

DOI:10.19651/j.cnki.emt.2518191

# 基于改进 YOLOv10 的液晶显示屏表面缺陷检测算法<sup>\*</sup>

杨瑞峰 廖映华 罗覃鹏 罗星燃

(四川轻化工大学机械工程学院 宜宾 644600)

**摘要:** 针对液晶显示屏(LCD)表面缺陷特征微弱、种类繁多且与背景相似度较高,导致现有检测方法精度较低的问题,提出了一种基于YOLOv10的改进液晶显示屏微弱缺陷检测模型—LC-YOLO。首先,将颈部网络上的卷积模块更改为全维动态卷积ODConv,在保证模型检测精度的同时降低了模型的计算量,提高对小缺陷特征信息的精确提取。其次,为进一步优化模型的性能,提出DySample动态上采样模块。通过点采样的方式避免背景的干扰,减少了误检和漏检现象。提高了模型在复杂背景下的鲁棒性。最后,为了增强模型对小目标的提取能力,本文引入了添加EMAttention注意力机制。该机制增强了模型对小型和暗淡目标的关注能力,从而显著提高了模型整体性能。在包含划痕、崩角、凹印3类缺陷的1774张数据集上进行的实验结果表明,与原YOLOv10模型相比,LC-YOLO在平均精度、准确率和召回率上分别提高了2.9%、2.4%和5.8%。同时,模型的计算量也减少了2%。与现有的目标检测算法相比,LC-YOLO在保持轻量化特性的同时,精度和检测速度也获得了提升,且在液晶屏表面微弱特征缺陷的检测中表现出优异的性能。

**关键词:** 液晶显示屏;微弱特征;缺陷检测;YOLOv10;EMAttention

**中图分类号:** TN873.93    **文献标识码:** A    **国家标准学科分类代码:** 520.60

## Liquid crystal display surface defect detection algorithm based on improved YOLOv10

Yang Rui Feng Liao Ying Hua Luo Qin Peng Luo Xing Ran

(College of Mechanical Engineering, Sichuan University of Science &amp; Engineering, Yibin 644600, China)

**Abstract:** In response to the challenges posed by the weak characteristics, diverse types, and high similarity with the background of surface defects in liquid crystal displays (LCDs), which result in low detection accuracy with existing methods, this paper proposes an improved micro-defect detection model for LCDs based on YOLOv10, referred to as LC-YOLO. First, the convolutional module in the neck network is replaced with a full-dimensional dynamic convolution (ODConv), which reduces the computational load of the model while maintaining detection accuracy and improving the precise extraction of small defect features. Next, to further optimize the model's performance, the DySample dynamic upsampling module is introduced. This module avoids background interference by point sampling, thereby reducing false positives and false negatives, and enhancing the model's robustness in complex backgrounds. Finally, to enhance the model's ability to detect small targets, the EMAttention attention mechanism is incorporated. This mechanism improves the model's sensitivity to small and dim targets, significantly boosting overall performance. Experimental results on a dataset of 1,774 images containing three types of defects—scratches, corner breaks, and dents—demonstrate that compared to the original YOLOv10 model, LC-YOLO improves mean average precision, accuracy rate, and recall by 2.9%, 2.4%, and 5.8%. Meanwhile, the computational load of the model is reduced by 2%. When compared to existing object detection algorithms, LC-YOLO not only retains its lightweight characteristics but also enhances detection accuracy and speed, showing excellent performance in detecting subtle surface defects in LCDs.

**Keywords:** LCD screen; weak feature; defect detection; YOLOv10; EMAttention

## 0 引言

液晶显示屏的外观缺陷不仅影响其视觉效果,还会显

著降低用户的使用体验<sup>[1]</sup>。根据缺陷的可见性和尺寸,液晶显示屏的外观缺陷可分为宏观缺陷和微观缺陷。宏观缺陷包括液晶面板上颜色分布不均、大面积污渍等容易被肉

眼识别的缺陷。而微观缺陷则包括点缺陷、线缺陷以及 Mura 缺陷等细微缺陷,这些缺陷难以通过肉眼察觉<sup>[2]</sup>。在当前的工业生产中,宏观缺陷仍主要依赖人工质检进行检测。然而,由于生产环境复杂,加之微观缺陷通常具有低对比度、种类繁多和整体亮度不均等特点,人工质检在微观缺陷的检测上存在明显局限性。人工质检不仅容易导致视觉疲劳,还会受到主观偏见、专业水平差异、遗漏和情绪状态等因素的干扰<sup>[3]</sup>。此外,随着电子产品出货量的迅速增加,液晶显示屏制造商面临着生产大量产品的压力,这对人工质检的人力需求提出了更高的要求,从而加重了质检工作的负担。为了克服传统人工检测的诸多弊端,基于深度学习的缺陷检测技术逐渐受到业界的广泛关注,成为提升液晶显示屏缺陷检测效率和精度的有效手段<sup>[4]</sup>。

然而,检测工业产品的表面缺陷不容易,特别是对于液晶显示屏这类具有大量小尺寸缺陷和复杂背景环境干扰的微弱缺陷,这对检测方法提出了挑战。刘熹等<sup>[5]</sup>采用动态非单调的聚焦机制损失函数来解决目标被遮挡时容易漏检的情况,并用空间金字塔池化模块来提高检测成功率,但这样增加了模型的复杂度并达不到理想的检测速度。Tao 等<sup>[6]</sup>提出一种 Deep Scratch Net 网络,通过分析提取大量的特征来表示划痕,实现的划痕特征的高效检测,但是该方法在复杂背景中容易受到背景噪声干扰。张航等<sup>[7]</sup>针对多尺度、多类型和复杂背景的钢材表面缺陷设计了一种融合 HGnetv2 的算法,通过对浅层边缘信息和深层语义信息的有效聚合使得其检测精度获得显著提升,但也导致模型的复杂度增加使得检测速度下降。Sun 等<sup>[8]</sup>为解决陶瓷表面小缺陷而提出了一种新型的卷积模块 CBS-SPD 来增强小特征的提取。然而,该网络在小样本数据集上的泛化能力较弱,对于拥有多样性的缺陷类型适应性明显不足。吴永泽等<sup>[9]</sup>引入空洞卷积增强多尺度特征提取能力,再通过 LSKA 模块增强多尺度特征融合效果来解决电池壳缺陷检测精度低的问题,但并未考虑到模型复杂度以及检测实时性的问题。Wan 等<sup>[10]</sup>提出针对导光板(LGP)背景复杂且对比度低的微弱缺陷的 LGP-YOLO 算法,增强网络对与微弱特征的提取能力,有效减少无关目标干扰,提高网络性能。

尽管已有研究在弱特征增强、局部相似性问题和复杂背景干扰的解决方面取得了重要进展,但仍然存在一些不足之处。例如,现有方法在面对极端复杂的工业场景时,检测效率和准确率可能受到限制,尽管检测精度得到了提高,但同时也增加了模型的复杂度以及检测速度,需要在实时性和轻量化设计之间的平衡方面进一步优化。此外,某些方法对缺陷的多样性和随机性适应性不足,尤其是在不同材料表面特性显著差异的情况下,模型的泛化能力有限。

本研究旨在解决 LCD 缺陷检测中实时性、精度和泛化能力不足的问题,提出一种基于改进 YOLOv10 的检测方法。针对在实际工业生产环境中光线暗淡导致液晶显示屏

缺陷特征识别困难,背景颜色较深,特征缺陷与背景相似度高且多数为小尺寸微弱特征等问题。基于 YOLOv10n<sup>[11]</sup>算法提出一种适用于工业生产实时检测的小尺寸液晶显示屏微弱特征缺陷的检测算法。主要研究内容如下:

1) 优化了 YOLOv10 上采样模块,利用新的 DySample<sup>[12]</sup>轻量动态上采样器,通过点采样而不是传统的内核方法来实现上采样,使采样点集中在特征区域而尽可能避免背景的干扰,相比于传统的采样方式具有更少的参数,更轻量级、运行更快。

2) 在保证检测精度的同时,将颈部网络中原有的卷积模块替换为动态的、多维的 ODCConv<sup>[13]</sup>模块,通过 4 个维度并行计算 4 种类型的注意力,减少了模型的计算量。

3) 为了提高模型对小尺寸液晶显示屏微弱缺陷的提取能力,在颈部的小目标检测层输出位置加入了一种高效多尺度注意力机制 EMAAttention,将部分通道映射到批次维度,并将通道分为多个子特征,保留每个通道信息的同时,又能显著减少计算量。

## 1 LC-YOLO 检测算法

### 1.1 LC-YOLO

YOLOv10 是 YOLO 系列目标检测模型中的最新版本,旨在实现检测精度与实时性之间的最佳平衡<sup>[14]</sup>。在拍摄的液晶屏数据集中随机选用 200 张样本对 YOLOv5、YOLOv7-Tiny、YOLOv8s 以及 YOLOv10n 进行性能检测,检测精度分别为 82.4%、78.2%、82.6% 以及 84.1%。相比之下 YOLOv10n 基础性能较好,因此选为本文的基础模型进行改进。

为了提高检测精度,YOLOv10 模型中引入了大量的 C2f 模块,虽然增强了特征表达能力,但也增加了模型的计算量。尽管在大部分场景中表现优异,但在处理小目标时仍存在一定的局限性,主要原因是模型在捕捉小目标细节时容易发生特征丢失<sup>[15]</sup>。液晶显示屏上的缺陷通常属于多尺度或小尺度目标,因此需要对卷积结构进行优化,以便更好捕捉细节并提升检测性能。尽管 YOLOv10 与前代模型的对比中展现了较大的优势,但在复杂的应用环境中,仍需要根据具体需求对模型进行优化,应对更多的挑战。

本文以 YOLOv10 为基础,并在此基础上开发一个利于工厂实际生产情况下的液晶显示屏缺陷实时检测算法 LC-YOLO。YOLOv10 的网络结构大致可以分为 3 个区块:主干、颈部和预测头部。针对小尺寸液晶显示屏表面存在的微弱缺陷特征具有对比度低、尺寸小、液晶屏背景复杂以及种类多且特征不明显等特点。在 YOLOv10n 模型基础上进行模型的优化和改进。改进后的 LC-YOLO 模型整体结构如图 1 所示。首先,使用 ODCConv 模块替换掉模型颈部网络中原有的 Conv 模块,在保证模型检测精度的同时降低了模型的计算量。然后,为了降低液晶屏背景的影

响,将 YOLOv10 原始的上采样更换为 DySample 轻量动态上采样器,将采样点集中在目标特征区域,避免背景部分对采样的干扰,避免出现误检及漏检等问题。最后,为了提升模型对小目标的提取能力,在上述模型改进的基础之上添加 EMAttention<sup>[16]</sup>注意力机制,增强网络对小目标和暗淡目标的检测性能,从而提高模型整体精度。

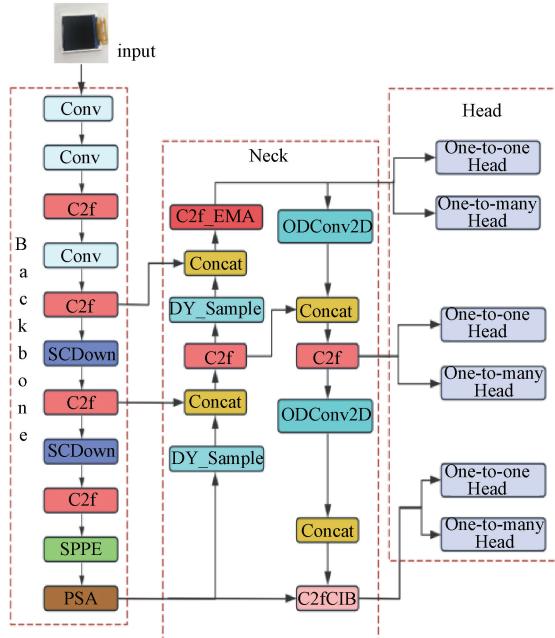


图 1 LC-YOLO 整体结构

Fig. 1 Overall structure of LC-YOLO

## 1.2 颈部网络替换新的卷积模块

在目标检测中,检测精度和速度是关键因素。卷积操作在模型中取得了显著成果,但过多的卷积模块会降低算法的运行速度。ODConv 作为一种新型的卷积操作,在提升卷积神经网络特征表达能力的同时还保持了计算效率<sup>[17]</sup>。相比于传统卷积,ODConv 引入了 3 个额外的维度参数:卷积核的空间维度、输入通道数和输出通道尺寸。ODConv 工作流程如图 2 所示。

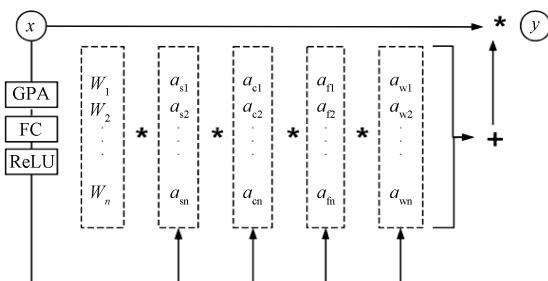


图 2 ODConv 工作流程

Fig. 2 ODConv workflow

传统卷积中的卷积层提取特征是使用固定的、非动态的卷积核来提取,ODConv 通过  $n$  的线性组合提取特征,沿

着卷积核空间的 4 个维度计算 4 种类型的注意力:  $a_{si}$ ,  $a_{ci}$ ,  $a_{fi}$  和  $a_{wi}$ 。卷积核通过注意力机制进行动态加权,使卷积运算依赖于输入,数学定义如式(1)所示。

$$y = (\alpha_{w1}w_1 + \dots + \alpha_{wn}w_n) \cdot x \quad (1)$$

其中,输入特征为  $x$ ,输出特征为  $y$ ,  $w_i$  则表示第  $i$  次卷积,  $\alpha_{wi}$  代表  $w_i$  的注意力标量。

ODConv 模块的集成帮助在不同维度上进行自适应卷积核动态调整,从而适应不同的输入特征,特别是对小目标缺陷和复杂背景的缺陷信息,在保持检测精度的同时提高模型的运算速度。

## 1.3 上采样方法优化

液晶显示屏检测中,其表面微弱的特征缺陷常与背景混淆,导致误检和漏检。YOLOv10 的上采样一般采用固定的双线性插值或转置卷积方法,但这种方式可能导致小目标信息的丢失,且在处理复杂背景或目标边缘区域时缺乏细节。为了解决这些问题,本文提出了 DySample 上采样模块,替代了传统的上采样方法。DySample 通过动态生成采样点和插值权重,显著提升了特征图上采样的效果<sup>[18]</sup>。与传统方法相比,DySample 在保持局部细节特征方面表现更佳,同时有效减少了背景干扰。DySample 模块的主要流程如图 3 所示。

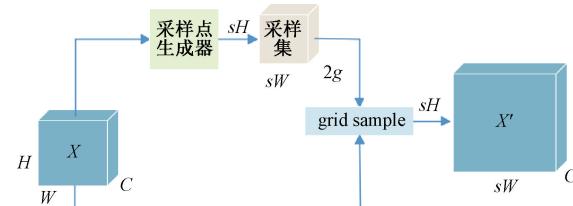


图 3 DySample 上采样流程

Fig. 3 DySample indicates the sampling process

给定一个大小为  $C \times H \times W$  的特征图  $X$  和一个大小为  $2g \times sH \times sW$  的点采样集  $S$ ,其中  $2g$  表示  $x$  和  $y$  坐标,使用 grid\_sample 函数根据点采样集  $\theta$  中的位置对  $X$  重新采样,得到大小为  $C \times sH \times sW$  的特征图  $X'$ ,如式(2)所示。

$$X' = \text{Gridsample}(X, S) \quad (2)$$

点采样集  $S$  采用“线性+像素重组”的方式生成,偏移范围可以由静态范围因子和动态范围因子决定,如图 4 所示。

由静态范围因子决定的方式为给定一个上采样因子  $s$  和一个大小为  $C \times H \times W$  的特征映射  $X$ ,  $X$  通过一个线性层,其输入和输出通道为  $C$  和  $2gs^2$ ,再重组为大小为  $sW \times sH \times 2g$  的偏移量  $O$ ,如式(3)所示。

$$O = \text{linear}(X) \quad (3)$$

于是采样集  $S$  为原始采样网格  $G$  和偏移量  $O$  之和,如式(4)所示。

$$S = O + G \quad (4)$$

通过动态调整上采样点的偏移量,可以更加精确地恢

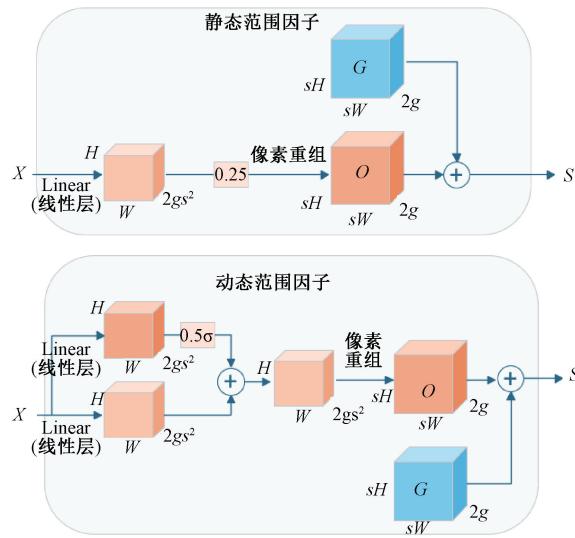


图 4 点采样集生成过程

Fig. 4 Point sampling set generation process

复液晶显示屏表面的微小缺陷特征,提高模型对细节的感知能力,从而更准确地定位和识别这些微小缺陷。

#### 1.4 EMAAttention 注意力机制

EMA(EMAttention)是一种高效的多尺度注意力模块。其核心是将部分通道映射到批次维度,并将通道划分成多个子特征,这样不仅保留了每个通道的信息,还能有效减少计算开销。如图 5 所示,输入特征图经过卷积层提取特征后进入 EMAttention 模块,将特征图的通道划分为多个组,每组只计算部分通道的注意力权重,其中包括两条  $1 \times 1$  分支和一条  $3 \times 3$  分支,前者分别进行  $X$  和  $Y$  方向池化,最终将两个通道捕捉的特征通过 Sigmoid 函数聚合在一起。后者则捕获局部跨通道特征关系。最终把两组的输出特征映射相加,得到增强后的特征图。在微弱缺陷或小目标检测任务中 EMA 表现出了出色的性能。

与仅关注通道或空间特征的 ECA (efficient channel attention)相比,EMA 更高效地结合了全局与局部信息。在处理低对比度和多样化缺陷场景时,其动态优化能力显

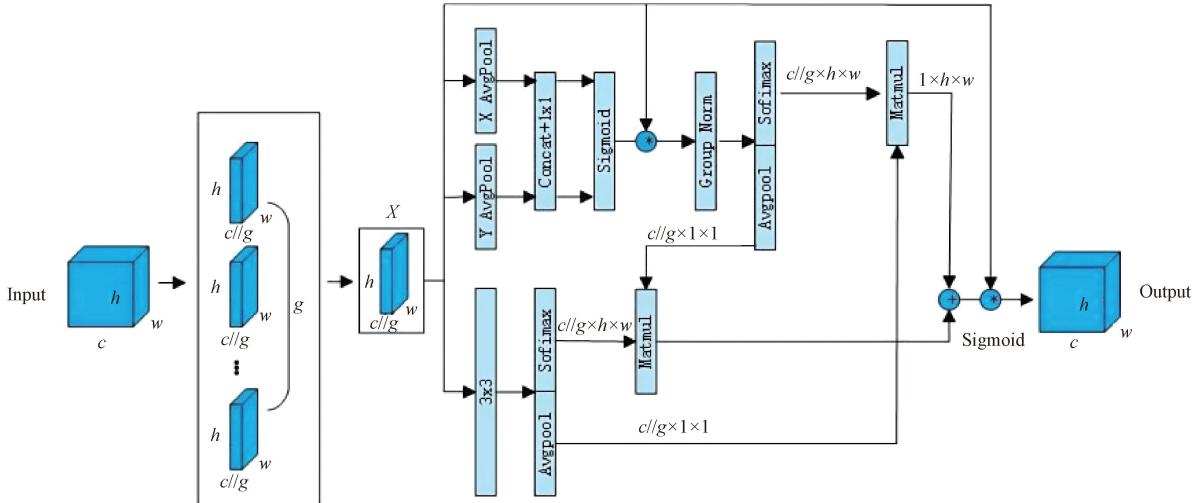


图 5 EMA 模块

Fig. 5 EMA module

著提升了模型性能。同时,相较于计算复杂的 DAT (DAttention),EMA 在保持高性能的同时显著降低了计算成本,尤其适合对实时性和计算效率要求较高的应用场景。EMA 是一种综合考虑全局与局部特征、动态优化权重的注意力机制,相较于其他注意力机制(DAT、ECA、CA),在处理复杂背景、微弱特征的工业产品缺陷检测任务中具有更强的适用性和鲁棒性,因此选择 EMA 作为本研究中的注意力机制实现方案。

## 2 实验与结果分析

### 2.1 实验环境配置与数据集

表 1 列出了所有模型的训练平台和超参数设置。本实验中,所有模型的训练与测试都在 Pytorch 深度学习框

架下进行,同时使用 Python 编程语言编写数据集的制作、模型评估与预测以及结果可视化等相关程序。

本实验使用的数据集来自当地一家液晶显示模组制造企业生产的 3.5 英寸液晶显示屏。由于显示屏背景较为复杂,导致缺陷识别任务的难度增加,而液晶显示屏缺陷通常是由小尺寸的特征瑕疵。因此,构建一个高质量的数据集比一般样本采集更加具有挑战性,尤其在液晶屏采集过程中,需要充分考虑背景反射、不同观察角度等因素。为此,选择了合适的光源和相机,具体考量如下:1) 相机像素至少需要达到 2000 万像素,而市面上的智能相机无法满足实验要求。因此,选用了工业相机。在对比多款工业相机的分辨率及主要参数后,同时综合考虑成本因素,最终选择了海康工业相机。2) 尝试了几种不同的光源如

轴光源、环形光源以及背光光源,发现同轴光源能够有效的减少反光,其对液晶屏背景的反射影响较小。3)为了进一步降低采集过程中液晶屏背景反光的影响,在同轴光源处安装了一张透光纸。这一处理在不改变光照强度的同时,有效减少了背景反光问题,提高了采集数据的质量。图像采集平台如图 6 所示。

表 1 实验环境配置

Table 1 Experimental environment configuration

配置	具体参数
操作系统	Windows10 21H1
CPU	AMD Ryzen 9 5950X
显卡	GeForce RTX 4090
显存	24 G
内存	64 G
深度学习框架	Pytorch 2.0.1
Opencv-Python	4.7.0
CUDA 版本	12.1
CUDNN	8.8.1
编程语言	Python3.7

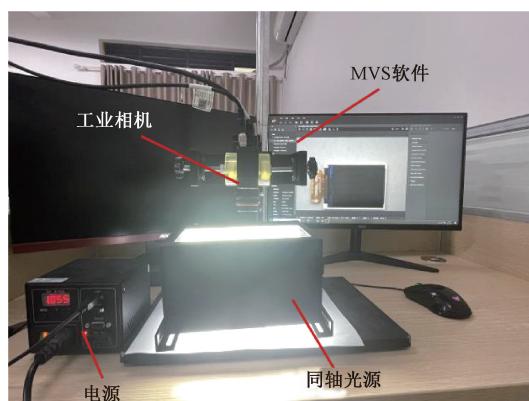


图 6 图像采集平台

Fig. 6 Image acquisition platform

图 7 展示了液晶显示屏表面常见的 3 种缺陷,分别是划痕、崩角和凹印。为了有效验证模型的性能,尽可能模拟实际的工业场景,在工厂中拍摄了一部分缺陷样本作为数据集,并且在后续拍摄过程中通过亮度变换、拍摄角度变换等方式模拟实际工业场景,从而实现在不同光线、背景条件下验证模型性能的有效性。

本实验共采集了 1 774 张图像,构建了涵盖这 3 类缺陷的数据集作为实验数据,并利用 LabelImg 标注工具对液晶屏缺陷数据集进行了精确标注。

首先将标注好的数据集打乱后,将训练集、验证集和测试集按 8 : 1 : 1 的比例进行划分。上述比例是机器学习和数据科学领域的标准做法,特别是在深度学习领域。该方法在足够数量的数据集上训练模型,同时确保验证集

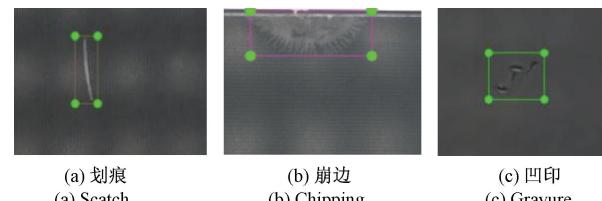


图 7 液晶屏 3 类常见缺陷样本

Fig. 7 LCD screen three common defect samples

和测试集保留足够的数据,从而实现了最佳的平衡,确保模型的鲁棒性和泛化能力。80% 的训练数据有助于模型学习更多的特征,避免过拟合。剩余的 20% 数据均匀分布于验证集和测试集,用于评估模型在未见数据上的表现,最大限度地降低过拟合的风险。

## 2.2 实验参数设置与评价指标

根据实验的硬件条件,选择了合适的超参数进行训练,具体设置如表 2 所示。为了减少因初始学习率过高而引起的模型震荡<sup>[19]</sup>,使用学习率预热(Warm-up)策略,学习率预热策略是在训练的初期,逐渐增加学习率的过程,以帮助模型更好地收敛到最优解。通过这样的学习率预热机制,可以使模型在训练初期更好地适应数据,提高训练的稳定性和性能,学习率预热曲线如图 8 所示。

表 2 实验超参数设置

Table 2 Experimental hyperparameter setting

Parameters	Configuration
输入图片尺寸	640×640
动量	0.937
权重衰减系数	0.000 5
参数学习率	0.01
迭代次数	200
批样本大小	16

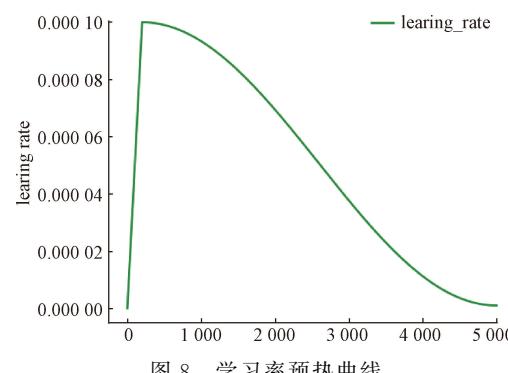


图 8 学习率预热曲线

Fig. 8 Learning rate preheating curve

此外,初始学习率设为 0.01,衰减系数为 0.000 5,迭代次数(epoch)设定为 200,批次大小(batch)为 16,输入图像尺寸为 640×640。为保持输入图像的多样性,采用了高

斯模糊和旋转变换等数据增强技术。同时,为了更公平地比较模型在液晶屏上的检测性能,所有模型都从 0 开始训练,不使用预训练权值。

本文主要使用以下指标从不同的角度对模型的性能进行评价:精度( $<P>$ )、召回率( $<R>$ )、平均精度( $<mAP@0.5>$ )、模型计算复杂度的计算量  $FLOPs$  以及算法内存占用的参数量(params)。 $P-R$  曲线是用精度和召回率作为变量绘制的曲线,曲线与坐标轴围成的面积即为  $AP$  值,表示单个类别的平均精度, $PR$  曲线的面积越大,右侧的凸度趋势更接近坐标系右上角则表示精度更高,其中  $i$  表示检测次数,  $n$  表示图像数量,  $AP(i)$  表示第  $i$  类别的平均准确率。此外,  $FPS$ (每秒帧数)用于衡量模型的推理速度,  $FPS$  值越高,模型的缺陷检测速度越快。上述指标的定义公式如下:

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$AP = \int_0^1 P(R) dR \quad (7)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (8)$$

### 2.3 卷积模块实验及分析

ODConv 替换不同位置的卷积对算法的影响如表 3 所示,各种类型的缺陷用  $mAP$  指标进行评估,最高的指标用粗体表示。为了得到最优的优化模型,本文在 YOLOv10n 模型的基础上对骨干、颈部以及两处都进行替换进行了 4 组实验,4 组实验除了替换位置不同外,模型其他模块以及实验参数没有变化。在骨干、颈部以及两者都替换后,算法的  $FLOPs$  分别降低了 3.2%、6.2% 和 7.8%,表明 ODConv 通过多维注意力机制并行学习,相较传统卷积有效减少了模型的计算量。尽管替换骨干与颈部网络后计算量降幅最大,但  $mAP$  值下降了 2.7%,表明改进后的算法在骨干网络特征提取方面存在不足,导致精度下降。相比之下,单独优化颈部网络时,算法的预测率、召回率和  $mAP$  均有所提升,尤其是在检测难度较大的凹印缺陷时表现突出。因此,本文决定在颈部网络部分优化卷积模块,提出新的 YOLO-O 算法。

表 3 ODConv 优化位置对算法的影响

Table 3 The influence of ODConv optimization position on the algorithm

实验	Backbone	Neck	$P/\%$	$R/\%$	$FLOPs/10^9$	$mAP/\%$	AP/%		
							scratch	gravure	Chipping
1			84.1	73.9	8.4	80.8	73.6	74.8	94.0
2	✓		83.1	76.4	8.1	80.7	73.8	74.4	94.2
3		✓	84.7	78.8	7.8	84.1	73.1	82.9	96.4
4	✓	✓	84.1	72.5	7.6	78.1	68.7	69.2	93.4

### 2.4 添加注意力模块实验及分析

为进一步提升模型在微弱特征缺陷检测中的精度,在替换颈部卷积模块后的 YOLO-O 中,单独添加 EMAAttention(EMA)等 4 种不同的注意力模块,在其他条件相同的情况下通过几组实验比较了不同注意力模块对模型网络整体性能的影响。在表 4 的实验结果中可以看到,添加了 EMAAttention 注意力机制后,模型的精度( $P$ )、召回率( $R$ )和  $mAP$  值效果最好。

表 4 不同注意力模块的模型性能

Table 4 Add model performance for different

注意力机制	attention modules			$\%$
	$P$	$R$	$mAP$	
YOLO-O	84.7	78.8	84.1	
DAT	83.2	79.6	86.2	
ECA	85.2	77.4	85.8	
MSDA	84.2	80.7	85.4	
EMA	<b>85.8</b>	<b>80.2</b>	<b>87.4</b>	

### 2.5 消融实验

为了更进一步分析各改进模块在算法中的贡献与效果,进行了消融实验对比,结果如表 5 所示。首先,在 YOLOv10n 算法基础上添加 EMAAttention 注意力机制,实验 4 结果表明,模型的  $mAP$  值显著提高,同时计算量略有减少,表明 EMA 在提升模型性能的同时,对模型计算复杂度几乎没有影响。接下来,将颈部原有卷积模块替换为 ODConv,并结合新的上采样模块 DySample,从实验 5 的结果可以看出,精确度值和  $mAP$  值提高了 1.3% 和 1.1%,并且模型计算量有所下降,这说明优化的上采样模块增强了模型的抗干扰能力,降低了模型计算复杂度。在实验 5 的基础上,不改变其他条件添加 EMAAttention 注意力机制,与实验 5 相比,算法的  $FLOPs$  未发生变化,但  $P$ 、 $R$  和  $mAP$  分别提升了 0.5%、2.3% 和 4.8%,结果表明 EMA 不会增加算法计算量,并能显著提升了模型的检测性能。根据多组实验结果,最终改进的 LC-YOLO 算法与 YOLOv10n 相比,模型在推理速度方面以及检测精度上有着较大的优势,有望实现液晶显示屏表面微弱特征缺陷的自动检测。

表 5 消融实验结果对比  
Table 5 Comparison of ablation results

实验	ODConv	DySample	EMAttention	P / %	R / %	mAP / %	FLOPs / %
1				84.1	73.9	80.8	8.4
2	√			84.7	78.8	84.1	7.8
3		√		82.4	74.2	82.8	8.2
4			√	85.2	72.4	86.5	8.3
5	√	√		86.0	78.4	85.2	7.6
6	√		√	85.8	80.2	87.4	8.0
7		√	√	84.6	76.4	83.4	8.2
8	√	√	√	<b>86.5</b>	<b>80.7</b>	<b>90.0</b>	<b>7.6</b>

## 2.6 检测结果可视化比较

为了更清晰地比较 LC-YOLO 和 YOLOv10n 在液晶显示屏缺陷检测中的性能,本节通过可视化展示了实验结果,包括 PR 曲线和部分推理结果的对比。

PR 曲线通过精度和召回率的关系绘制,能够直观反映模型的检测性能。YOLOv10n 和 LC-YOLO 的 PR 曲线如图 9 所示,曲线下方区域代表检测精度。可以看出优化以后的模型对于整体检测精度有很大的提升。而对于液晶屏表面上常见的划痕、凹印以及崩边 3 类缺陷的检测也有着较高的精度,相比于传统模型,精度分别提高了 15.3%、10.2% 和 2.2%。特别是划痕和凹印缺陷的提升效果较为显著,原因在于划痕与凹印这两类缺陷多数出现在液晶屏的中部而非边缘,背景的干扰较大。引入 DySample 模块后,采样点更多集中于目标区域,有效减少了背景影响,从而提升了算法的抗干扰能力。

此外,将优化后的算法与基础的 YOLOv10n 算法分别对数据集进行了测试,并随机选取了多幅具有代表性的液晶显示屏缺陷图像进行检测,结果如图 10 所示。图 10 中,缺陷位置以及类型通过不同颜色的图形标示,图形的右上角则显示每种缺陷的检测概率。结果表明,LC-YOLO 算法能够成功预测 3 种类型的缺陷,而 YOLOv10n 算法在某些情况下存在漏检问题。此外,LC-YOLO 算法对所有缺陷类型的检测均展现了较高的置信度,证明其在检测精度和定位能力上具有优势。在液晶显示屏缺陷的不同场景下,如光照或视角变化等,LC-YOLO 算法由于具有更高的置信度,能够更有效地检测目标并表现出更强的鲁棒性。

## 2.7 对比实验与泛化性分析

为了进一步验证本文提出算法改进的合理性和有效性,在实验条件(数据集、软硬件设备及参数配置)保持一致的情况下,YOLOv5s 等主流的目标检测算法对液晶屏缺陷数据集中各类缺陷的具体检测结果如表 6 所示。各种类型的缺陷用精度、召回率、计算量以及 mAP 指标进行评估,最高的指标用粗体表示。LC-YOLO 对液晶屏缺陷的检测效果最好,mAP 值在几种算法中最高,达到了

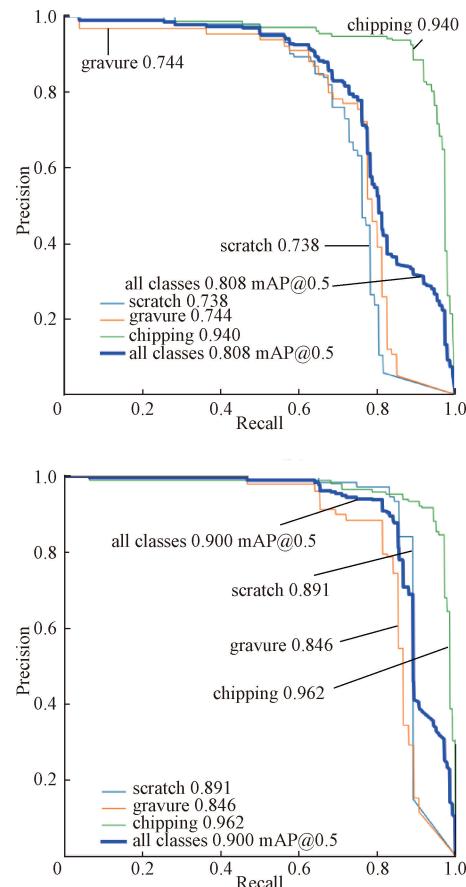


图 9 优化前后的 P-R 结果对比

Fig. 9 Comparison of P-R curves before and after improvement

90%,且计算量大幅降低。尽管 LC-YOLO 的参数量较 YOLOv8 有所增加,但计算复杂度降低了 5%,能够更好的满足工业实时检测的需求。通过以上分析,与其他目标检测算法相比,本文提出的 LC-YOLO 模型在液晶显示屏缺陷检测任务中具有一定的竞争力。

为了验证 LC-YOLO 模型的泛化能力,选择了来自 AI Studio 的手机屏幕缺陷公开数据集进行对比实验,该数据集包含了划痕、斑点、油污 3 种缺陷,并由工业相机采集,



图 10 检测结果对比图

Fig. 10 Comparison of test results

表 6 不同算法性能对比

Table 6 Performance comparison of different algorithms

算法	$mAP/\%$	Params/ $10^6$	FLOPs/ $10^9$	FPS
YOLOv5s	85.2	7.1	16.5	75.1
YOLOv7-tiny	82.4	6.2	13.0	85.2
YOLOv8n	86.7	<b>3.0</b>	8.1	73.5
RT-DETR	84.6	32.8	10.6	95.5
LC-YOLO	<b>90.0</b>	3.2	<b>7.6</b>	<b>70.4</b>

模拟工业环境制造。该数据集由 1 200 张图像构成,每种缺陷样本各有 400 张。实验参数设置与之前一样。数据集按照 8 : 1 : 1 的比例分为训练、验证和测试集。

表 7 给出了 LC-YOLO 模型与其他主流检测模型在公开数据集上的实验对比结果。与选用的基础模型 YOLOv10 相比,LC-YOLO 的精确率  $P$  提高了 3.6%,召回率  $R$  提高了 4.1%,同时  $mAP$  值也增长了 6.8%,并且相较于 YOLOv8 模型也有着明细的提升。实验验证,LC-

YOLO 算法具有良好的泛用性。

表 7 泛化实验对比

Table 7 Comparison of generalized experiments %

模型	$P$	$R$	$mAP$
YOLOv8	78.7	78.9	83.1
YOLOv10	80.6	78.5	84.4
LC-YOLO	<b>84.2</b>	<b>82.6</b>	<b>91.2</b>

### 3 实验系统验证

为了更好的适用于工业环境下的检测,本文开发了一种用于液晶显示屏缺陷实时检测的系统软件,此次测试旨在验证该系统能否有效、准确的检测液晶显示屏上的各类缺陷。如图 11 所示为液晶显示屏检测系统的主界面,选取自制的数据集用于系统检测,系统检测结果与本文标定的缺陷种类、数量一致,没有出现漏检、误检的情况,有效验证了系统良好的性能。



图 11 液晶显示屏检测系统

Fig. 11 LCD screen detection system

## 4 结 论

针对液晶显示屏表面缺陷特征微弱、对比度低、目标尺寸小且与背景高度相似的问题,提出了一种改进 YOLOv10 算法从而实现液晶屏表面缺陷的精确实时检测。提出了 ODConv 动态卷积模块,替代传统颈部网络的卷积模块,有效解决了传统卷积在特征提取方面的不足,减少了细节特征丢失的问题,在保持检测精度的同时提高模型的运算速度。优化模型上采样模块,采用 DySample 轻量动态上采样模块,使采样点聚焦于目标区域,减少背景区域的干扰,从而显著提升了算法的抗干扰能力。引入 EMAtteention 注意力机制至模型的小目标检测层。该机制通过重塑部分通道批次维度,并将通道划分为多个子特征组,有效提升了模型捕获小目标特征细节能力。

实验结果表明改进后的 LC-YOLO 模型的有效性,相比基础模型 YOLOv10n,在精确率、召回率和  $mAP@0.5$  方面分别提升了 2.4%、6.8% 和 9.2%,同时计算复杂度 ( $FLOPs$ ) 降低了 8%。与主流目标检测算法的对比结果表明,LC-YOLO 在检测精度和推理速度之间取得了良好的平衡,在液晶显示屏缺陷检测任务中展现出优异的性能。但是改进后的模型参数量相比 YOLOv8n 略有增加,后续将对模型的轻量化做进一步研究,并尝试部署到实际产线进行验证。

## 参考文献

- [1] RAHIMI S, ASGHARI M. Design and evaluation of two proposed hybrid FCC-BCC lattice structures for enhanced mechanical performance[J]. Heliyon, 2025, 11(1):e40911.
- [2] LIU J, HUANG X, PENG Z, et al. Liquid crystal display with high transmittance and excellent image quality[J]. Optik, 2025, 320:172105.
- [3] 张峰. 基于改进 YOLOv8 的图像液晶显示屏像素缺陷检测算法[J]. 计算机科学, 2024, 51(S2):245-251.
- [4] ZHANG F. Pixel defect detection in LCD screens using an improved YOLOv8 algorithm [J]. Journal of Computer Science, 2024, 51(S2): 245-251.
- [5] YUJIE S, ARAVIND K, ZEHAN Q, et al. Reducing lateral stair-stepping defects in liquid crystal display-based vat photopolymerization by defocusing the image pattern[J]. Additive Manufacturing, 2022, 52:102653.
- [6] 刘熹,陈晨,双丰. 基于改进 YOLOv7-tiny 的多种类绝缘子检测算法 [J]. 仪器仪表学报, 2024, 45 (9): 101-110.
- [7] LIU X, CHEN CH, SHUANG F. Multi-class insulator detection using improved YOLOv7-tiny algorithm[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 101-110.

- [6] TAO X, ZHANG D, HOU W, et al. Industrial weak scratches inspection based on multifeature fusion network[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-14.
- [7] 张航,周毅,邱宇峰.融合 HGNetV2 和注意力机制的钢材表面缺陷检测方法[J].电子测量与仪器学报,2025,39(1):36-49.  
ZHANG H,ZHOU Y, QIU Y F. Steel surface defect detection by integrating HGNetV2 with attention mechanism [J]. Journal of Electronic Measurement and Instrumentation, 2025,39(1):36-49.
- [8] SUN P, HUA CH CH, DING W L, et al. Ceramic tableware surface defect detection based on deep learning[J]. Engineering Applications of Artificial Intelligence, 2025, 141:109723.
- [9] 吴永泽,俞建峰,化春键,等.基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术研究[J].电子测量与仪器学报,2024,38(12):62-71.  
WU Y Z, YU J F, HUA CH J. Multidimensional defect detection in cylindrical battery shells using enhanced YOLOv8n[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 62-71.
- [10] WAN Y, LI J F. LGP-YOLO: An efficient convolutional neural network for surface defect detection of light guide plate [J]. Complex & Intelligent Systems, 2024,10(2):2083-2105.
- [11] 崔晶楠,黄春艳,李艳玲.融合动态卷积的 YOLOv5s 钢材表面缺陷检测[J].制造业自动化,2024,46(11):126-132.  
CUI J N, HUANG CH Y, LI Y L, Steel surface defect detection using YOLOv5s with dynamic convolution[J]. Manufacturing Automation, 2024, 46(11): 126-132.
- [12] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. ArXiv preprint arXiv:2405.14458, 2024.
- [13] CHEN Y, YUAN X, WU R, et al. YOLO-ms: Rethinking multi-scale representation learning for real-time object detection [J]. ArXiv preprint arXiv: 2308.05480, 2023.
- [14] QIU J. Multimodal image local registration by attention gauge fields with robust adaptive probability distributions[J]. Authorea Preprints, 2023,DOI:10.36227/techrxiv.22266820.
- [15] MA J, ZHANG Z, XIAO W, et al. Flame and smoke detection algorithm based on ODConvBS-YOLOv5s[J]. IEEE Access, 2023, 11: 34005-34014.
- [16] 王慧云,赵俊生,王禹,等.面向无人边防的复杂环境遮挡小目标检测算法[J].电子测量技术,2024,47(21):168-177.  
WANG H Y,ZHAO J SH,WANG Y, et al. Occluded small object detection in complex environments for autonomous border surveillance [J]. Electronic Measurement Technology, 2024, 47(21): 168-177.
- [17] XIONG R B, YANG Y C, HE D, et al. On layer normali in the transformer architecture [C]. 37th International Conference on Machine Learning. Virtual:PMLR,2020:10524-10533.
- [18] SONG Q, LI S, BAI Q, et al. Object detection method for grasping robot based on improved YOLOv5[J]. Micromachines, 2021, 12(11): 1273.
- [19] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

### 作者简介

廖映华(通信作者),博士,教授,主要研究方向为机电耦合系统动力学及可靠性。

E-mail:liaoyinghua118@163.com

杨瑞峰,硕士研究生,主要研究方向为机器视觉。

E-mail:18881909420@163.com