的液晶面板电极图像是单通道的灰度图,在训练时,会将图层复制 3 次生成三通道图像进行训练。特征图在经过多次卷积之后,特征抽象程度高,会造成缺陷细节的丢失,导致最终检测精度下降。而 CBAM 注意力模块首先由通道注意力模块在通道维度上增强重要特征的关注度,并舍弃重复的无效信息;然后通过空间注意力模块在空间维度上对重要特征的位置信息进行加强,从而保留提取更多的特征信息。

其中,通道注意力模块首先使用全局最大池化和全局平均池化两种方式对输入特征 F 的空间维度进行压缩;然后输入到两层共享神经网络中进行计算;最后将输出的特征向量进行逐元素相加,并通过 Sigmoid 激活得到通道注意力特征 F_c 。 F_c 再与 F 进行逐元素相乘后得到空间注意力模块的输入特征 F' 。空间注意力模块首先使用全局最大池化和全局平均池化两种方式对特征 F' 的通道维度进行压缩,并将池化操作后的结果进行拼接;然

后进行卷积操作;最后将卷积结果通过 Sigmoid 激活得到空间注意力特征 F_s 。 F_s 再与 F' 进行逐元素相乘后得到最终的输出特征 F_r 。

2) 跨层级连接

当缺陷尺寸较小时,其像素点数往往比较少,而随着卷积层数的增多,卷积操作对特征信息的采集和处理会逐渐深入,导致在卷积神经网络中,小尺寸缺陷的有用特征容易被忽略和丢失,这是小物体在目标检测中难以被准确检测的根本原因。为了融合深层和浅层卷积层的特征并改善多尺度检测困难的问题,采用 FPN 加 PAN 的结构分别建立自上而下和自下而上的通道,并有 3 个不同尺寸大小的检测头对检测结果进行输出,从而使得深

层特征图同时具有高级和低级语义信息,有利于多尺度的目标检测^[16]。

由于上采样会造成低级语义信息大量丢失,影响缺陷识别定位^[17]。为实现对小尺寸缺陷位置的精确定位,保留低级语义信息,增强模型对小尺寸目标的识别能力。基于 BiFPN^[18] 的思想,进行跨层级连接,即根据特征图的尺寸大小,将相同尺寸大小的 Backbone 部分中的浅层特征图与 PAN 结构中的深层特征图进行张量拼接,从而使得深层特征图包含浅层特征图的特征信息。在小幅增涨参数量的情况下,将边缘、轮廓等低级语义信息融入到 PAN 结构中,从而提升模型检测小目标的能力。改进后的 YOLOv7 网络结构如图 2 所示。

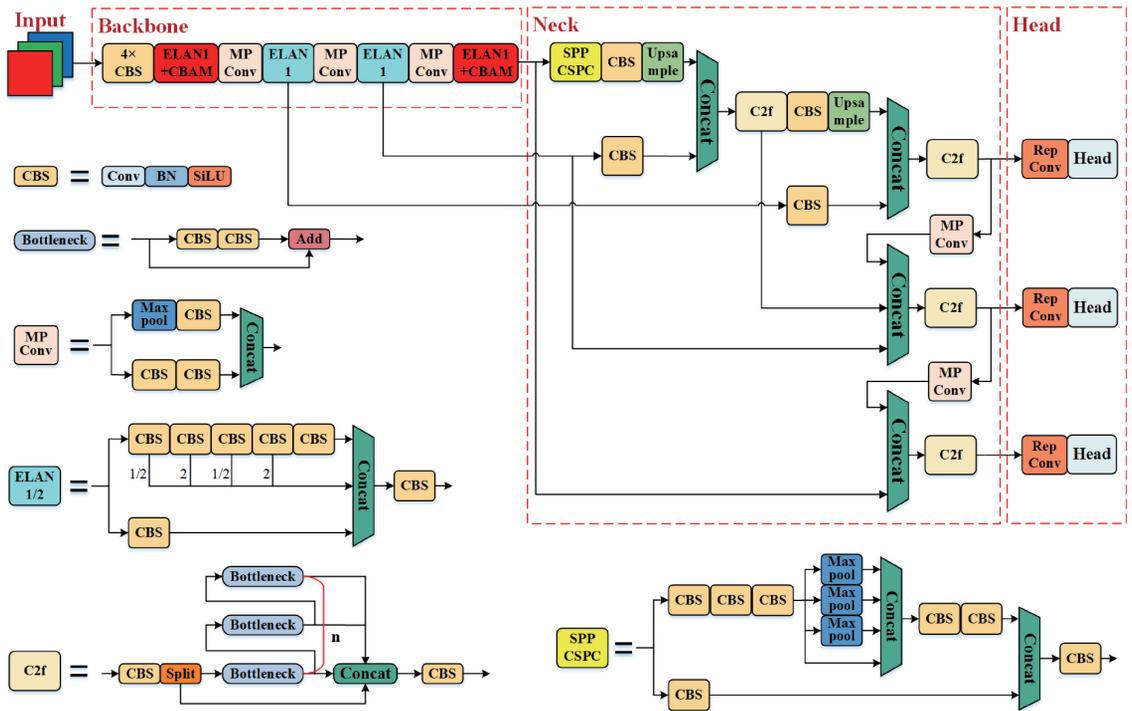


图 2 改进后的 YOLOv7 网络结构

Fig. 2 Structure of improved YOLOv7

3) 引入 C2f 模块

在原 YOLOv7 模型的 Neck 部分中,ELAN2 模块利用了大量的卷积层进行下采样和张量拼接,使得 Neck 部分输出的特征图中含有大量的冗余特征。经过 1.2 节 1) 和 2) 的方法改进后,YOLOv7 模型的检测精度有所提高,但 Neck 部分输出的特征图中由于含有重复特征,会增加模型参数量,导致计算量增加。为了减少计算量,引入 C2f 模块替换 Neck 部分中的 ELAN2 模块^[19]。

C2f 模块主要由 CBS、Split 和 Bottleneck 模块组成,结构如图 2 中所示。C2f 模块通过 Split 操作将卷积后的特征图张量分割为多个小张量,从而实现特征图张量的并行计算,加快模型的训练速度和计算效率。同时采

用 1 个 Bottleneck 模块(即残差模块)作为主梯度流分支,其堆叠的个数由模型的大小自行决定。通过这种结构可以使模型在获得丰富信息的同时减少计算量。

4) 损失函数的替换

YOLOv7 中的边界框回归损失函数为 CIoU,但对于小标注框和低质量标注框的回归有一定的局限性。为了降低低质量标注框对检测性能的干扰,进一步提高检测精度,使用 WIoU (wise-intersection over union)^[20] 对 CIoU 进行替换。

WIoU 由交并比 (Intersection over Union, IoU) 函数、动态聚焦机制 (dynamic focusing mechanism) 所构成。IoU 函数用于测量目标检测任务中锚框与目标框的重叠程

度,如图 3 所示。

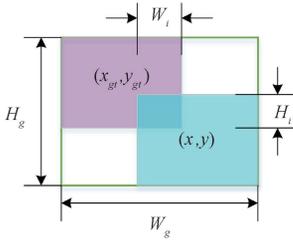


图 3 预测框和真实框示意图

Fig. 3 Prediction box and real box

图 3 中, x_{gt} 、 y_{gt} 为真实框的中心坐标, x 、 y 为预测框的中心坐标, W_i 、 H_i 为预测框和真实框相交区域的宽和高, W_g 、 H_g 为预测框和真实框的最小包围框的宽和高。IoU 函数定义如下:

$$S_u = wh + w_{gt}h_{gt} - W_iH_i \quad (1)$$

$$L_{IoU} = 1 - IoU = 1 - \frac{W_iH_i}{S_u} \quad (2)$$

其中, w 、 h 为预测框的宽和高, w_{gt} 、 h_{gt} 为真实框的宽和高, S_u 为预测框和真实框的联合区域。当预测框和真实框无重叠区域时, 反向传播的梯度会消失, 导致权重无法更新。为解决这个问题, 提出惩罚项 R_{WIoU} , 如式 (3) 所示。

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (3)$$

其中, $*$ 表示将 W_g 、 H_g 从计算图中分离, 转换为不需要梯度的张量以防止惩罚项阻碍收敛, 从而降低了原 CIoU 损失函数中长短宽比对函数收敛的影响, 同时在真实框与预测框接近重合的情况下, 弱化了几何因素的影响, 增大了普通标注框的 IoU 函数。

动态聚焦机制通过计算边界框的离群度 β 来分配梯度增益, 并利用 β 构建了一个非单调聚焦系数 r , 如式 (4)、(5) 所示。

$$\beta = \frac{L_{IoU}}{\overline{L_{IoU}}} \in [0, +\infty) \quad (4)$$

$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (5)$$

其中, $\overline{L_{IoU}}$ 表示 L_{IoU} 的均值, α 、 δ 为超参数, 分别取 1.9 和 3。由于 $\overline{L_{IoU}}$ 是动态的, 从而构建出具有动态非单调聚焦机制的 $WIoU$, 如式 (6) 所示。

$$L_{WIoU} = r \times R_{WIoU} \times L_{IoU} \quad (6)$$

通过将小梯度增益分配给具有小离群度高质量边界框, 使损失函数更关注普通质量的边界框, 将小梯度增益分配给具有大离群度的低质量标注框, 从而抑制了低质量边界框的有害梯度, 从而显著提高了模型的定位性能。

2 实验与结果分析

2.1 数据集与实验环境

1) 数据集

在生产现场, 通过黑白线阵扫描相机、远心镜头和点光源拍摄了 400 多张不同型号的液晶面板电极图像, 以此作为液晶面板电极缺陷检测的数据源。采集到的原始图像分辨率为 $6\,544 \text{ pixels} \times 78\,654 \text{ pixels}$, 每张图像的文件大小约 11 MB。从中挑选裁剪出 2 100 张成像清晰且带有电极缺陷的图像, 图像分辨率为 $1\,500 \text{ pixels} \times 1\,500 \text{ pixels}$ 。由于某些缺陷图像所占像素极少, 为提高 GPU 的运算效率, 再将其切割成 15 801 张 $500 \text{ pixels} \times 500 \text{ pixels}$ 的图片, 并从中挑选出 3 650 张带有电极缺陷的图片作为数据集。缺陷类别有大划伤、划伤、磕伤和脏污 4 类, 其部分样本如图 4 所示。

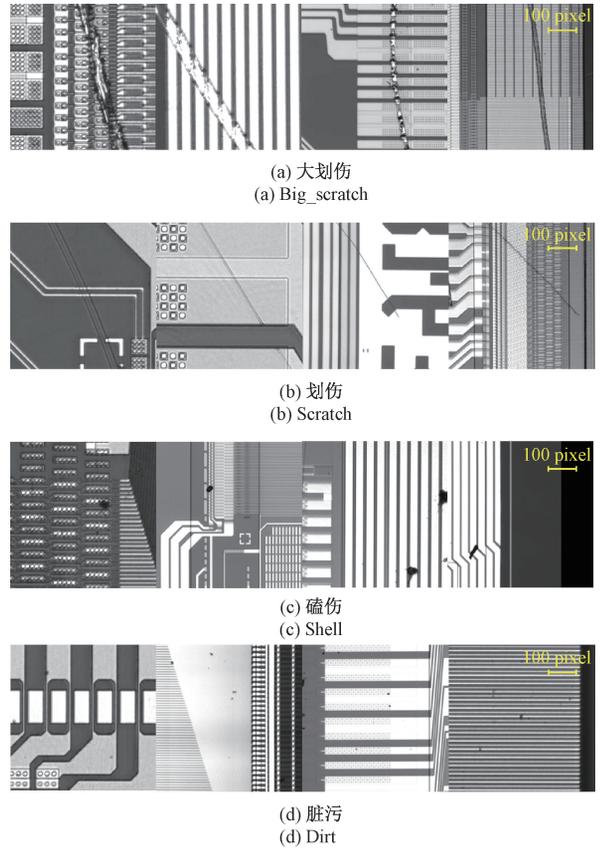


图 4 液晶面板电极典型缺陷图像

Fig. 4 Typical electrode defect images

使用 Labelimg 标注软件共标注 11 294 个缺陷, 并将数据集按照 8 : 1 : 1 的比例划分为训练集、验证集和测试集, 各种缺陷的数量如表 1 所示。

表1 数据集中各种缺陷的数量

Table 1 The number of defects in the data set

缺陷名称	训练集	验证集	测试集
大划伤 (big_scratch)	2 958	359	411
划伤 (scratch)	2 210	328	251
磕伤 (shell)	1 432	177	207
脏污 (dirt)	2 408	298	255
合计	9 008	1 162	1 124

由于数据集规模较小,为了提高模型的泛化性和鲁棒性。在建立数据集时,通过降噪、改变图像对比度等方法,改善了图像质量^[21];在训练时,采用在线增广的方法,对数据集使用了随机左右翻转、尺寸缩放以及 Mosaic 数据增强方法,以此增加了训练数据的丰富性和多样性,使模型学习到更多的特征。

2) 实验环境

实验的操作系统和软件环境为:Ubuntu20.04、Python 3.8、CUDA11.0、PyTorch1.7.1。硬件环境为:CPU 采用 Intel Core i7-12700K,内存为 32 G;GPU 采用 NVIDIA GeForce RTX 3080,显存为 10 G。训练时采用的参数如下,训练轮数设置为 250 次,批量设置为 16,输入图像大小为 512 pixels×512 pixels,初始学习速率设置为 0.01,采用余弦退火方式调整学习率,权重衰减值为 0.0005。在训练中使用具有内斯特罗夫 (Nesterov) 动量的随机梯度下降 (stochastic gradient descent, SGD) 优化器,动量设置为 0.937,用于加快梯度下降算法的收敛速度,并防止波动和快速变化,从而更快地实现模型训练和优化。

2.2 评价指标

为客观地评价改进后模型与原模型及其他模型的性能,在同样的实验条件下对缺陷检测结果进行比较,主要选取准确率 (Precision, P)、召回率 (Recall, R)、平均精度 (Average Precision, AP)、平均精度均值 (mean Average Precision, mAP)、计算量 (GFLOPs)、检测时间 (Time) 作为模型的评价指标。检测时间指的是检测单张电极图片所需的时间。计算公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$AP = \int_0^1 P(R) dR \quad (9)$$

$$mAP = \frac{\sum_{j=1}^M AP}{M} \quad (10)$$

其中,TP 表示真实的正样本数量,FP 表示虚假的正样本数量,FN 表示虚假的负样本数量,M 表示数据集中的类别数。

2.3 不同改进点的实验分析

1) CBAM 注意力模块

为验证 YOLOv7 网络模型嵌入 CBAM 模块后的检测性能,基于自定义的电极缺陷数据集进行如下实验:实验 1 基准模型;实验 2 在 ELAN1 和上下采样后嵌入 CBAM 模块;实验 3 在 ELAN1 后嵌入 CBAM 模块;实验 4 在上下采样后嵌入 CBAM 模块;实验 5 在第 1 个和第 4 个 ELAN1 后嵌入 CBAM 模块;实验 6 在第 1 个和第 4 个 ELAN1 后以及两个分支卷积层后嵌入 CBAM 模块;实验 7 在第 1 个和第 4 个 ELAN1 后嵌入 SimAM (a simple, parameter-free attention module for convolutional neural networks)^[22] 模块。结果如表 2 所示。

表2 CBAM 注意力模块的实验分析

Table 2 Experiment of CBAM module

实验序号	计算量/G	P/%	R/%	mAP/%
1	105.2	61.1	66.5	64.6
2	107.9	61.4	66.9	65.0
3	106.0	65.8	62.2	65.4
4	107.0	61.6	66.5	64.9
5	105.7	65.3	63.8	66.1
6	107.0	58.4	59.8	59.6
7	105.2	68.4	63.2	65.8

由表 2 可知,实验 2 使模型 mAP 提升了 0.4%;实验 3 提升了 0.8%;实验 4 提升了 0.3%。由此得知,无论是在 ELAN1 后还是上下采样后嵌入 CBAM 模块,均可提升模型的检测精度。其中实验 3 的 mAP 提升最大,且计算量增加的较少。因此,选择在 ELAN1 后嵌入 CBAM 模块,可以更好地抑制背景信息干扰,增强模型提取电极缺陷的能力。

由实验 5、6 可知,实验 5 使模型的 mAP 提升了 1.5%;实验 6 降低了 5%,这是由于分支卷积层和骨干网络提取的注意力特征信息不同,当进行张量拼接时,分支卷积层提取的注意力特征信息会对特征融合产生干扰,增加缺陷分类的难度,从而降低检测精度。由此选择在第 1 个和第 4 个 ELAN1 后嵌入 CBAM 模块,不仅 mAP 高,而且计算量比其他嵌入方式更少。

为了更进一步探究注意力模块对模型检测精度的影响,使用 SimAM 注意力模块进行对比实验。由实验 7 可知,模型添加 SimAM 注意力模块后不仅没有增加计算量,反而提升了检测精度,但相较于 CBAM 注意力模块检测精度略有不如。

2) 跨层级连接

为了验证跨层级连接位置对网络模型的影响,进行如下实验:实验 1 第 3 个和第 4 个 ELAN1 直接与 Concat 层融合;实验 2 Backbone 部分中第 3 个和第 4 个 MPConv 直接与 Concat 层融合。结果如表 3 所示。

表 3 跨层级连接实验分析

Table 3 Experiment of cross level connection

实验序号	计算量/%	P/%	R/%	mAP/%
1	107.3	64.5	67.6	66.2
2	106.4	60.5	60.2	61.5

由表 3 可知,实验 1 和实验 2 均对模型的计算量有不同程度的增加,主要原因是跨层级连接增加了 Neck 部分的计算量。其中实验 1 的 mAP 比实验 2 结果更高,主要原因是池化后的特征图对缺陷特征的定位不够精准。由此,采用将第 3 个和第 4 个 ELAN1 直接与 Concat 层融合的方式进行跨层级连接。

3) C2f 模块

为了验证模型引入 C2f 模块后的效果,进行如下实验:实验 1 将第 1 个和第 4 个 ELAN1 替换为 C2f 模块;实验 2 将所有 ELAN2 替换为 C2f 模块;实验 3 将第 1 个和第 2 个 ELAN1 以及所有 ELAN2 替换为 C2f 模块。结果如表 4 所示。

表 4 C2f 模块实验分析

Table 4 Experiment of C2f module

实验序号	计算量/G	P/%	R/%	mAP /%
1	46.1	57.4	57.7	57.7
2	94.4	60.4	68.9	65.7
3	43.4	63.8	59.4	63.1

由表 4 可知,实验 2 使模型 mAP 提升了 1.1%,比其他两种方式的提升幅度高,相较于基准模型计算量都有明显降低。实验 1 和实验 3 虽然大幅度降低了计算量,但是 mAP 都有不同程度的降低。这是因为在 Backbone 部分替换 ELAN1 模块为 C2f 模块会减少参数量,影响 Backbone 对特征的提取。因此,通过将所有 ELAN2 替换为 C2f 模块,可以在减少计算量的同时提升特征融合的性能,从而提高检测精度。

2.4 消融实验

为了验证改进后模型在复杂背景下对液晶面板电极缺陷检测的优化效果,进行了如下实验来分析性能影响。每个实验都使用相同的训练参数和不同的模型结构进行,分别为:实验 1 嵌入 CBAM 模块;实验 2 进行跨层级连接;实验 3 替换 ELAN2 为 C2f 模块;实验 4 替换损失函数为 WIoU;实验 5 嵌入 CBAM 模块并进行跨层级连接;实验 6 添加 CBAM 和 C2f 模块并进行跨层级连接;实验 7 添加 CBAM 和 C2f 模块,进行跨层级连接并替换损失函数。结果如表 5 所示。

表 5 消融实验分析

Table 5 Comparison of ablation experiment result

实验序号	方法	计算量/G	P/%	R/%	mAP/ %	时间/ ms
0	YOLOv7	105.2	61.1	66.5	64.6	5.9
1	+CBAM	105.7	65.3	63.8	66.1	10.8
2	+BiFPN	107.3	64.5	67.6	66.2	8.5
3	+C2f	94.4	60.4	68.9	65.7	6.1
4	+WIoU	105.2	65.8	64.9	66.7	9.2
5	1+BiFPN	107.7	63.6	66.8	66.8	11.0
6	5+C2f	95.9	64.8	66.6	67.2	6.7
7	6+WIoU	95.9	67.6	63.0	67.8	5.6

由表 5 可知,嵌入 CBAM 模块后,网络表征能力得到增强,通过突出关键特征,有效解决了背景复杂导致特征提取困难的问题。并使模型 mAP 提升了 1.5%,虽然检测时间增加了 4.9 ms,但仍满足实时检测(小于 40 ms/张)的要求。主要因为嵌入 CBAM 模块后,增加了模型的计算量和内存占用,导致检测时间增加。

进行跨层级连接后,由于深层特征图保留了低级语义信息,从而提升了模型对图像中像素占比少的小目标缺陷的识别能力,解决了小目标缺陷漏检的问题,其检测精度比嵌入 CBAM 模块有 0.1% 的提升。在引入 C2f 模块后,模型的检测精度虽然不如实验 1 和 2,但计算量显著减低。可知模型在引入 C2f 模块后,有利于轻量化模型且不影响检测精度。替换损失函数后可知,不会增加模型的计算量,且有助于检测精度的提升。

在添加 CBAM 模块的基础上进行跨层级连接使 mAP 提升至 66.8%,检测时间增加了 5.1 ms,说明通过添加 CBAM 模块和跨层级连接操作,可以抑制复杂背景信息的干扰,并实现小目标的识别,但会增加检测时间。继续引入 C2f 模块后,不仅模型的计算量明显减少,而且 mAP 继续提升至 67.2%,相较于实验 5 检测时间减少了 4.3 ms。

通过对 Neck 部分进行轻量化改进,可以很好的兼顾 mAP 和检测时间。最后在对损失函数进行替换后,模型性能达到最佳,mAP 为 67.8%,检测时间为 5.6 ms,比改进前的 YOLOv7 网络模型 mAP 高 3.2%,检测时间减少了 0.3 ms,这验证了改进后模型的有效性。改进前后的 P-R 曲线如图 5 所示,可知改进后模型对 4 类缺陷的检测性能均有提升。

2.5 对比实验

为进一步验证和评估所提出方法的检测性能,采用相同的硬件资源和电极缺陷数据集对 YOLOv3、YOLOv3-spp、YOLOv4-csp 和 YOLOv5-s 网络模型进行对比实验。结果如表 6 所示。

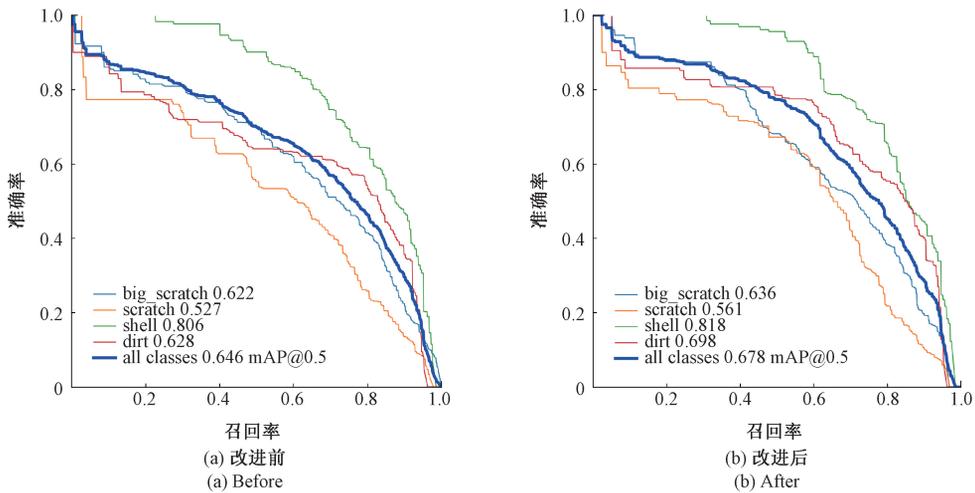


图5 YOLOv7网络模型改进前后的P-R曲线

Fig. 5 Comparison before and after improvement

表6 对比实验分析

Table 6 Performance comparison of algorithms

方法	计算量/G	AP/%				mAP/%	时间/ms
		大划伤	划伤	磕伤	脏污		
YOLOv3	155.3	63.0	50.8	80.6	60.3	63.7	5.3
YOLOv3-spp	156.2	59.1	47.4	72.2	59.0	60.7	5.4
YOLOv4-csp	119.7	59.4	47.5	77.7	61.7	61.6	5.7
YOLOv5-s	15.1	56.9	44.1	73.8	60.7	58.9	2.6
YOLOv7	105.2	62.2	52.7	80.6	62.8	64.6	5.9
本文	95.9	63.6	56.1	81.8	69.8	67.8	5.6

由表6可知,改进后模型不仅计算量减少为95.9 G,而且各类别缺陷的检测精度均为最高,其mAP为67.8%,比YOLOv7模型提高了3.2%。虽然YOLOv5-s的计算量为15.1 G,但是其对各类别的检测精度较低,其mAP只有58.9%。

为直观表述不同算法对不同缺陷的检测效果,选取测试集中4类缺陷进行测试。测试效果如图6所示,每组依次为原图、YOLOv5-s、YOLOv7和改进后模型。

通过图6可知,YOLOv5-s、YOLOv7和改进后模型均能正确检测出缺陷的类别,主要原因是图中背景信息干扰较小、模型特征明显以及数据集中big_scratch和dirt标签充足,因此都能够较为准确地检测出目标。但是,改进后模型检测得分最高。在大划伤、磕伤和脏污的检测中,YOLOv5-s均出现漏检现象,其特征提取的能力较弱,对于目标的检测得分较低。YOLOv5-s和YOLOv7在划伤的检测中出现了重复标签的现象,主要原因是数据集中存在一些低质量的标注,从而导致算法误判,而改进后模型利用WIoU替换损失函数,能够很好地抑制低质量标注的干扰。在对小目标缺陷脏污的检测结果中可以发现改进后模型识别准确率最高,达到69.8%,远超过其他

算法。对比结果表明,改进后模型对各类缺陷的检测精度最高。

3 结论

针对液晶面板电极缺陷种类多、尺度小、背景复杂而导致难以检测的问题,本文提出了一种基于改进YOLOv7的液晶面板电极缺陷视觉检测方法。首先,通过添加CBAM注意力模块和跨层级连接操作,提高了模型对复杂背景信息的抗干扰能力,使模型能够在深层特征图中保留更多的低级语义信息,从而更好的识别小尺寸目标;其次,通过引入C2f模块和WIoU损失函数,大幅降低了模型的参数量和重复标签的出现,使模型轻量化,从而提升模型的训练速度和检测精度。在自定义的液晶面板电极缺陷数据集上进行测试,结果表明,本文提出的算法对电极大划伤、划伤、磕伤以及脏污4类缺陷的平均检测精度达67.8%,单张检测时间为5.6 ms,满足工业中实时检测要求。相较于其他YOLO系列的目标检测算法,具有更好的检测性能。

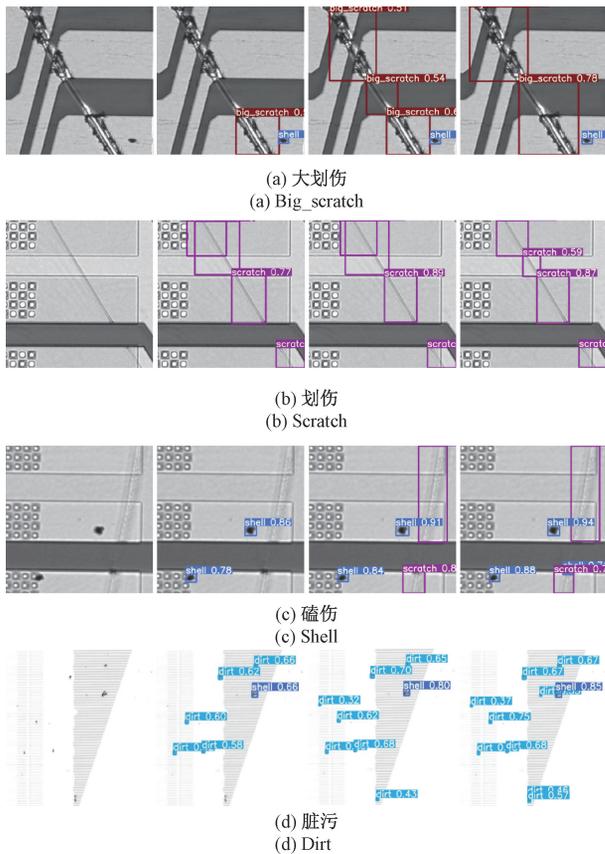


图 6 电极缺陷测试集上的检测效果

Fig. 6 Renderings on electrode defect test set

参考文献

- [1] RAMAN V, LEE J E, KIM H K. Mechanically flexible multi-stacked ITO/PEDOT:PSS hybrid superlattice films for transparent conductive electrodes [J]. Journal of Alloys and Compounds, 2022, 903: 163799.
- [2] 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.
- ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43 (1): 198-219.
- [3] LIN G, KONG L, LIU T, et al. An antagonistic training algorithm for TFT-LCD module mura defect detection [J]. Signal Processing: Image Communication, 2022, 107: 116791.
- [4] GAO Y P, LI X Y, WANG X V, et al. A review on recent advances in vision-based defect recognition towards industrial intelligence [J]. Journal of Manufacturing Systems, 2022, 62: 753-766.
- [5] LI C S, ZHANG X M, HUANG Y J, et al. A novel

algorithm for defect extraction and classification of mobile phone screen based on machine vision [J]. Computers & Industrial Engineering, 2020, 146: 106530.

- [6] YAO J, LI J. AYOLOv3-Tiny: An improved convolutional neural network architecture for real-time defect detection of PAD light guide plates [J]. Computers in Industry, 2022, 136: 103588.
- [7] 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.
- [8] WANG C Y, BOCHKOVSKIY A, LIAO H. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. ArXiv Preprint, 2022, ArXiv: 2207.02696.
- [9] 强栋, 王占刚. 基于改进 YOLOv5 的复杂场景多目标检测 [J]. 电子测量技术, 2022, 45 (23): 82-90.
- QIANG D, WANG ZH G. Improved YOLOv5 complex scene multi-target detection [J]. Electronic Measurement Technology, 2022, 45 (23): 82-90.
- [10] 吕辉, 董帆. 基于 YOLOv4 的复杂交通状况下多目标检测算法 [J]. 国外电子测量技术, 2022, 41 (12): 41-47.
- LYU H, DONG F. Multi object detection algorithm under complex traffic conditions based on YOLOv4 [J]. Foreign Electronic Measurement Technology, 2022, 41 (12): 41-47.
- [11] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 936-944.
- [12] 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, IEEE, 2018: 8759-8768.
- [13] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. ArXiv Preprint, 2021, ArXiv: 2005.03572.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. Proceedings of the 15th European Conference on Computer Vision (ECCV), 2018: 3-19.
- [15] 彭道刚, 潘俊臻, 王丹豪, 等. 基于改进 YOLO v5 的电厂管道油液泄漏检测 [J]. 电子测量与仪器学报, 2022, 36 (12): 200-209.
- PANG D G, PAN J ZH, WANG D H, et al. Oil leakage detection of pipeline of power plants based on improved

- YOLOv5 [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12): 200-209.
- [16] 石欣, 卢灏, 秦鹏杰, 等. 一种远距离行人小目标检测方法[J]. 仪器仪表学报, 2022, 43(5): 136-146.
SHI X, LU H, QIN P J, et al. A long-distance pedestrian small target detection method [J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 136-146.
- [17] 赵文博, 周德强, 邓干然, 等. 基于改进YOLOv5的甘蔗茎节识别方法[J]. 华中农业大学学报, 2023, 42(1): 268-276.
ZHAO W B, ZHOU D Q, DENG G R, et al. Sugarcane stem node recognition method based on improved YOLOv5 [J]. Journal of Huazhong Agricultural University, 2023, 42(1): 268-276.
- [18] AI S, CHEN Y T, LIU F, et al. Pill defect detection based on improved YOLOv5s network [J]. Instrumentation, 2022, 9(3): 27-36.
- [19] MA J, LU A, CHEN C, et al. YOLOv5-lotus an efficient object detection method for lotus seedpod in a natural environment [J]. Computers and Electronics in Agriculture, 2023, 206: 107635.
- [20] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv Preprint, 2023, ArXiv: 2301.10051.
- [21] CAI X, CHEN Y T, MA H B, et al. Visual inspection method of steel pipe surface cracks based on dry magnetic

particle feature enhancement[J]. Nondestructive Testing and Evaluation, 2023, 38(2): 254-274.

- [22] YANG L X, ZHANG R Y, LI L D, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning, PMLR, 2021: 11863-11874.

作者简介



范先友, 2019年于安徽工程大学获得学士学位。现为江南大学硕士研究生, 主要研究方向为深度学习和目标检测。

E-mail: fdxianyou@163.com

Fan Xianyou received his B. Sc. degree from Anhui University of Engineering in 2019.

Now his is a M. Sc. candidate of Jiangnan University. His main research interests include deep learning and object detection.



俞建峰(通信作者), 2004年于上海交通大学获得博士学位。现为江南大学机械工程学院教授, 主要研究方向为机器人运动控制、工业互联网与智能传感、电机嵌入式驱动系统等。

E-mail: robotmecu@126.com

Yu Jianfeng (Corresponding author) received his Ph. D. degree from Shanghai Jiao Tong University in 2004. Now he is a professor in the School of Mechanical Engineering at Jiangnan University. His main research interests include robot motion control, industrial interconnection and intelligent sensing, and embedded motor drive systems, etc.