

## 基于改进YOLOV8的图像液晶显示屏像素缺陷检测算法

张峰

引用本文

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(11A): 240100162-7.

ZHANG Feng. Graphical LCD Pixel Defect Detection Algorithm Based on Improved YOLOV8[J]. Computer Science, 2024, 51(11A): 240100162-7.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[PS-YOLOv8:增强电力线路检测中的小规模损坏检测](#)

PS YOLOv8:Enhancing Detection of Small-scale Damage in Power Lines Inspection  
计算机科学, 2024, 51(11A): 240100003-6. <https://doi.org/10.11896/jsjcx.240100003>

[基于可见光-红外跨域迁移的红外弱小目标检测](#)

Infrared Dim and Small Target Detection Based on Cross-domain Migration of Visible Light and Infrared  
计算机科学, 2024, 51(10): 287-294. <https://doi.org/10.11896/jsjcx.230800013>

[融合注意力机制与线激光辅助的输送带缺陷检测网络](#)

Conveyor Belt Defect Detection Network Combining Attention Mechanism with Line Laser Assistance  
计算机科学, 2024, 51(6A): 230800115-6. <https://doi.org/10.11896/jsjcx.230800115>

[卷烟厂卷包车间工人违规作业行为检测方法](#)

Detection Method for Workers' Illegal Operation Behavior in Packaging Workshop of Cigarette Factory  
计算机科学, 2024, 51(6A): 230700123-8. <https://doi.org/10.11896/jsjcx.230700123>

[基于Depth-wise卷积和视觉Transformer的图像分类模型](#)

Novel Image Classification Model Based on Depth-wise Convolution Neural Network and Visual Transformer  
计算机科学, 2024, 51(2): 196-204. <https://doi.org/10.11896/jsjcx.221100234>

# 基于改进 YOLOV8 的图像液晶显示屏像素缺陷检测算法

张 峰

北京航空航天大学软件学院 北京 100083

**摘 要** 在工业仪表液晶显示屏检测过程中,由于显示屏像素尺寸较小,像素缺陷难以被检测。传统的计算机视觉方法对环境变化敏感,需要手动设置参数。针对上述问题,设计了一种基于深度学习的液晶屏缺陷检测算法,其能够在较低的算力条件下识别液晶屏的像素级别像素缺陷。主要工作包括:(1)针对小尺寸目标正负样本匹配过程中正样本数量较少的问题,提出了一种不同尺寸目标的自适应正样本数量增强方法;(2)针对小尺寸目标正样本 IoU 小导致训练困难的问题,提出了一种自适应正样本 IoU 补偿加权方法;(3)针对小数据集对超参数敏感的问题,设计了一种正负交叉熵不平衡权重分类损失函数;(4)针对小尺寸目标细节特征提取困难的问题,在主干网络中引入了频域通道注意力,强化了小目标的细节特征提取能力。实验结果表明,相较于基线模型 YOLOV8,此算法的小尺寸检测目标的  $mAP_s$  达到 63.3%,提高了 3.7%。其中,小尺寸像素缺陷的  $mAP_s$  达到 78.8%,提升了 4.5%;灰尘杂质检测目标的  $mAP_s$  达到 47.8%,提升了 3%;像素缺陷召回率达到 99.8%。以上结果充分验证了算法的有效性。

**关键词**:小目标;IoU 补偿;不平衡加权损失;正样本数量增强

**中图分类号** TP391.41

## Graphical LCD Pixel Defect Detection Algorithm Based on Improved YOLOV8

ZHANG Feng

School of Software, Beihang University, Beijing 100083, China

**Abstract** During the inspection process of industrial instrument LCD displays, pixel defects are difficult to detect due to its small pixel size. Traditional computer vision methods are sensitive to environmental changes and require manual setting of parameters. In response to the above problems, this paper designs an LCD screen defect detection algorithm based on deep learning, which can identify pixel-level pixel defects on the LCD screen under lower computing power. The main work includes: (1) Aiming at the problem of the small number of positive samples in the sample assigner process of positive and negative samples for small-sized targets, an adaptive positive samples enhancement method for targets of different sizes is proposed. (2) Aiming at the problem of difficulty in small-sized targets training caused by small IoU of positive samples, an adaptive positive sample IoU compensation weighting method is proposed. (3) Aiming at the problem that small data sets are sensitive to hyperparameters in the loss function, a positive and negative cross-entropy imbalance weight classification loss function is designed. (4) In order to solve the problem that detailed features of small-sized target are difficult to extract, frequency channel attention is introduced in the backbone network to enhance the ability to extract detailed features of small targets. Experiments show that compared with the baseline-comparison model YOLOV8, the  $mAP_s$  reaches 63.3%, which is 3.7% higher than the baseline. The  $mAP_s$  for pixel defects reaches 78.85%, which improves 4.5%. Meanwhile, the recall rate of pixel defects reaches 99.8%. The  $mAP_s$  for dust detection targets reaches 47.8%, improves 3%. These fully verify the effectiveness of the proposed algorithm.

**Keywords** Minor targets, IoU compensation, Imbalanced weighted loss, Positive samples enhancement

## 1 引言

在液晶显示屏生产过程中,缺陷检测是一项非常重要的质检环节。人工质检容易视觉疲劳,降低缺陷检测准确度,并且人力成本越来越高。为解决传统人工检测的弊端,基于计算机系统的表面缺陷检测逐渐受到重视。当前研究主要集中在基于传统计算机视觉的 Mura 色差缺陷以及屏幕划痕等物理缺陷<sup>[1]</sup>,针对液晶屏像素级缺陷的检测方案较少。Qian 等<sup>[2]</sup>基于改进梯度算法对采集到的图像进行缺陷特征提取,采用优化的中值滤波算法对图像去噪,通过二值图像连通域标记算法对缺陷进行定位,实现了亚像素级缺陷检测。传统

计算机视觉方法往往只针对特定测试环境下的缺陷进行特征设计,泛化能力较差,同时还需要人工调节多个超参数以提高算法性能。相比之下,深度学习端到端的训练方式更适合复杂检测场景,但当前基于深度学习理论的液晶屏像素缺陷检测研究极少。Luo<sup>[3]</sup>采用图像重叠区域切分的方法,基于 Faster R-CNN 改进膨胀卷积结构,缓解液晶屏表面小尺寸瑕疵检测效果不好的问题。类似的小目标检测场景中,Gong 等<sup>[4]</sup>在研究卫星图像中小目标检测的解决方案时,根据卫星图像特点将 YOLOV5 模型更新,改进特征融合层将骨干网络获取的浅层特征带入特征融合层,有效减少了小物体特征信息的丢失,提高了检测性能。引入了多个基于规范化的注意

力(NAM<sup>[5]</sup>),专门针对复杂场景中的检测物体。Zhu等<sup>[6]</sup>在处理无人机拍摄图像的小目标检测问题时,在YOLOV5的基础上增加了一个预测头来集成卷积块注意模型(CBAM<sup>[7]</sup>),帮助在具有密集对象的场景中寻找有效区域。

本文提出了一种基于少样本数据集、小尺寸检测目标、深度学习的缺陷检测算法。该算法能够在较低算力条件下,有效检测形态尺寸多样的像素缺陷,识别图像上的灰尘杂质。主要研究内容包括:

(1)设计了一种正负交叉熵不平衡权重的分类损失函数,结合本文所提出的针对不同尺寸检测目标的正样本IoU补偿策略以及自适应增加正样本数量的方法,有效缓解了正负样本比例不平衡以及小尺寸目标检测困难的问题;

(2)改进了模型网络结构,通过引入频域通道注意力等机制增强了模型对小目标的特征提取能力;

(3)提出了一种“从训练学习标注”的数据标注方法,减少了数据的多义性标注。

## 2 缺陷数据集的采集及建立

本课题检测的液晶显示屏尺寸大小为4 cm × 5 cm,每个像素尺寸大小为0.5 mm左右。单个像素尺寸非常小,因此需要采集高分辨率图像。综合以上因素,在生产线上搭建了夹具测试台用于固定显示屏放置位置,使用工业相机采集图像。通过此种方式采集的图像,具有尺寸大小一致、像素清晰的特点,方便后续图像处理。样例图像如图1所示。





图1 无缺陷的棋盘形状图像

Fig. 1 Image of defect-free chessboard shape

### 2.1 像素缺陷特征分析

生产线真实生产过程中会随机出现各种像素缺陷。液晶显示屏的固有电气特性使得缺陷像素组成的图案大概率呈现点、线、堆的几何特征。典型的像素缺陷如图2所示。



(a) Defect on chess

(b) Defect on edge

图2 随机像素缺陷示例

Fig. 2 Image demo with random pixel defects

### 2.2 干扰杂质特征分析

生产环境中的灰尘等杂质会随机吸附在显示屏表面。灰尘杂质主要是环境中漂浮的微小粉尘以及絮状物。常见的干扰杂质如图3所示。部分微小杂质形状尺寸与单个像素非常相似,对像素缺陷检测造成较大干扰。

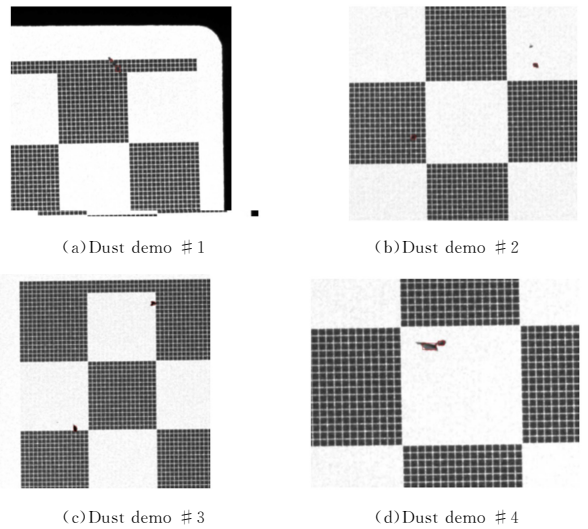


图3 随机干扰杂质示例

Fig. 3 Image demo with dusts

### 2.3 图像压缩以及裁剪

采集图像尺寸为3112 × 2384,显著超过常规检测模型所需尺寸要求。本文采用间隔行列选取像素的方法压缩图像,使之调整为1556 × 1192的4张图像。压缩之后的图像均能保留像素的细节信息,因此任选一份图像即可。一次压缩之后的图像尺寸依旧较大,为保留小目标特征信息,本文采用图像裁剪的方法继续缩小图像。处理后的4份图像尺寸均为750 × 564。

### 2.4 缺陷样本扩增

依据已有灰尘杂质特点以及像素电气特性,扩增杂质检测目标和像素缺陷检测目标。扩增后,每张图像均含有多个像素缺陷以及杂质检测目标,如图4所示。





图4 裁切以及图像增强后的待训练图像

Fig. 4 Training image after cropping and image augmentation

### 2.5 数据标注

本文数据集存在着目标类别定义多义性的问题,如图5所示。



检测目标

(a) 以白色为标注目标

(b) 以黑色为标注目标

图5 带有歧义性的数据标注

Fig. 5 Images with ambiguous annotation

为解决此问题,本文提出了一种“从训练学习标注”的方法。选取部分数据集,给定一种先验似然标注,并基于此标注进行初步训练。训练完成后,使用测试数据集验证,将模型预测结果作为解决多义性问题的辅助标准。

## 2.6 数据集分析

本文数据集缺陷以及杂质检测目标的数量分布如表 1 所列。条形杂质和圆形杂质数量远小于像素缺陷检测目标数量,并且整个数据集没有符合 COCO 数据集定义的大尺寸物体(96, +∞)。

表 1 不同类别不同尺寸下的检测目标数量

Table 1 Number of detected targets in different categories and scales

类别	小尺寸	中尺寸	大尺寸
黑条	2590	2179	N/A
条形杂质	513	450	N/A
圆形杂质	455	144	N/A
白条	4101	3933	N/A

本数据集检测目标的长宽尺寸统计分布如表 2 所列。可以看出,本文数据集的所有检测目标的平均尺寸较小,整个数据集以小检测目标为主。

表 2 检测目标的尺寸中位数

Table 2 Scale median of detection objects

类别	宽度平均值	长度平均值
黑条	34.44	24.82
条形杂质	31.08	32.36
圆形杂质	27.09	26.73
白条	30.71	28.92

## 3 缺陷检测模型设计

本文以 YOLOV8 算法为基线,主要改进点包括在主干网络使用空间金字塔池化(SPPF)以及 DropBlock<sup>[8]</sup>等模块;在跨层部分连接模块(CSP Layer)使用频域通道注意力(FCA<sup>[9]</sup>)机制;为了有效缓解小尺寸检测目标检测困难以及本文数据集正负样本比例不均衡的问题,在检测头网络设计了正样本自适应 IoU 补偿算法、自适应增加可训练正样本数量算法以及正负交叉熵不平衡类别损失函数等。改进的模型概要结构如图 6 所示。

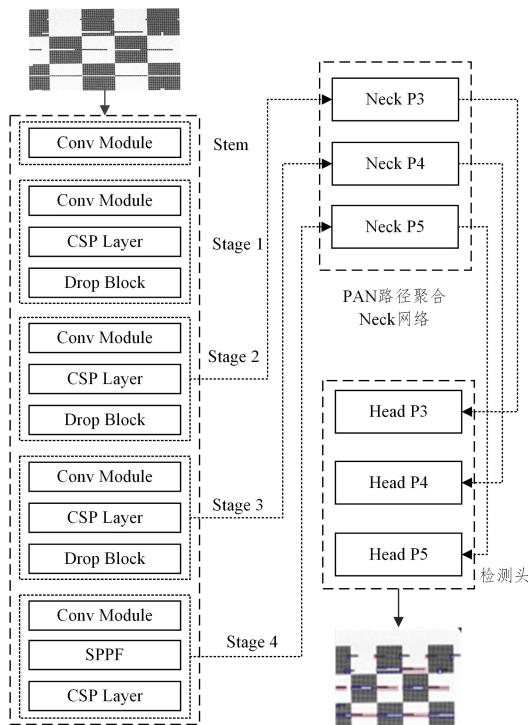


图 6 模型网络概要结构图

Fig. 6 Model overall structure

模型最终部署硬件算力较低。在研究模型轻量化的过程中,本文对模型网络宽度因子和深度因子进行了调整。基线模型实验数据如表 3 所列。

表 3 模型宽度和深度因子性能对比表

Table 3 Model performance comparison with different width and depth factors

宽度因子	深度因子	$mAP_{s}$	参数量/ $10^6$
0.5000(默认)	0.33	58.8	74.83
0.3750(本文)	0.50	59.0	55.20
0.3750	0.75	58.5	73.68
0.1875	0.75	56.3	21.57

从表 3 可以看出,当网络宽度因子设定为 0.375,网络深度因子设定为 0.50 时,模型在参数量相对较小的情况下达到了相对最优的检测精度。

### 3.1 正负样本匹配策略

本文基于 RTMDet<sup>[10]</sup>提出的 Soft Label Assigner 算法进行改进。在 SimOTA 过程中,针对小尺寸检测目标对应正样本的 IoU 较小,导致对应正样本明显较少的问题,本文在计算检测目标的正样本数量时,借鉴了自适应训练标签匹配策略(ATSS<sup>[11]</sup>)。对于不同尺寸检测目标,设计了独立且自适应的正样本 IoU 调整方法。如式(1)所示:

$$IoU = \begin{cases} \text{the original IoU,} & \text{if } IoU < (mean + std) \\ 1, & \text{if } IoU \geq (mean + std) \end{cases} \quad (1)$$

对于每一个检测目标,计算其前 13 大 IoU 初筛样本的均值  $mean$  与标准差  $std$ ,将两者的和作为该检测目标正样本的自适应 IoU 阈值。大于该阈值的初筛样本被认为是高质量样本,样本 IoU 被调整为 1,然后再参与正样本数量计算,实现了小检测目标增加最多正样本数量的目的。

### 3.2 自适应 IoU 补偿

小检测目标由于太小,容易被大检测目标损失掩盖,导致小目标训练不稳定或难以训练。为缓解此问题,本文提出了一种自适应 IoU 补偿方法,自适应调整正样本 IoU 数值,结合分类损失函数,增强小目标在训练过程中的权重。本文将不同尺寸检测目标对应正样本的 IoU 的平均值,作为衡量各自检测能力难易程度的量化标准。小、中、大尺寸检测目标的检测能力计算方法如式(2)一式(4)所示。

$$Mean_{ss} = \frac{1}{N_{ss}} \sum IoU_{ss} \quad (2)$$

$$Mean_{ms} = \frac{1}{N_{ms}} \sum IoU_{ms} \quad (3)$$

$$Mean_{ls} = \frac{1}{N_{ls}} \sum IoU_{ls} \quad (4)$$

其中,  $N_{ss}$ ,  $N_{ms}$ ,  $N_{ls}$  分别代表小、中、大尺寸检测目标对应的正样本的数量总和。  $IoU_{ss}$ ,  $IoU_{ms}$ ,  $IoU_{ls}$  分别代表小、中、大尺寸检测目标对应的正样本的 IoU 集合。3 种尺寸检测目标中的最大 IoU 均值作为检测能力的补偿基准,如式(5)所示。

$$IoU_{base} = \text{Max}(Mean_{ss}, Mean_{ms}, Mean_{ls}) \quad (5)$$

不同尺寸检测目标对应的 IoU 均值与此补偿基准的商值作为各自的补偿权重。小、中、大尺寸检测目标对应正样本 IoU 的自适应补偿方法分别如式(6)一式(8)所示。

$$IoU_{ss-new} = \frac{IoU_{base}}{Mean_{ss}} * IoU_{ss} \quad (6)$$

$$IoU_{ms-new} = \frac{IoU_{base}}{Mean_{ms}} * IoU_{ms} \quad (7)$$

$$IoU_{ls-new} = \frac{IoU_{base}}{Mean_{ls}} * IoU_{ls} \quad (8)$$

其中,  $IoU_{ss}$ ,  $IoU_{ms}$ ,  $IoU_{ls}$  代表检测目标对应正样本的原始  $IoU$  数值;  $IoU_{ss-new}$ ,  $IoU_{ms-new}$ ,  $IoU_{ls-new}$  代表检测目标对应正样本补偿后的  $IoU$  数值。

### 3.3 分类损失

由于本文数据集较小,因此含有较多超参数的分类损失函数难以调优。本文参考 Quality Focal Loss(QFL<sup>[12]</sup>), Vari-ous Focal Loss(VFL<sup>[13]</sup>)以及 Dual Weight Loss(DWL<sup>[14]</sup>)类别损失函数,设计了一种适用于本文小数据集的正负交叉熵不平衡权重类别损失函数(S-DWFL),如式(9)所示。

$$L_{class} = -\omega_{pos} * q * \ln(p) - \omega_{neg} * (1-q) * \ln(1-p) \quad (9)$$

其中,  $q$  为检测目标与对应正负样本的  $IoU$ 。对于正样本,  $q$  为检测目标与对应正样本自适应补偿之后的  $IoU$ ; 对于负样本,  $q$  为零。  $p$  为模型类别预测值。  $\omega_{pos}$  为类别损失函数的正向交叉熵权重,  $\omega_{neg}$  为类别损失函数的负向交叉熵权重。本文类别损失函数正样本的正向、负向交叉熵惩罚权值的计算方法设计如式(10)、式(11)所示。

$$\omega_{pos} = q * e^{|q-p|} \quad (10)$$

$$\omega_{neg} = (1-q) * e^{|q-p|} \quad (11)$$

对于正样本的正向权重,训练目标  $q$  代表了锚点的预测质量好坏程度,  $q$  越大代表预测质量越高,对训练损失贡献就越大,因此用来作为损失惩罚权重的一部分。预测值  $p$  与训练目标  $q$  的差异值也很好表达了模型训练的效果。两者差异值越大,说明模型预测值越差,此时加大惩罚权重放大损失值,引导预测值向训练目标靠拢。正样本负向权重使用极值 1 与  $q$  的差值取代了正权重方法中的  $q$ , 当  $q$  较大时,抑制负向交叉熵的影响,使得分类预测值  $p$  变大并向目标  $q$  的方向优化; 当  $q$  较小时,增强负向交叉熵的影响,引导模型向预测值  $p$  变小的方向优化。

负样本权重设计的目标是使得模型的类别预测值向零值靠拢。对于负样本的正向交叉熵,由于训练目标值  $q$  为零,正向交叉熵损失值永远为零,故无需考虑权重。负样本负向交叉熵惩罚权重计算方法如式(12)所示。

$$\omega_{negative} = \alpha * (e^p - 1) * p \quad (12)$$

其中,  $\alpha$  是超参数,用以调节负样本在总损失的比重。

## 4 实验与结果分析

### 4.1 实验环境以及评价指标

训练环境的主要配置如表 4 所列。

Table 4 Training hardwares	
规格	
GPU	NVIDIA Tesla T4
Python	3.8
CUDA	11.8
Pytorch	2.0.0

本文重点关注小尺寸检测目标,因此将小尺寸目标  $mAP_s$  作为衡量模型性能以及保存最好训练权重的指标。

### 4.2 注意力模块对比实验

本文与常用的通道注意力模块 Effective SE(ESE<sup>[15]</sup>)以及 Efficient Channel Attention(ECA<sup>[16]</sup>)进行了对比实验。实验结果如表 5 所列。

表 5 不同注意力机制性能对照

Table 5 Performance comparison of different channel attentions

注意力	$mAP_s$	参数量	FPS
FCA	63.3	$54.2 \times 10^6$	9.2
ESE	63.4	$67.0 \times 10^6$	9.8
ECA	61.9	$54.1 \times 10^6$	12.6

从表 5 可以看出,本文采用的 FCA 频域通道注意力与 ESE 性能指标类似,但模型权重文件却减少了  $10 \times 10^6$  以上。从检测精度以及参数量两个指标综合来看, FCA 频域通道注意力最好。此外,在实验过程中发现,通道注意力对模型性能影响较明显。去掉通道注意力之后,模型训练过程中出现了多次训练精度为零的现象。

### 4.3 正负样本匹配策略对比实验

YOLOV8 模型采用了 Task Aligned Assigner(TAA<sup>[17]</sup>)正负样本分配策略。商汤科技 RTMDet 模型采用了基于 SimOTA 算法的 Dynamic Soft Label Assigner(DSLA)正负样本匹配策略。本文以上述两个正负样本匹配策略作为参考,与本文在 DSLA 基础上改进的、可以自适应增加正样本数量的匹配策略(I-DSLA)进行实验对比。实验效果如表 6 所列。

表 6 正负样本匹配策略对检测类别的影响

Table 6 Performance under different sample matching strategies

类别	策略	$mAP$	$mAP_s$
黑条	TAA	76.0	75.4
	DSLA	76.3	75.2
	I-DSLA	<b>76.7</b>	<b>75.4</b>
白条	TAA	88.4	88.3
	DSLA	88.3	88.4
	I-DSLA	<b>88.5</b>	<b>88.4</b>
圆形杂质	TAA	48.5	52.9
	DSLA	51.5	52.0
	I-DSLA	<b>51.6</b>	52.6
线形杂质	TAA	45.2	42.2
	DSLA	47.5	44.0
	I-DSLA	<b>48.0</b>	<b>45.6</b>

从表 6 可以看出,对于黑条像素缺陷以及白条像素缺陷,数据集中存在着部分尺寸相对较大的检测目标,本文正负样本匹配策略的效果与两种对比匹配策略相似。对于整体上以小尺寸为主的杂质检测目标,本文正负样本匹配策略表现更好一些,符合此改进匹配策略的设计初衷。

### 4.4 类别损失函数对比实验

本文类别损失函数 S-DWFL 与当前流行类别损失函数 QFL 和 VFL 分别对 4 类检测目标的实验结果如表 7 所列。

表 7 类别损失函数性能对比

Table 7 Performance comparison of different class loss functions

类别	类别损失函数	$mAP$	$mAP_s$
黑条	VFL	74.2	72.0
	QFL	74.2	71.9
	BCE	75.2	71.8
	S-DWFL	75.0	<b>73.1</b>
白条	VFL	85.2	82.7
	QFL	85.4	83.1
	BCE	85.8	83.4
	S-DWFL	<b>86.6</b>	<b>84.6</b>
圆形杂质	VFL	53.1	52.3
	QFL	53.3	55.4
	BCE	50.0	51.2
	S-DWFL	<b>54.6</b>	<b>56.6</b>
线形杂质	VFL	39.0	42.0
	QFL	43.5	40.0
	BCE	42.1	41.2
	S-DWFL	41.2	39.0

从表 7 可以看出,本文提出的类别损失函数对黑条像素缺陷、白条像素缺陷以及圆形杂质 3 类检测目标效果最好。

为了进一步评估本文提出的类别损失函数算法的有效性以及泛化能力,使用了 Roboflow 网站提供的一个公开数据集 Football-players-detection 进行训练和验证。与本文数据集检测目标特点类似,此数据集也以密集小检测目标居多,整个数据集不到 300 张图像,数据集由足球、守门员、球员、裁判 4 类标签组成,如图 7 所示。




图 7 公开数据集数据标注示例

Fig. 7 Public dataset annotations demo

基于公开数据集的类别损失函数详细性能对照如表 8 所列。从数据可以看出,本文提出的类别损失函数 S-DWFL 的精度指标均好于对比类别损失函数。

表 8 公开数据集类别损失函数性能对比

Table 8 Performance comparison of class loss functions on public dataset

类别损失函数	$mAP$	$mAP_s$	$mAP_m$
VFL	48.9	42.9	68.2
QFL	49.0	45.0	66.9
BCE	49.2	42.7	69.6
S-DWFL	<b>51.8</b>	<b>45.0</b>	<b>72.2</b>

#### 4.5 自适应 IoU 补偿对比实验

4 类检测目标分别在有无 IoU 自适应补偿情况下的实验数据如表 9 所列。

表 9 自适应 IoU 补偿性能对比

Table 9 Performance comparison of adaptive IoU compensation

类别	自适应 IoU	$mAP$	$mAP_s$
黑条	无	76.3	75.4
	有	<b>76.7</b>	75.4
白条	无	88.2	88.1
	有	<b>88.5</b>	<b>88.4</b>
圆形杂质	无	45.4	49.2
	有	<b>51.6</b>	<b>51.6</b>
线形杂质	无	42.2	41.3
	有	<b>48.0</b>	<b>43.4</b>

从表 9 可以看出,对于数量少且尺寸小的杂质检测目标来说,自适应 IoU 补偿方法对模型精度有一定的提升。对于数量多、形状相对规则的黑条以及白条像素缺陷目标,由于可训练样本多并且检测目标尺寸相对较大,有无自适应加权对模型性能影响不明显。整体来看,自适应 IoU 补偿方法对小尺寸检测目标有较好的效果。

自适应 IoU 补偿方法在公开数据集上的实验数据如表 10 所列。从表 10 可以看出,本文提出的自适应 IoU 补偿策略,当采用 QFL 以及本文 S-DWFL 类别损失函数时,模型  $mAP_s$  得到了明显提升,说明此补偿策略有一定的泛化性。

表 10 公开数据集自适应 IoU 补偿性能对比

Table 10 Performance comparison of adaptive IoU compensation in public dataset

类别	自适应 IoU	$mAP$	$mAP_s$
VFL	无	51.9	44
	有	48.9	42.9
QFL	无	46.2	40
	有	<b>49.0</b>	<b>45.0</b>
BCE	无	48.4	42.9
	有	<b>49.2</b>	42.8
S-DWFL	无	48.3	42.6
	有	<b>51.8</b>	<b>45.0</b>

#### 4.6 消融实验

消融实验如表 11 所列。在模型参数文件相比 YOLOV8 减小  $17 \times 10^6$  的前提下, $mAP_s$  提升了 4.9%。从实验结果来看,主要是通过改变训练图像尺寸、添加频域通道注意力、优化正负样本匹配策略、自适应 IoU 补偿以及本文设计的类别损失函数等核心改进点实现了模型性能提升。

表 11 消融实验对照

Table 11 Ablation experiment comparison

消融点	$mAP_s$	$mAP$	参数量
YOLOV8baseline	58.4	60.5	$74.40 \times 10^6$
+ Image sizeto 960	59.6(+1.2)	61.5	$74.83 \times 10^6$
+ Widen & DepthChange	59.8(+0.2)	62.0	$55.29 \times 10^6$
+ CSPNeXtBlock	59.9(+0.1)	61.9	$53.18 \times 10^6$
+ FCA Attention	60.8(+0.9)	62.2	$56.50 \times 10^6$
+ AdamW	61.0(+0.2)	62.8	$56.30 \times 10^6$
+ Drop Block	61.2(+0.2)	63.1	$56.80 \times 10^6$
+ IoU Compensation	62.1(+0.9)	63.5	$56.50 \times 10^6$
+ I-DSLA Assigner	62.5(+0.4)	63.8	$56.40 \times 10^6$
+ S-DWFL Class Loss	63.3(+0.8)	64.3	$56.70 \times 10^6$
总增益	<b>+4.9</b>	<b>+3.8</b>	<b>-17.70</b>

实验中发现使用 ASFF<sup>[18]</sup> 特征融合效果不理想。猜测可能是因为对于小尺寸检测目标,通道注意力机制已经融合了特征提取网络提取的极限特征,导致 ASFF 无法融合获取更多有价值的特征信息。

#### 4.7 不同模型对比实验

本文以单阶段 YOLO 系列检测模型、经典双阶段检测模型 Cascade R-CNN,以及基于自注意力的 DETR<sup>[19]</sup> 和 Deformable DETR<sup>[20]</sup> 检测模型作为对照模型,验证本文模型 SDW-YOLO 的有效性。实验数据如表 12 所列。

表 12 模型性能对比

Table 12 Performance comparison of different models

模型	$mAP$	$mAP_s$	$mAP_s$ (像素)	参数量
RTMDet	61.7	58.9	73.40	$42.70 \times 10^6$
YOLOV8	61.5	59.6	74.35	$73.90 \times 10^6$
PPYOLOE	48.3	47.1	66.50	$60.50 \times 10^6$
YOLOV7	44.1	39.3	54.70	$48.13 \times 10^6$
YOLOX	59.9	58.9	74.85	$70.50 \times 10^6$
YOLOV5	37.2	33.6	46.05	$55.80 \times 10^6$
YOLOV6	61.0	58.9	74.90	$146.00 \times 10^6$
Cascade R-CNN	61.4	59.5	75.25	$265.00 \times 10^6$
DETR	0	0	0	0
Deformable DETR	59.9	58.7	73.25	$162.00 \times 10^6$
SDW-YOLO	64.3	63.3	78.50	$56.70 \times 10^6$

从表 12 可以看出,本文提出的检测模型类别平均精度指

标  $mAP$  达到了 64.3%，性能指标明显高于其他对比模型。对于本文最为关心的小尺寸检测目标的  $mAP_s$  及小尺寸像素缺陷检测目标的  $mAP_{ps}$ ，本模型分别达到了 63.3% 以及 78.5%，也明显高于其他对比模型。此外，通常需要大量数据进行训练的 DETR 在本文数据集上无法收敛。整体来看，本文模型效果最好。

与图片背景色相似的检测目标，其特征细节难以捕获，检测十分困难。本文模型 SDW-YOLO 与对比模型对此类检测目标的检测结果如图 8 所示。从检测结果可知，在分类置信度阈值为 0.4 的前提下，只有本文模型成功识别了检测目标。




图 8 与背景色相似的检测目标的不同模型效果对比  
Fig. 8 Effect comparison of different models for detection targets with similar background color

#### 4.8 模型应用效果

考虑到本模型最终将在生产线环境进行部署使用，本文选取了 66 张未曾参与训练的图像进行实验测试。生产线测试计算机的硬件环境如表 13 所列。

表 13 生产线部署计算机硬件

Table 13 Computer hardware deployment in production line	
规格	
处理器	Intel(R) Core i5-8500 CPU @ 3.00GHz 3.00GHz
内存/GB	8

推理过程中将预测置信度阈值设置为 0.4，用于只保留高质量的候选预测目标。此 66 张图像包含 1733 个不同尺寸的像素缺陷标注检测目标，其中 1731 个像素缺陷被检测出来，像素缺陷召回率超过了 99.8%。含有密集检测目标的检测图像的测试结果如图 9 所示。




图 9 密集检测目标的测试结果  
Fig. 9 Test results of intensive detection objects

图 9(a) 为人工标注的检测目标，图 9(b) 为本文模型预测结果，不同颜色代表不同类别的检测目标。从图中可以看出，在不规则复杂密集检测条件下，人工标注检测目标不仅被本文模型检测出来，而且检测模型预测的检测目标边界框也非常准确。

对于形状不规则的杂质检测目标，如图 10 所示，本文检测模型给出了较高的预测类别置信度和预测位置信息。

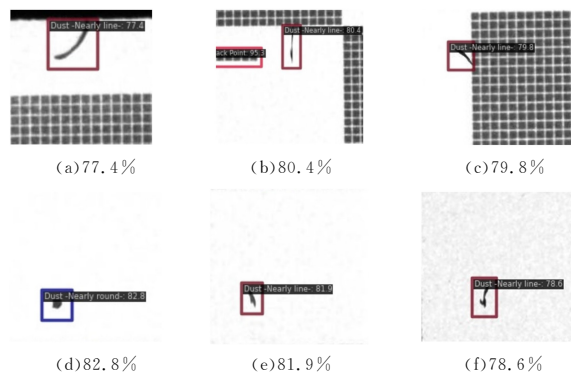


图 10 本文模型对不规则小目标的检测效果  
Fig. 10 Detection result of the proposed model on irregular small objects

对于真正的像素缺陷，本文模型检测效果如图 11 所示。

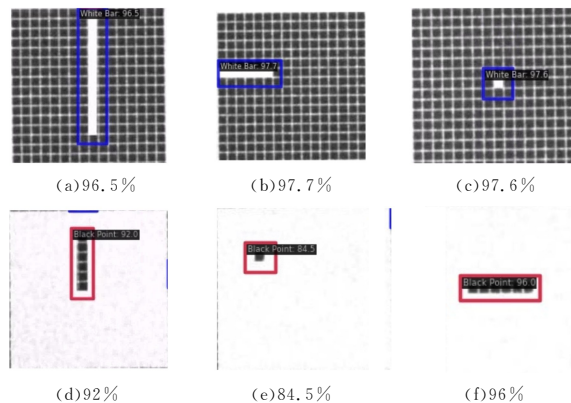


图 11 本文模型像素缺陷检测效果  
Fig. 11 Detection results of the proposed model on pixel defects

从检测结果看，无论像素缺陷数量、黑白、方向如何变化，本模型均能给出一个较高预测值将其准确检测出来。

#### 4.9 模型特征可视化

为了验证本文模型的特征提取能力，选取了一张含有较淡颜色检测目标(红色圆框内)的测试图像进行测试。特征提取效果如图 12 所示。从图中可以看出，本文模型特征融合有效，能够聚焦有效特征信息。像素级别的检测目标热力图效果清晰明确，颜色较淡的检测目标也得到了明显的特征增强。

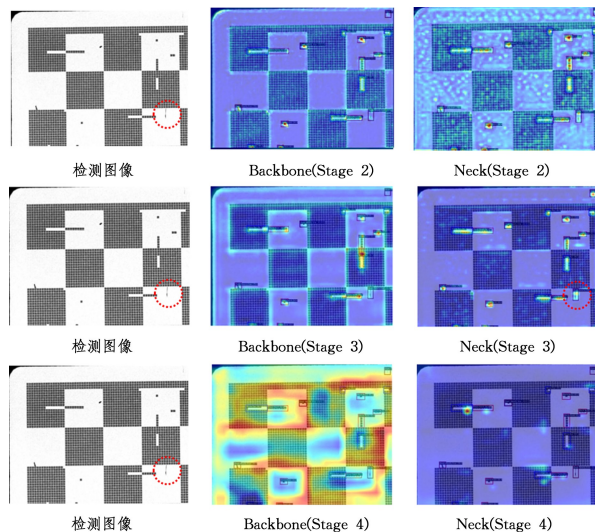


图 12 检测目标的特征可视化  
Fig. 12 Feature visualization of detection objects

**结束语** 本文提出了一种基于小样本、小尺寸目标的图像液晶显示屏像素缺陷检测算法。该算法能够有效检测出像素级别的形状不规则的像素缺陷,并且能够有效识别图像上的灰尘杂质,减少像素缺陷的错误检测。实验结果表明,本文模型小尺寸检测目标的  $mAP_s$  达到了 63.3%,相比基线模型提高了 3.7%。其中,小尺寸像素缺陷、灰尘杂质检测目标的  $mAP_s$  分别达到了 78.85% 和 47.8%,相比基线模型分别提升了 4.5% 和 3%。此外,像素缺陷召回率达到了 99.8%。实验结果充分验证了本文算法的有效性。在公开数据集上的结果表明本文方法具有较好的泛化性。本文对杂质检测目标的效果还有待提高。此类检测目标虽然不影响显示屏质量,但未来,对检测显示屏划伤划痕等缺陷具有借鉴意义。在后续的研究中,将探索不含有超参数的分类损失函数以及其他惩罚权重函数,使之能自适应地处理数据集正负样本比例不平衡以及小尺寸检测目标检测困难的问题。

### 参 考 文 献

- [1] MING W,ZHANG S,LIU X,et al. Survey of Mura Defect Detection in Liquid Crystal Displays Based on Machine Vision[J]. Crystals,2021,11(12):1444.
- [2] QIAN J D,CHEN B,QIAN J Y,et al. Fast detection of sub-pixel defects in LCD based on improved gradient algorithm[J]. Journal of Computer Applications,2017,37(S1):201-205.
- [3] LUO Q Y. Design and Implementation of Screen Surface Defect Detection System Based on Improved Faster RCNN[D]. Beijing:BUPT,2021.
- [4] GONG H,MU T,LI Q,et al. Swin-Transformer-Enabled YOLOv5 with Attention Mechanism for Small Object Detection on Satellite Images[J]. Remote Sensing,2022,14(12):2861.
- [5] LIU Y,SHAO Z. NAM: Normalization-based Attention Module [J]. arXiv:2111.12419,2021.
- [6] ZHU X,LYU S,WANG X,et al. TPH-YOLOv5: Improved YOLOv5 Based on Transformer Prediction Head for Object Detection on Drone-captured Scenarios[C]// IEEE/CVF International Conference on Computer Vision. 2021:2778-2788.
- [7] WOO S,PARK J. CBAM: Convolutional Block Attention Module[C]// European Conference on Computer Vision (ECCV). 2018:3-19.
- [8] GHIASI G,LIN T Y,LE Q V. DropBlock: A regularization method for convolutional networks[J]. Advances in Neural Information Processing Systems,2018,31.
- [9] QIN Z,ZHANG P,WU F,et al. FcaNet: Frequency Channel Attention Networks[C]// IEEE/CVF International Conference on Computer Vision. 2021:783-792.
- [10] LYU C,ZHANG W,HUANG H,et al. RTMDet: An Empirical Study of Designing Real-Time Object Detectors[J]. arXiv:2212.07784,2022.
- [11] ZHANG S,CHI C,YAO Y,et al. Bridging the Gap Between Anchor-Based and Anchor-Free Detection via Adaptive Training Sample Selection[C]// IEEE CVF Conference on Computer Vision and Pattern Recognition. 2020:9759-9768.
- [12] LI X,WANG W,WU L,et al. Generalized Focal Loss: Learning Qualified and Distributed Bounding Boxes for Dense Object Detection[J]. Advances in Neural Information Processing Systems. 2020:21002-21012.
- [13] ZHANG H,WANG Y,DAYOUB F,et al. VarifocalNet: An IoU-aware Dense Object Detector[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:8514-8523.
- [14] LI S,HE C,LI R,et al. A Dual Weighting Label Assignment Scheme for Object Detection[C]// IEEE CVF Conference on Computer Vision and Pattern Recognition. 2022:9387-9396.
- [15] TAN M,PANG R,LE Q V. EfficientDet: Scalable and Efficient Object Detection[C]// IEEE CVF Conference on Computer Vision and Pattern Recognition. 2020:10781-10790.
- [16] WANG Q,WU B,ZHU P,et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks [C] // IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:11534-11542.
- [17] FENG C,ZHONG Y,GAO Y,et al. TOOD: Task-aligned One-stage Object Detection[C]// IEEE CVF International Conference on Computer Vision (ICCV). 2021:3490-3499.
- [18] LIU S,HUANG D,WANG Y. Learning Spatial Fusion for Single-Shot Object Detection[J]. arXiv:1911.09516,2019.
- [19] CARION N,MASSA F,SYNNAEVE G,et al. End-to-End Object Detection with Transformers[C]// European Conference on Computer Vision. 2020:213-229.
- [20] ZHU X,SU W,LU L,et al. Deformable DETR: Deformable Transformers for End-to-End Object Detection[J]. arXiv:2010.04159,2020.



**ZHANG Feng**, born in 1985, postgraduate. His main research interest is production line test system automation and intelligence.