

文章编号:1007-2780(2026)02-0208-14

FFD-YOLO: 面向小目标与复杂背景 的液晶屏缺陷检测

山宏刚¹, 倪奕麟¹, 蔡建刚¹, 朱 军¹, 廖泽威^{2*}, 戚顺楠²

(1. 上海海关机电产品检测技术中心, 上海 201210;

2. 上海电机学院 机械学院, 上海 201306)

摘要: 液晶屏表面缺陷会影响外观并降低可靠性, 且存在尺度跨度大、背景复杂、小目标难检测等问题。本文基于轻量的 YOLOv8n 提出了一种液晶屏缺陷检测算法 FFD-YOLO。该算法引入 FasterNet 主干网络以提升特征提取能力; 设计特征金字塔共享卷积模块 FPSC, 通过多膨胀率卷积与共享卷积机制增强多尺度特征建模能力; 提出多尺度自适应卷积模块 MACM, 利用动态卷积权重与多尺度卷积核融合强化小目标特征表达与复杂背景下的稳定性。实验结果表明, 在自建工业级 LCD-NET 数据集上, FFD-YOLO 的精度(Precision)、召回率(Recall)和 mAP50 分别较基线模型提升 5.0%、4.7% 和 3.2%, 其中污渍类小目标检测精度提升达 6.4%。证明 FFD-YOLO 在保持轻量化的同时可显著提升液晶屏缺陷检测性能, 为工业视觉检测系统提供了一种高效、可靠的解决方案。

关键词: 液晶屏; 缺陷检测; 特征金字塔共享卷积; 多尺度自适应卷积; YOLOv8

中图分类号: TN873.93; TP391.4 **文献标识码:** A **doi:**10.37188/CJLCD.2025-0220 **CSTR:**32172.14.CJLCD.2025-0220

FFD-YOLO: LCD screen defect detection for small targets and complex backgrounds

SHAN Honggang¹, NI Yilin¹, CAI Jiangang¹, ZHU Jun¹, LIAO Zewei^{2*}, QI Shunnan²

(1. *Technical Center for Mechanical and Electrical Product Inspection and Testing
of Shanghai Customs District, Shanghai 201210, China;*

2. *School of Mechanical Engineering, Shanghai Dianji University, Shanghai 201306, China)*

Abstract: Surface defects on liquid crystal displays(LCDs) impair appearance and reliability, presenting challenges such as wide-scale variations, complex backgrounds, and difficulty in detecting small targets. This paper proposes FFD-YOLO, an LCD defect detection algorithm based on the lightweight YOLOv8n framework. The algorithm uses the FasterNet backbone to enhance feature extraction. It designs the Feature Pyramid Shared Convolution(FPSC) module, which uses multi-expansion-rate convolutions and shared convolutional mechanisms to enhance multi-scale feature modeling. Additionally, it proposes the Multi-Scale Adaptive Convolution Module(MACM), which employs dynamic convolution weights and

收稿日期:2025-10-31;修订日期:2025-12-21.

基金项目:海关机电类实验室智慧检验检测场景的研究及实践项目(No.2024HK078)

Supported by Project of Research and Practice of Intelligent Inspection and Testing Scenarios in Customs
Electromechanical Laboratories (No.2024HK078)

*通信联系人, E-mail:laurenceyy@163.com

multi-scale convolution kernels to enhance the representation of small objects and stability in complex backgrounds. Experimental results demonstrate that on the self-built industrial-grade LCD-NET dataset, FFD-YOLO achieves 5.0%, 4.7%, and 3.2% improvements in Precision, Recall, and mAP50, respectively, compared to baseline models, with a 6.4% boost in accuracy for detecting small stain-type objects. These results demonstrate that FFD-YOLO significantly enhances LCD defect detection performance while maintaining lightweight efficiency, offering an effective and reliable solution for industrial vision inspection systems.

Key words: liquid crystal display; defect detection; feature pyramid shared convolutions; multi-scale adaptive convolutions; YOLOv8

1 引言

随着电子产品的快速更新换代,二次回收利用规模不断扩大,产品的质量检测愈发重要。其中,液晶屏表面缺陷成为二手电子产品进出口质检的首要难题,不仅直接影响视觉效果,还会显著降低用户的使用体验^[1]。目前的检测方式主要包括人工检测与机器视觉检测。人工方法在工业质检中应用广泛,但效率低且易受疲劳影响,难以满足现代生产对高效稳定检测的需求^[2]。机器视觉检测具有实时性强和精度高等优势,还能以图像或数据直观呈现缺陷信息,因此逐渐成为提升检测效率与精度的重要途径^[3]。

在表面缺陷自动检测领域,基于深度学习的目标检测算法已成为主流技术路线,大体可分为两阶段检测与单阶段检测两大类^[4]。以 Faster R-CNN 为代表的两阶段检测方法,通常先生成候选区域再进行分类与边界框回归,具有较高的检测精度,已广泛应用于多类工业表面缺陷检测任务。Chen 等人^[5]提出的融合模型通过改进特征提取网络和锚框设计,提高了复杂纹理背景下的检测效果。然而,两阶段方法普遍存在网络结构复杂、推理速度较慢的问题,在对实时性要求较高的生产线上部署仍存在一定局限。

单阶段检测方法以 SSD^[6]和 YOLO 系列算法^[7]为代表,将目标检测视为实时的回归问题,在保证一定检测精度的前提下显著提升了推理速度,更适用于在线检测等实时性场景。围绕单阶段框架,已有大量工作从多尺度特征融合与轻量化设计等方面对模型进行改进。刘彦磊等^[8]提出了一种轻量型 YOLOv5s 目标检测方法,在降低模型参数数量和计算复杂度的同时保持了较好的检

测性能。蔡引娣等^[9]将改进 YOLOv8 模型应用于微小气孔缺陷检测,通过强化微小缺陷特征的表达能力,实现了微小缺陷的高精度识别与尺寸测量。杨彦萍等^[10]面向印刷电路板表面小缺陷,在 YOLO11 框架下引入多尺度卷积注意力机制和高效特征金字塔网络,实现了在复杂线路背景下的小目标缺陷高效检测。景会成等^[11]提出基于铝型材表面缺陷检测方法,通过加强多尺度特征融合缓解了小目标漏检与误检问题,但同时增加了网络复杂度。Liu 等人^[12]设计的 MSDC 模型旨在融合多尺度缺陷特征,以避免因模型深度增加而丢失微小缺陷特征。Wan 等人^[13]提出了一种针对导光板(LGP)背景复杂且对比度低的微弱缺陷的 LGP-YOLO 算法,在特征提取与多尺度检测结构上进行优化,有效减少了无关目标的干扰,提升了网络性能。朱广等^[14]针对表面缺陷尺度跨度大、背景复杂的问题,提出了一种改进 YOLOv8 的多尺度缺陷检测方法,通过增强多尺度特征建模能力,提升了复杂工业场景下的检测精度与鲁棒性。Zhao 等人^[15]提出的 RDD-YOLO 模型采用 Res2Net 模块及改进特征金字塔结构,进一步提升了多尺度特征表示能力和检测精度。这些算法通过多尺度特征融合分析,突破了小目标缺陷检测的瓶颈,但也使网络结构变得更加复杂,增加了模型的推理时间。

针对液晶屏表面缺陷,近年来也有学者在 YOLO 框架上开展了更具针对性的研究。Yang 等人^[16]构建了面向智能手机屏幕的缺陷检测模型,缓解了人工检测结果不一致的问题。林峰等^[17]在 YOLOv5 框架下提出液晶屏微弱特征缺陷检测算法,通过改进骨干网络与特征融合结构,加强了对微弱 Mura 缺陷的表征能力。陈顺龙等^[18]

基于 YOLOv8n 构建液晶屏 Mura 缺陷检测模型,从网络结构和损失函数两方面优化了小尺度、低对比度缺陷的检测性能。上述工作表明,围绕 YOLO 系列对特征提取、多尺度建模与注意力机制进行有针对性的改进,是提升屏幕及相关电子部件表面微小缺陷检测性能的有效途径。但同时可以看到,部分方法为提升精度引入了较为复杂的网络结构与模块设计,导致模型参数量和计算量明显增加,在复杂背景鲁棒性与轻量化实时检测之间的平衡仍有待进一步优化。

现有研究在复杂背景干扰和小目标缺陷检测方面虽然取得了一些进展,但在兼顾检测精度、模型轻量化和工业级实时性方面仍存在不足。对于极端复杂背景、低对比度图像以及纹理模糊的小缺陷,现有方法在实际产线中仍易出现漏检与误检,模型的鲁棒性和泛化能力有待进一步提升。

为便于分析模型在不同场景下的表现,本文对小目标和复杂背景进行了明确界定。结合工业液晶屏缺陷的实际特征,我们将归一化面积小于 0.01 或宽、高小于 0.05 的缺陷记为小目标,该类目标多为细小划痕与微弱污渍,特征不明显且易被背景淹没。而对于同时存在低对比度、背光纹理干扰、反射与噪声等因素,导致目标边界模糊、纹理弱化的场景,则归类为复杂背景,用于分析模型在不同难度场景下的鲁棒性。

本文聚焦于实际工业环境下的液晶屏缺陷检测,旨在解决精度、对复杂环境的自适应能力和泛化能力不足的问题。液晶屏表面缺陷往往尺度跨度大,以特征较弱的小目标居多,检测任务具有较大挑战。基于此,本文提出了一种改进的 YOLOv8n 模型 FFD-YOLO,在保持较高实时性的前提下提升小目标缺陷检测性能,并增强复杂背景下的检测稳定性。主要研究内容如下:

(1) 针对缺乏公开液晶屏缺陷数据集的问题,构建了工业级 LCD-NET 数据集,为实际工业场景提供可靠的数据支持,并提升模型在多场景下的泛化能力。

(2) 采用 FasterNet 作为主干网络,利用其高效的部分卷积机制,优化特征提取能力。

(3) 设计特征金字塔共享卷积模块 FPSC,首次将多膨胀率卷积与共享卷积核机制结合于特征金字塔结构中,有效提升多尺度特征建模能

力,增强模型对小目标和复杂缺陷的表征能力。

(4) 设计多尺度自适应卷积模块 MACM,创新性地融合动态卷积核权重机制与多尺度卷积,实现卷积运算的自适应选择。同时,引入缩放层 (LayerScale) 与随机深度 (DropPath) 策略,以增强网络在多尺度缺陷识别中的表现和鲁棒性。

2 YOLOv8 算法

YOLOv8^[19]是一种基于卷积神经网络 (CNN) 的目标检测算法,兼具检测速度快、精度高和部署灵活等优势,尤其适用于实时性要求较高的工业检测等场景。为全面评估不同 YOLO 模型在目标检测任务中的性能,本文基于同一数据集对 YOLOv5、YOLOv7、YOLOv8n、YOLOv10 和 YOLOv11 五种模型进行了对比实验,其 mAP 分别为 66.2%、67.2%、70.5%、70.0% 和 69.8%。其中,YOLOv8n 性能优于其他模型,因而被选为本文优化的基础模型。

YOLOv8 在主干网络中摒弃 YOLOv5 和 YOLOv7 沿用的 CSP 结构,采用更加轻量且特征表达能力更强的 CBS 与 C2f 模块,提升了梯度传递效率与深层语义特征提取能力。而 YOLOv10 与 YOLOv11 虽然采用更复杂的主干结构,但在轻量化模型中难以充分发挥深层特征优势,导致精度优势不明显。

YOLOv8 在颈部网络中采用重新设计的 FPN-PAN 双路径结构,减少了 YOLOv5 和 YOLOv7 中存在的多级跨层传递瓶颈。相比之下,YOLOv10 与 YOLOv11 较多关注结构化重参数化与更深层的特征通路,虽然理论表达能力增强,但特征融合路径的复杂化往往会导致推理延迟增大,难以在工业检测中保持实时性。

YOLOv8 采用无锚框 (Anchor-free) 解耦检测头,较 YOLOv5 和 YOLOv7 的基于锚框 (Anchor-based) 机制具有更高的回归一致性和更低的超参数依赖,同时相比 YOLOv10 和 YOLOv11 中引入的复杂解耦头,YOLOv8 在保持较小模型规模的前提下借助更高效的损失设计实现了精度提升。

YOLOv8 在特征提取、多尺度融合与检测头设计上在轻量化与精度之间取得了更优平衡,因而在同类模型中表现出更高的检测精度。YOLOv8 完整网络结构如图 1 所示。




图1 YOLOv8n网络结构图

Fig. 1 YOLOv8n network structure diagram

3 FFD-YOLO检测算法

YOLOv8 模型在结构上引入了大量的 C2f 模块,显著增强了网络的特征表达能力。然而,在复杂背景环境下及小目标检测任务中,该模型的稳定性仍存在一定不足。其主要原因在于模型频繁采用卷积操作进行特征提取,容易造成小目标特征信息的丢失。同时,该模型对

复杂背景中的目标识别适应能力较差。为此,本文在YOLOv8基础上进行了优化,提出了一种改进模型——FFD-YOLO。该模型引入FasterNet作为主干网络,以提升特征提取的稳定性;同时设计了FPSC模块与MACM模块,分别用于增强模型的多尺度特征建模能力与提升小目标检测的鲁棒性。FFD-YOLO整体结构如图2所示。




图2 FFD-YOLO整体结构图

Fig. 2 Overall structure diagram of FFD-YOLO

3.1 FasterNet 主干网络

为提升模型在液晶屏多尺度缺陷检测中的特征提取能力,本文在 YOLOv8 框架中引入了 FasterNet 主干网络。与常规方法不同,FasterNet 通过引入部分卷积(Partial Convolution, PConv)^[20],仅对部分通道进行卷积运算,从而充分利用特征映射中的冗余信息,提升特征通道间的利用率与感受野覆盖能力,在此基础上重新设计了神经网络结构。该设计既能有效保留关键结构特征,又能强化网络对细粒度缺陷的感知能力,实现了在计算量较低条件下的高效特征提取。

FasterNet 的整体架构如图 3 所示,采用 4 层分层结构,每层由多个 FasterNet 块组成。前面配有嵌入层(4×4 卷积,步长 4)或合并层(2×2 卷积,步长 2),用于空间下采样与通道扩展。在每个 FasterNet 块中,核心是 PConv 层,随后接两个 PWConv 层进行特征增强。图 3(b)展示了 PConv

的工作原理。与常规卷积不同,PConv 只有部分通道参与卷积运算,其他通道保持不变。此时,PConv 内存访问次数为:

$$K = h \times w \times 2c_p + k^2 \times c_p^2 \approx h \times w \times 2c_p. \quad (1)$$

其中: h 和 w 分别代表输入特征图的高度和宽度, k 代表卷积核的尺寸, c_p 代表参与部分卷积运算的通道数。在 FasterNet 的 PConv 设计中,仅有部分通道(c_p)参与运算,而剩余通道保持不变,以此降低计算量。假设参与卷积的通道比例为 r ,那么当 $r = \frac{c_p}{c} = \frac{1}{4}$ 时,PConv 的内存访问次数约为常规卷积的 $1/4$ 。同时,部分卷积的浮点运算次数(FLOPs)为:

$$\text{FLOPs} = h \times w \times k^2 \times c_p^2. \quad (2)$$

当 $r=1/4$ 时,部分卷积的浮点运算次数仅为传统卷积的 $1/16$ 。这种方式显著降低了计算量,同时仍能聚焦关键特征。简而言之,PConv 在减轻计算负担的同时保留了有效的特征提取能力,使网络更高效也更准确。




图 3 FasterNet 模块结构

Fig. 3 FasterNet module structure

3.2 特征金字塔共享卷积模块

在原始 YOLOv8 模型中,SPPF 模块用于提升特征提取效率。它通过轻量级池化操作完成多尺度特征融合,能有效减少计算量与参数规模,也适合在资源有限的设备上实现推理。但由于池化本身的限制,该模块在复杂工业场景中的表现不够理想,尤其在处理微小缺陷时,检测精度会明显下降。SPPF 的网络结构见图 4,图中 k 、 s 、 p 分别代表卷积核大小(Kernel size)、步长(Stride)和边缘填充(Padding)。

为解决这一问题,我们设计了新的特征金字塔共享卷积模块 FPSC 替代原有的 SPPF。与 SPPF 相比,FPSC 采用参数共享卷积(PSCConv)进行特征提取,表达能力更强,能够捕捉更多细节和复杂特征。FPSC 的网络结构如图 5 所示。

其核心思想是利用不同膨胀率的卷积算子来获取多种感受野,从而提升模型在多尺度目标上的感知能力。为了避免多分支结构带来的冗余计算,我们引入共享卷积机制,使模型在保持表达




图4 SPPF网络结构

Fig. 4 Architecture of SPPF network

能力的同时保持轻量化。在结构设计上,其一,引入 1×1 卷积对通道进行压缩和重整,在降低参数规模的同时保留关键信息;其二,基于共享的 3×3 卷积核,通过多组膨胀卷积来捕获跨尺度特征。小膨胀率更适合描述细粒度的局部模式,大膨胀率则强化对全局语义的建模。PSConv的形式化表达如公式(3)所示:

$$y_{n+1} = W_1 \cdot y_n^d + b_1, \quad (3)$$

其中: y_n 表示输出特征图; W_1 是共享卷积核权重, b_1 为共享偏置项; d 代表dilation; n 为1、2和3,分别对应不同膨胀率1、3和5。膨胀率为1时,膨胀卷

积与标准 3×3 卷积等价,当膨胀率为3或5时,卷积核会在更大间隔下作用,扩大感受野。其计算过程可描述为:

$$\mathcal{F}_d(u, v) = \sum_{i=-k}^k \sum_{j=-k}^k W(i, j) \cdot I(u + i \cdot d, v + i \cdot d), \quad (4)$$

其中: u, v 为特征图坐标, i, j 为卷积核索引, k 为卷积核大小的 $1/2$, I 是输入特征的映射。通过这种方式,PSConv相较于独立卷积层减少了冗余参数,提高了效率。最后,我们通过Concat融合不同膨胀率的特征映射,再用 1×1 卷积调整通道维度,形成包含多尺度信息的输出。




图5 FPSC网络结构

Fig. 5 Architecture of FPSC network

3.3 多尺度自适应卷积模块

传统卷积神经网络(CNN)大多依赖固定大小的卷积核。在处理小目标、多尺度目标以及复杂工业场景时,这种方式往往难以兼顾细节建模与全局感知。为了解决这一问题,我们提出了多尺度自适应卷积模块(MACM),其结构如图6所示。MACM的核心是引入动态卷积核权重(Dynamic Kernel Weight, DKW)机制,它能够根据输入特征自动分配不同卷积核的权重,从而更好地捕获不同尺度的小目标特征。同时,我们在模块中加入了Layer Scale策略以提升训练的收敛性与稳定性,并且结合DropPath技术来增强正则化效果,从而有效缓解过拟合。

在特征提取方面,MACM内置动态多尺度

混合器(Dynamic Inception Mixer),通过不同卷积核尺寸与通道的动态调整实现多尺度特征融合,使网络能够同时关注局部细节与全局语义。该结构结合了CGLU激活函数,其形式化定义为:

$$\text{CGLU}(x) = x \odot \sigma(W_g x + b_g), \quad (5)$$

其中: $\odot$ 表示元素相乘, σ 表示Sigmoid激活函数, W_g 和 b_g 分别是权重矩阵和偏置向量。CG-LU将输入通道一分为二,在不同卷积路径中进行动态处理,再拼接与压缩恢复通道数,从而增强了网络的非线性表达能力与特征判别性。

Dynamic Inception DWConv2d的思想是通过组合不同大小的卷积核来捕获多尺度信息,同时根据输入特征动态调整卷积核权重,使卷积运算更灵活、更有针对性,其结构如图7所示。具体而言:




图 6 MACM 网络结构

Fig. 6 MACM network structure




图 7 Dynamic Inception DWConv2d 结构

Fig. 7 Dynamic Inception DWConv2d structure

(1)多尺度结构。Dynamic Inception DW-Conv2d 采用 Inception 式的多分支设计,在同一特征子空间中并行布置 3 种空间形状不同的 depthwise 卷积核:小方核(3×3),用于在较小感受野

内提取纹理、边缘等局部细节信息;横向长条核($1\times k$),在水平方向上具有更长的感受野,可以连续地扫过整行像素,从而更敏感于横向延展的条状缺陷或背景结构;纵向长条核($k\times1$),在垂直方

向上具有更长的感受野,重点捕获竖直方向上的长程依赖。3种卷积核在同一位置对同一特征做并行处理,相当于同时从局部放大镜、横向和纵向长距离扫描3个视角观察输入特征,使网络既能保留局部纹理,又能感知背景或缺陷中沿特定方向延展的长距离结构。

(2)自适应选择机制。仅有多尺度卷积还不足以保证对所有样本都同样有效,因此MACM在此基础上引入了动态权重机制。对每一个输入特征图,模块首先通过全局平均池化对每个通道内所有空间位置的激活进行求均值,得到该通道在全局范围内的平均响应强度,从而得到一个紧凑的全局语义描述。在此基础上,利用 1×1 卷积将这一描述映射为多个卷积分支对应的权重系数,并通过Softmax归一化,使得同一位置上不同分支的权重在数值上可比较且和为1。基于此,每个卷积分支的输出都会乘上一个由当前样本和当前通道自动计算得到的权重,再在分支之间做加权求和,相当于使网络在“小方核、横向长核、纵向长核,以及不同基础kernel size”等多种感受野组合之间进行一次选择。直观上,如果某一通道更依赖局部细节,小方核分支的权重会被自动放大;而当特征中存在明显的条状噪声或沿某一方向延展的缺陷时,相应方向的长条核分支权重会占据主导。

4 实验与结果分析

4.1 数据集

为弥补液晶屏缺陷检测领域缺乏工业级

数据集的问题,我们在上海海关机电产品技术检测中心实验室采集并构建了LCD-NET数据集。样品由上海海关总署从进口液晶屏中抽样提供。共采集约1500张含缺陷的液晶屏图像,涵盖3类典型缺陷:划痕(Scratch)、污渍(Stain)及碎屏(Broken Screen)。筛选后最终保留900张有效图像,并通过数据增强扩展至1900张。数据集按照8:1:1的比例划分,用于训练、验证与测试。缺陷样本如图8所示,不同图像中缺陷的数量与分布存在差异。为了更直观地展示数据特征,我们统计了缺陷的数量与尺寸。缺陷数量分布见图9(a),尺寸分布见图9(b)。经归一化可知,图9(b)左下角颜色较深,大多数缺陷在宽度和高




图8 LCD-NET缺陷样本示意图。(a) 划痕;(b) 污渍;(c) 碎屏;(d) 划痕与污渍;(e) 划痕与碎屏;(f) 含干扰背景的划痕与碎屏。

Fig. 8 Diagram of LCD-NET defect sample. (a) Scratch; (b) Stain; (c) Broken screen; (d) Scratch and stain; (e) Scratch and broken screen; (f) Scratch and broken screen with interference.




图9 液晶屏缺陷种类(a)和归一化尺寸统计图(b)

Fig. 9 Statistics on types (a) and normalized sizes (b) of LCD screen defects

度上都小于 0.05(相对于 640×640 的图像尺寸, 对应约 32 像素), 表明存在大量小目标但也存在少量较大目标。

此外, LCD-NET 的标注对象限定为液晶屏表面肉眼可见的宏观缺陷。数据标注由具有实际经验的检测人员按照海关现行外观检验标准进行筛选与标注, 仅保留在采集图像上能够稳定辨认的缺陷目标, 未纳入显微级或难以判定的极微小瑕疵。因此, 本文所讨论的“缺陷识别精度”主要对应于图像层面可见缺陷的检测能力, 与现有人工质检的判定精度保持一致。

为了全面评估模型的泛化能力, 我们在缺乏公开工业级液晶屏缺陷数据集的情况下, 将所提出的检测模型迁移至东北大学的通用表面缺陷数据集 NEU-DET 进行验证。尽管液晶屏缺陷在弱纹理、低对比度等方面具有一定特殊性, 但从表面缺陷检测的通用视觉机理来看, 其本质均可归结为局部结构或纹理模式的异常。NEU-DET 数据集集中的 crazing、scratches、patches 等典型缺陷, 同样表现为局部纹理破坏、方向性细纹及亮度不连续等特征, 在缺陷尺度、形态及局部纹理分布等方面与液晶屏小目标缺陷具有较高相似性。因此, 将模型迁移至 NEU-DET 进行测试, 有助于检验本文提出结构改进在多尺度建模与弱纹理表征方面的有效性, 评价模型在不同材质表面与不同缺陷类型上的跨场景泛化能力。这一设计不仅缓解了领域数据不足的问题, 也从跨任务角度考察了模型在不同缺陷检测场景下的适应性与鲁棒性。

4.2 实验环境及参数配置

在实验环境方面, 我们在 Windows11 系统下完成了模型训练与测试。编程语言使用 Python3.9.20, 并且基于 PyTorch2.0.0 框架实现。硬件平台为 Intel(R)Core(TM)i7-14700KF 处理器与 NVIDIA GeForce RTX4060Ti。在训练参数设置上, 图像输入分辨率为 640×640 , 批大小 (Batchsize) 设置为 32, 训练轮次为 300。优化器采用 SGD, 初始学习率设定为 0.01。

为验证分辨率设置的合理性, 本文对 320×320 、 640×640 和 1280×1280 三种输入尺度进行了对比实验。结果如表 1 所示, 640×640 的检测精度最高, 同时在保证显存占用的前提下能够实现

表 1 不同分辨率配置下模型的性能表现

Tab.1 Performance of the model under different input resolution configurations

分辨率	mAP50/%	显存占用/G
320	61.7	1.28
640	70.5	4.7
1280	65.8	17.5

最佳的整体性能。具体而言, 320×320 分辨率因特征表达不足导致小目标检测精度下降; 1280×1280 训练不稳定、显存占用大, 整体 mAP 反而低于 640×640 。综合检测精度与显存占用, 640×640 是最优选择, 因此本文采用该分辨率作为模型训练的默认输入规模。

4.3 算法评估标准

本文采用多种评价指标对模型性能进行综合分析, 包括精度 (Precision, P)、召回率 (Recall, R)、平均精度 (AP)、均值平均精度 (mAP) 以及参数量 (Parameters, Params)。其计算公式如下:

$$P = \frac{TP}{TP + FP}, \quad (6)$$

$$R = \frac{TP}{TP + FN}, \quad (7)$$

$$AP = \int_0^1 P(R) dR, \quad (8)$$

$$mAP = \frac{1}{N} \sum_{i=0}^n AP_i, \quad (9)$$

其中: TP 即真实为正且被模型预测为正的样本数, FP 即真实为负但被模型预测为正的样本数, FN 即真实为正但被模型预测为负的样本数。N 表示检测类别数 (本实验中类别数为 3)。

4.4 消融实验

为了全面评估本文提出的 FFD-YOLO 在复杂工业场景下的检测性能, 我们在自建 LCD-NET 数据集上进行消融实验 (见表 2 与表 3)。结果显示, 单独引入 FasterNet 后, 精度提升了 4.4%, 突出表现在碎屏 (Screen broken) 目标精度的提升, 表明主干网络特征提取对小目标敏感度不高, 但避免了后续大尺度目标精度不足; 加入 FPSC 模块后, 模型的精度和 mAP 提升了 7% 和 1.4%, 特别体现在划痕 (Scratch) 和碎屏的检测上, 这说明模块在多尺度特征建模方面对不同尺寸缺陷的感知能力; 引入 MACM 模块, 模型的精度和 mAP 分别达到了 75% 和 73.7%, 主要改善了小

表 2 自建数据集上的消融实验结果

Tab. 2 Ablation experiment results on the self-built dataset

Baseline	FasterNet	FPSC	MACM	Precision/%	mAP50%	FPS	FLOPs/G
✓				70	70.5	91	8.1
✓	✓			74.4(+4.4)	71.0(+0.5)	70.8	10.7
✓		✓		77.1(+7.1)	71.3(+0.8)	88.9	8.1
✓			✓	72.4(+2.4)	72.5(+1.5)	120	6.3
✓	✓	✓		77.0(+7.0)	71.9(+1.4)	67.5	10.7
✓		✓	✓	75.8(+5.8)	71.7(+1.2)	110	7.4
✓	✓		✓	80.0(+10)	72.6(+1.9)	100	8
✓	✓	✓	✓	75.0(+5.0)	73.7(+3.2)	95	8.3

注:“+”或“−”表示相较于未修改模型的提升或下降

表 3 自建数据集上的消融实验结果

Tab. 3 Ablation experiment results on the self-built dataset

Baseline	FasterNet	FPSC	MACM	AP (IoU=0.5)/%		
				Scratch	Stain	Screen broken
✓				54.6	63.7	92.4
✓	✓			54.4	63.7	94.8
✓		✓		54.2	65.3	94.9
✓			✓	54.2	67	96.2
✓	✓	✓		55.8	63.2	96.1
✓		✓	✓	55.4	67.3	92.4
✓	✓		✓	55.4	69	93.3
✓	✓	✓	✓	57.7	70.1	93.3

目标的检测能力,同时优化了计算量和推理效率,表明动态卷积机制在提升特征表达能力的同时,有效减少了计算开销并提升了推理速度。在此基础上,本文进一步从网络整体结构设计的角度对轻量化与精度之间的平衡进行系统性分析。

在液晶屏缺陷检测任务中,轻量化设计与检测精度之间存在不可避免的矛盾:过度裁剪卷积结构会导致小目标与弱纹理特征的表达能力下降,而过度增加网络深度与宽度又会显著降低推理速度。为解决这一问题,本文在设计FFD-YOLO时旨在“提升结构效率而非增加结构规模”的原则,采用Fastnet与PSConv技术,在不显著增加计算量的前提下增强了特征表达能力。同时,通过共享卷积和动态卷积权重机制,降低了冗余分支的参数开销,同时保持了精度的提升。最终,模型在保持95 FPS实时性的基础上,mAP50提升3.2%,有效缓解了“轻量化-精度”矛盾。

4.5 对比实验及可视化

为验证FFD-YOLO在液晶屏缺陷检测中的性能,我们将其与多种主流检测算法在LCD-NET数据集上进行了对比。对比对象包括二阶段检测器(FasterR-CNN、SSD)以及一阶段检测器(YOLOv5s、YOLOv7-tiny、YOLOv8n等),所有模型均在相同环境下训练与评估,结果见表4。

整体来看,FasterR-CNN与SSD在复杂背景和小目标检测上表现不足,mAP50仅为63.7%和62.1%,且计算开销过大,难以满足实时需求。单阶段模型中,YOLOv5s、YOLOv7-tiny、YOLOv8n和YOLOv9t等在速度与精度上更均衡,但对微小缺陷不够敏感。YOLOv8n的mAP50为70.5%,在划痕与污渍类小目标检测上仍有不足;Rt-DETR虽具全局建模能力,但召回率仅61.3%,mAP50为65.3%,计算开销大,不适合工业应用。

相比之下,FFD-YOLO在多尺度特征建模与小目标检测方面表现突出。整体精度、召回率与mAP50分别为75.0%、69.7%与73.7%,均优于YOLOv8n及其他模型。从类别来看,Scratch与Stain类缺陷的检测精度分别达到57.7%和70.1%,显著优于对比模型,说明FPSC与MACM有效提升了小目标特征提取与上下文建模能力。Screen broken类缺陷的检测保持在93.3%的高精度,验证了模型的鲁棒性。

此外,在可视化实验中,图10(a)和图10(b)展示了复杂背景下的检测效果。可以看到,FFD-YOLO在这些场景中依然保持了较高的置信度输出,并且没有出现明显的漏检或误检。图10(c)和图10(d)对应的是小目标缺陷以及模糊背景下

表 4 LCD-NET 数据集上不同算法的性能比较

Tab. 4 Performance comparison of different algorithms on LCD-NET dataset

Algorithm	Precision/%	Recall/%	AP (IoU=0.5)/%			mAP50%	Params/M	FLOPs/G
			Scratch	Stain	Screen broken			
Faster-RCNN	68.2	62.3	51.1	55.3	85.6	63.7	137.9	370.2
SSD	66.8	61.2	50.1	53.3	85.3	62.1	26.3	62.7
YOLOv5s	72.1	67	52.3	56.2	90.1	66.2	7	16
YOLOv7-tiny	67.3	66.3	52.3	60.2	89.1	67.2	6	13.2
YOLOv8n	70	65	54.6	63.7	92.4	70.5	3	8.1
YOLOv9t	70.6	61.4	48.4	61.8	92.5	67.6	2.6	10.7
YOLOv10n	74.1	63.5	52.7	59.1	92.7	70	2.7	8.2
YOLOv11	68.5	69.6	52.9	61.9	94.7	69.8	2.6	6.3
Rt-DETR-r18	63.4	61.3	48.6	59	87.7	65.3	20	58.6
FFD-YOLO	75	69.7	57.7	70.1	93.3	73.7	4	8.3

注:粗体数字表示最优值




图 10 液晶屏幕表面缺陷实际检测的可视化结果。(a) 碎屏;(b) 污渍与划痕;(c) 细微划痕;(d) 低对比度划痕。
Fig. 10 Visualization results of actual detection of surface defects on an LCD screen. (a) Broken screen; (b) Stain and scratch; (c) Tiny scratch; (d) Low contrast scratch.

的检测,FFD-YOLO的结果依旧稳定,边界框定位准确,分类也比较可靠。相比之下,其他对比算法容易出现漏检和误检问题,整体表现不够稳定。综合来看,FFD-YOLO在复杂工况下检测性能可靠、鲁棒性更强,更契合工业液晶屏缺陷检测需求,具备良好的应用前景。

4.6 迁移实验

为进一步验证所提出的FFD-YOLO模型在多尺度和复杂背景下的检测效果,选择了与液晶屏具有相似缺陷特征的NEU-NET数据集进行迁移实验。该数据集包含6种典型的热轧钢带表

面缺陷:裂纹(Crazing, cr)、夹杂(Inclusion, in)、斑块(Patches, pa)、麻点(Pitted Surface, ps)、压入氧化皮(Rolled in Scale, rs)和划痕(Scratches, sc)。在实验中保持了相同的模型设置,以此评估模型在非液晶屏场景下的泛化能力,结果见表5。整体来看,YOLOv5s、YOLOv7-t与YOLOv8在大目标缺陷(如in、ps)的检测中表现较好,但在小目标或细粒度缺陷(如cr、rs)上表现不足,mAP50分别只有71.2%、69.7%与75.5%。YOLOv10在部分类别上较优,但多尺度建模依旧不足,mAP50仅71.3%。

表5 不同模型在NEU-DET数据集上的检测指标对比

Tab. 5 Comparison of detection metrics across different models on the NEU-DET dataset

Algorithms	AP (IoU=0.5)/%						mAP50%
	cr	in	pa	ps	rs	sc	
YOLOv5s	37.6	83	93.3	77.3	56.6	79	71.2
YOLOv7-t	38.1	86.2	94	75.6	64.6	59.6	69.7
YOLOv8n	47.4	81.9	94.9	79.6	67.5	81.4	75.5
YOLOv9-t	42.3	84.1	94.1	80.8	71.2	77.5	75
YOLOv10n	47.4	82.3	92	79.5	56.9	69.9	71.3
FFD-YOLO	56.5	85.4	94.8	82.2	66	79.7	77.4

相比之下,我们提出的改进模型在多尺度和小目标检测上优势更明显。FFD-YOLO的mAP50为77.4%,均优于对比模型。在类别结果中,模型在cr缺陷的检测中达到56.5%,在rs缺陷的检测中达到82.2%,在典型小目标与复杂纹理缺陷检测方面明显优于其他方法。同时,在大目标检测中,in缺陷的检测精度为85.4%,sc缺陷的检测精度为79.7%,保持了较高水平。上述结果说明,FFD-YOLO在不同尺度目标和多类型表面缺陷场景下均具有良好的鲁棒性与跨领域泛化能力。

4.7 实验系统验证

为提升目标检测模型在工业场景中的应用性能,本文开发了一套面向液晶显示屏缺陷的实时检测系统软件。该系统旨在实现对液晶显示屏表面各类缺陷的快速、准确识别与分类。图11为系统的软件操作界面,用户可通过该界面完成图像加载、检测执行及结果显示等功能。实验结果表明,该系统能够准确识别出图像中存在的缺陷种类与数量,且检测结果与人工标注数据完全



图11 液晶屏缺陷检测系统

Fig. 11 LCD defect detection system

一致,未出现漏检或误检现象,充分验证了该系统在实际工业检测中的应用可行性与稳定性。

5 结 论

本文针对液晶屏缺陷检测中存在的小目标检测困难、尺度跨度大以及复杂背景干扰等问题,基于YOLOv8n提出了FFD-YOLO模型。模

型采用 FasterNet 主干网络,提高特征提取能力;设计 FPSC 模块,将多膨胀率卷积与共享卷积机制结合,增强多尺度建模能力;提出 MACM 模块,融合动态卷积权重与多尺度卷积核,提高小目标检测性能与复杂场景下的鲁棒性。

实验结果显示,FFD-YOLO 在 LCD-NET 数据集上的精度、召回率与 mAP50 分别为 75.0%、69.7% 与 73.7%,显著优于 YOLOv8n,尤其在划痕与污渍等小目标检测中效果突出。消融实

验验证了各模块的有效性,对比实验与可视化结果进一步说明模型在复杂背景与模糊场景下稳定可靠。在 NEU-DET 数据集上的泛化实验中,mAP50 达到 77.4%,表现出较强的跨场景适应性。未来,我们将基于更大规模的数据集开展验证,并探索自监督学习与多模态特征融合。同时结合实际工艺流程进行跨平台优化与应用集成,进一步提升模型的泛化能力与工业应用价值。

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] REN Z H, FANG F Z, YAN N, *et al.* State of the art in defect detection based on machine vision [J]. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2022, 9(2): 661-691.
- [3] SHAN Y J, KRISHNAKUMAR A, QIN Z H, *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.
- [4] LIU Z G, GAO Y, DU Q Q, *et al.* YOLO-extract: improved YOLOv5 for aircraft object detection in remote sensing images [J]. *IEEE Access*, 2023, 11: 1742-1751.
- [5] CHEN Z H, ZHA Y W, WU Z Z, *et al.* Detection of mobile phone screen defect based on faster R-CNN fusion model [C]//*Proceedings of 2021 China Automation Congress (CAC)*. Beijing: IEEE, 2021: 6601-6606.
- [6] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot MultiBox detector [C]//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam: Springer, 2016: 21-37.
- [7] 徐彦威,李军,董元方,等. YOLO 系列目标检测算法综述[J]. *计算机科学与探索*, 2024, 18(9): 2221-2238.
XU Y W, LI J, DONG Y F, *et al.* Survey of development of YOLO object detection algorithms [J]. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(9): 2221-2238. (in Chinese)
- [8] 刘彦磊,李孟喆,王宣宣. 轻量型 YOLOv5s 车载红外图像目标检测[J]. *中国光学(中英文)*, 2023, 16(5): 1045-1055.
LIU Y L, LI M Z, WANG X X. Lightweight YOLOv5s vehicle infrared image target detection [J]. *Chinese Optics*, 2023, 16(5): 1045-1055. (in Chinese)
- [9] 蔡引娣,张殿鹏,孙梓盟,等. 基于改进 YOLOv8 模型的增材制造微小气孔缺陷检测及其尺寸测量[J]. *光学精密工程*, 2024, 32(21): 3222-3230.
CAI Y D, ZHANG D P, SUN Z M, *et al.* YOLOv8 model-based additive manufacturing micro porosity defect detection and its dimension measurement [J]. *Optics and Precision Engineering*, 2024, 32(21): 3222-3230. (in Chinese)
- [10] 杨彦萍,高军伟,刘兆龙,等. 基于改进 YOLO11 的印刷电路板表面缺陷检测算法[J]. *液晶与显示*, 2025, 40(10): 1545-1556.
YANG Y P, GAO J W, LIU Z L, *et al.* Surface defect detection on printed circuit boards based on improved YOLO11 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(10): 1545-1556. (in Chinese)
- [11] 景会成,鲍成明. 基于改进 YOLOv12 的铝型材工件缺陷检测技术研究[J/OL]. *电子测量技术*, 1-11. (2025-07-29) [2025-08-11]. <https://link.cnki.net/urlid/11.2175.TN.20250729.1342.011>.
JING H C, BAO C M. Research on defect detection technology of aluminum profile workpiece based on improved YOLOv12 [J/OL]. *Electronic Measurement Technology*, 1-11. (2025-07-29) [2025-08-11]. <https://link.cnki.net/urlid/11.2175.TN.20250729.1342.011>. (in Chinese)
- [12] LIU T H, HE Z S, LIN Z J, *et al.* An adaptive image segmentation network for surface defect detection [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(6): 8510-8523.

- [13] 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.
- [14] 朱广,顾晨,徐立云,等. 改进YOLOv8的风机叶片多尺度缺陷检测[J]. 光学精密工程, 2025, 33(9): 1496-1514. ZHU G, GU C, XU L Y, *et al.* Improvement of YOLOv8 for multi-scale defect detection in wind turbine blades [J]. *Optics and Precision Engineering*, 2025, 33(9): 1496-1514. (in Chinese)
- [15] ZHAO C, SHU X, YAN X, *et al.* RDD-YOLO: a modified YOLO for detection of steel surface defects [J]. *Measurement*, 2023, 214: 112776.
- [16] YANG G, LAI H J, ZHOU Q F. Visual defects detection model of mobile phone screen [J]. *Journal of Intelligent & Fuzzy Systems*, 2022, 43(4): 4335-4349.
- [17] 林峰,石艳,陈顺龙,等. 基于YOLOv5的液晶屏微弱特征缺陷检测算法[J]. 液晶与显示, 2024, 39(6): 790-800. LIN F, SHI Y, CHEN S L, *et al.* Weak feature defect detection method for LCD screens based on YOLOv5 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(6): 790-800. (in Chinese)
- [18] 陈顺龙,廖映华,林峰,等. 基于改进YOLOv8n的液晶屏Mura缺陷检测[J]. 液晶与显示, 2025, 40(3): 439-447. CHEN S L, LIAO Y H, LIN F, *et al.* Mura defect detection of LCD screen based on improved YOLOv8n [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(3): 439-447. (in Chinese)
- [19] VARGHESE R, SAMBATH M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness [C]//*Proceedings of 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*. Chennai: IEEE, 2024: 1-6.
- [20] CHEN J R, KAO S H, HE H, *et al.* Run, don't walk: chasing higher FLOPS for faster neural networks [C]//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023: 12021-12031.

作者简介:



山宏刚,男,硕士,高级工程师,2004年于上海交通大学获得硕士学位,主要研究方向为机电产品检测。E-mail: 1270118@qq.com



廖泽威,男,硕士研究生,2024年于上海电机学院获得学士学位,主要研究方向为图像处理及缺陷检测。E-mail: laurenceyy@163.com