

# PDN-YOLO: 面向触控屏组件表面缺陷的检测算法

朱浩淼, 魏鑫瑶, 孙晓莹, 曹鑫阳, 吴哲\*, 翁智峰\*

华侨大学数学科学学院, 计算科学福建省高校重点实验室, 福建 泉州

收稿日期: 2026年6月22日; 录用日期: 2026年7月20日; 发布日期: 2026年7月29日

## 摘要

针对触控屏组件表面缺陷尺度较小、对比度低且易与柔性电路复杂背景相混淆, 导致现有检测方法难以兼顾精度与实时性的问题, 本文提出了一种基于改进YOLOv10s架构的轻量化高保真检测框架PDN-YOLO。首先, 将颈部特征融合网络中的传统卷积模块替换为部分卷积PConv, 在保留深层感受野的同时降低计算量, 提升了检测效率。其次, 采用动态上采样模块DySample替换传统的静态插值算子, 该模块利用空间自适应采样机制, 改善了微小目标在上采样过程中的边缘模糊问题。此外, 引入归一化Wasserstein距离NWD损失函数优化边界框度量机制, 缓解了传统损失函数对微小位置偏差过于敏感的问题, 提升了定位精度。在包含泡棉、粘膜纸、FPC连接器等8类典型缺陷的1510张触控屏产线数据集上进行的实验结果表明, 与基线模型YOLOv10s相比, PDN-YOLO的mAP@[0.5:0.95]指标提升了2.1个百分点, 达到87.1%。同时, 单图检测速度由6.9 ms缩短至5.9 ms, 检测速度提升约14.5%。

## 关键词

触控屏缺陷检测, 部分卷积, 动态上采样, 损失函数, YOLOv10s

# PDN-YOLO: A Detection Algorithm for Surface Defects on Touch Screen Components

Haomiao Zhu, Xinyao Wei, Xiaoying Sun, Xinyang Cao, Zhe Wu\*, Zhifeng Weng\*

Fujian Province University Key Laboratory of Computation Science, School of Mathematical Sciences of Huaqiao University, Quanzhou Fujian

Received: June 22, 2026; accepted: July 20, 2026; published: July 29, 2026

\*通讯作者。

文章引用: 朱浩淼, 魏鑫瑶, 孙晓莹, 曹鑫阳, 吴哲, 翁智峰. PDN-YOLO: 面向触控屏组件表面缺陷的检测算法[J]. 计算机科学与应用, 2026, 16(7): 180-195. DOI: 10.12677/csa.2026.167251

## Abstract

To address the problem that existing detection methods struggle to balance accuracy and real-time performance due to the small scale, low contrast of surface defects on touch screen components and their easy confusion with the complex background of flexible circuits, this paper proposes a lightweight high-fidelity detection framework PDN-YOLO based on the improved YOLOv10s architecture. Firstly, the traditional convolution modules in the neck feature fusion network are replaced with Partial Convolution (PConv), which reduces the computational load while preserving the deep receptive field and improves detection efficiency. Secondly, the dynamic upsampling module DySample is adopted to replace the traditional static interpolation operator. This module utilizes a spatially adaptive sampling mechanism to alleviate the edge blurring problem of tiny targets during the upsampling process. Furthermore, the Normalized Wasserstein Distance (NWD) loss function is introduced to optimize the bounding box measurement mechanism, which mitigates the excessive sensitivity of traditional loss functions to minor positional deviations and enhances localization accuracy. Experimental results on a dataset of 1510 touch screen production line images containing 8 typical defects such as foam, adhesive film, and FPC connectors show that compared with the baseline model YOLOv10s, the mAP@[0.5:0.95] metric of PDN-YOLO is improved by 2.1 percentage points, reaching 87.1%. Meanwhile, the single-image detection latency is reduced from 6.9 ms to 5.9 ms, representing an approximately 14.5% improvement in detection speed.

## Keywords

Touch Screen Defect Detection, Partial Convolution, Dynamic Upsampling, Loss Function, YOLOv10s

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

触控屏(TP)与柔性印制电路板(FPC)广泛运用于智能设备与工业控制终端的基础交互界面[1],其质量直接关乎电子设备的性能与可靠性。其制造与组装涉及多种关键元器件,在实际生产线中容易产生喷码缺失、导电泡棉错位、微型元器件偏移及 FPC 连接器损坏等缺陷。这些缺陷将直接影响产品的电气可靠性与稳定性[2]。因此,在生产线上部署高效高精度的自动光学检测系统是实现高质量保证的关键环节。传统缺陷检测严重依赖人工目检,该方法受主观判断不一致、人工易疲劳等因素影响,漏检率较高。传统机器视觉技术虽已被采用,但难以应对工业背景复杂、缺陷尺度微小等挑战[3]。近年来,随着深度学习技术的发展,卷积神经网络被广泛应用于工业检测。特别是以 YOLO 为代表的单阶段目标检测算法,凭借在检测精度与检测速度之间的良好平衡,成为工业缺陷检测的主流方法[4]。

尽管 YOLOv10 等先进模型具有架构上的优越性,但在复杂环境中检测微小元器件仍然是一个艰巨的挑战。2023 年唐等人[5]提出了一种用于电子元器件表面缺陷检测的多尺度特征融合网络,该方法通过引入加权双向特征金字塔加深网络结构提升了检测精度,但这不可避免地增加了模型的计算复杂度,难以满足工业边缘设备的实时性处理要求。2025 年龚等人[6]针对微小目标的高频边缘信息退化问题,探索了动态分辨率恢复策略以精细重建目标轮廓,但在极端复杂的工业背景下,其抗干扰能力仍有待进一步提升。2026 年林等人[7]针对小目标位置敏感问题,将边界框建模为高斯分布并引入几何距离度量,有效

缓解了微小位置偏差导致的指标下降问题,然而该方法尚未在超低延迟的轻量化架构中得到充分验证。2024 年赵等人[8]提出了一种基于最新 YOLO 框架的轻量化检测模型,通过引入深度可分离卷积模块大幅减少了参数量,并利用动态聚焦机制优化了回归精度,然而该模型在极端微小目标特征提取上的细粒度仍显不足。2025 年王等人[9]针对印刷电路板混合缺陷检测问题开发了增强型目标检测模型,在保持较高召回率的同时实现了较低的浮点运算量,但其特征聚合网络对触控屏柔性材料复杂背景的抗干扰能力尚未得到充分验证。

为了克服上述微小缺陷检测精度与计算开销之间的矛盾,本研究提出了一种基于改进 YOLOv10 架构的轻量化、高精度缺陷检测框架。该方法对特征提取、上采样和损失优化范式进行优化,以专门针对 TP 检测的需求。本文的主要贡献总结如下:

(1) 主干网络的轻量化。本文引入部分卷积即 PConv 重构特征提取主干网络。利用空间冗余性,PConv 仅对部分通道执行卷积,大幅降低了浮点运算量与内存访问成本,在不牺牲感受野的前提下实现了工业级轻量化部署[10]。

(2) 动态高分辨率特征恢复。为了缓解标准插值方法导致的微小元器件语义模糊问题,本文使用动态上采样即 DySample 替换常规上采样模块。DySample 根据输入特征图生成动态的点采样偏移量,从而精细地重建了高密度目标例如 FPC 引脚的结构边缘,并增强了网络对局部微小异常的感知能力[11]。

(3) 基于分布的微小目标度量。本文引入归一化 Wasserstein 距离即 NWD 替代 IoU 损失。通过将边界框建模为二维高斯分布,该方法在零重叠时仍能平滑惩罚定位误差,显著加速模型收敛并提升极端微小缺陷召回率[12]。

## 2. PDN-YOLO 检测算法

### 2.1. PDN-YOLO

YOLOv10 是单阶段目标检测模型中的主流算法,在触控屏表面缺陷检测的初步测试中,YOLOv10s 模型在检测精度与检测速度之间取得了较好的平衡[13]。考虑到该模型能较好地适配工业边缘设备的算力限制与低延迟要求,本研究将其选定为基础网络并进行针对性优化。




Figure 1. Overall architecture of PDN-YOLO

图 1. PDN-YOLO 总框架

为提升检测精度, YOLOv10 在主干与颈部网络引入了大量跨阶段局部融合 C2f 模块, 在增强特征表达的同时加剧了计算负担。此外, 在应对触控屏表面柔性印制电路板引脚与微型集成电路等微小尺度缺陷时, 该模型往往因连续下采样而丢失高频特征, 导致细节捕捉能力受限[14]。因此, 为满足实际工业检测需求, 仍需针对触控屏缺陷的特点对模型进行改进, 以更好地捕捉细微边缘并提升检测性能。

针对工业边缘部署中高精度与低时延的实际需求, 以及触控屏表面疵点尺度小、对比度低且背景复杂的难点, 本文以 YOLOv10s 为基准, 提出了一种轻量化实时缺陷检测算法——PDN-YOLO, 其整体结构如图 1 所示。首先, 在颈部网络中使用部分卷积(PConv)替换原有的部分 C2f 模块, 在保持深层感受野的同时有效降低了模型计算量。其次, 采用轻量级动态上采样模块(DySample)替换最近邻上采样, 将采样点自适应聚焦于目标特征区域, 有效抑制复杂背景干扰, 强化了边缘细节提取并减少漏检。最后, 在预测头引入归一化 Wasserstein 距离(NWD)替代常规交并比损失, 缓解了传统损失对微小目标位置偏差的过度敏感问题, 显著提升了模型对极端微小缺陷的回归定位精度与整体召回率。

## 2.2. 基于 PConv 的轻量化特征提取

在触控屏生产线的实时检测任务中, 工业边缘设备存在着计算资源有限与高分辨率输入带来的高计算负载的矛盾。传统的卷积神经网络在处理高维特征图时, 往往伴随着严重的通道间信息冗余, 难以满足实时性要求[15]。为了提升检测效率, 本文引入部分卷积即 PConv 并改进了跨阶段局部融合模块, 提出 C2f\_PConv 结构, 如图 2 所示。




Figure 2. Structure of PConv module

图 2. PConv 结构图

PConv 的核心思想是利用特征图的空间冗余, 仅对输入通道的一部分执行卷积运算。设输入特征图为  $X \in \mathbb{R}^{C \times H \times W}$ , PConv 算子将输入通道划分为两个部分: 执行空间卷积的活跃通道  $c_p$  以及保持原样透传的冗余通道  $C - c_p$ , 本文设定  $n_{div} = 4$ , 即  $c_p = C/4$ 。其运算逻辑可表示为:

$$x_1, x_2 = \text{Split}(X), \quad x_1 \in \mathbb{R}^{c_p \times H \times W}, \quad x_2 \in \mathbb{R}^{(C-c_p) \times H \times W} \quad (1)$$

$$Y = \text{Concat}(\text{Conv}_{3 \times 3}(x_1), x_2) \quad (2)$$

这使得 PConv 的浮点运算量仅为标准卷积的 1/16, 有效缓解了工业计算设备的内存访问压力。

为了进一步提升特征提取的非线性表征能力, 本文构建了 FasterBlock 作为基本残差单元, 并将其集成至 C2f 结构中。FasterBlock 由 PConv 层与由两层  $1 \times 1$  积组成的 MLP 层级联组成, 其数学映射关系为:

$$X_{\text{mid}} = \text{PConv}(X) \quad (3)$$

$$X_{\text{out}} = X + \text{Conv}_{1 \times 1} \left( \text{GELU} \left( \text{BN} \left( \text{Conv}_{1 \times 1} (X_{\text{mid}}) \right) \right) \right) \quad (4)$$

在此基础上, C2f\_PConv 模块利用跨阶段连接策略, 通过初级卷积进行通道分流, 并将 FasterBlock 生成的各级特征图进行拼接, 这种多分支梯度流设计在保持模型轻量化的同时, 增强了对复杂缺陷特征的提取能力[16]:

$$y = \text{Split}(\text{Conv}_{1 \times 1}(x), 2) \quad (5)$$

$$y_{\text{list}} = [y_0, y_1, \mathcal{M}_1(y_1), \dots, \mathcal{M}_n(y_n)] \quad (6)$$

$$\text{Output} = \text{Conv}_{1 \times 1}(\text{Concat}(y_{\text{list}})) \quad (7)$$

其中  $\mathcal{M}$  代表 FasterBlock 算子。该架构通过引入部分卷积, 在保持较高缺陷检测所需的深度感受野的同时, 降低了模型参数量与部署成本。

### 2.3. 基于 DySample 的动态高分辨率特征采样

在触控屏电子元件等精密组件的缺陷检测中, 微小目标易受到复杂背景的干扰。YOLOv10s 的 Neck 部分默认采用最近邻或双线性插值, 这种静态采样方式难以捕捉图像局部的结构变化, 易造成信息损失。此外, 传统的特征融合网络在处理非相邻层级的语义鸿沟时, 往往存在对齐偏差[17]。因此, 本文采用轻量级动态上采样模块 DySample, 通过特征引导的自适应采样机制, 更好地保留了微小缺陷的边缘细节。




Figure 3. Flowchart of DySample module

图 3. DySample 流程图

如图 3 所示, DySample 的核心机制是引导网络自发学习每个像素点的最优采样位置。设输入特征图为  $X \in \mathbb{R}^{B \times C \times H \times W}$ , 为了限制模型参数量并提升检测速度, 模块将通道划分为  $g$  个独立组并进行处理。特征图首先会经过一个轻量级的映射层, 用于预测初始空间偏移量, 同时引入阻尼因子  $\alpha$  对初始方差进行动态调节, 从而有效避免网络在训练初期的梯度震荡与坐标形变失真。该过程表示为:

$$O_{\text{pred}} = \mathcal{F}_{\text{offset}}(X) \cdot \alpha \quad (8)$$

为了使初始采样点在特征空间均匀分布, 模型首先构建了一个归一化的基础坐标阵列  $P_{\text{init}} \in \mathbb{R}^{1 \times s^2 \times 2}$ 。接着, 将预测偏移量与基础坐标相加, 生成涵盖组维度的最终偏移场  $O_{\text{final}}$ :

$$O_{\text{final}} = \text{Reshape}(O_{\text{pred}}) + P_{\text{init}} \quad (9)$$

在获得预测偏移量后, 网络将低分辨率特征图映射到高分辨率输出空间。该过程基于预设的基础二维网格  $G_{\text{base}} \in \mathbb{R}^{H \times W \times 2}$  实现。通过将最终偏移场乘以预设的上采样尺度因子  $S$ , 并叠加到基础网格上, 从而得到采样坐标的高精度绝对定位:

$$G_{\text{sample}} = G_{\text{base}} + O_{\text{final}} \cdot S \quad (10)$$

为了符合空间变换函数的定义域要求, 坐标被归一化至  $[-1, 1]$  区间。随后, 通过双线性采样算子  $\psi$  提取像素特征。输入张量  $X$  经过重组以实现与采样坐标维度的对齐, 最终输出上采样特征  $Y$ :

$$Y = \psi(\text{Reshape}(X), G_{\text{sample}}) \quad (11)$$

基于网格采样的动态空间变换有效抑制了伪影的生成[18], 在几乎不增加整体浮点运算量的情况下, 自适应地将感受野聚焦于缺陷结构的密集高频区域, 显著增强了对微小缺陷边界的特征提取能力。

#### 2.4. 基于归一化 Wasserstein 距离的微小目标度量

在触控屏表面缺陷检测中, 微小缺陷如锡球飞溅或泡棉的像素面积占比低。传统的交并比损失函数对微小目标的定位偏差极其敏感。当预测框与真实框发生轻微的像素级偏移时, 交并比数值会出现剧烈下降甚至直接归零, 导致网络在训练过程中丢失梯度信息并陷入局部最优解。为了缓解传统损失函数对微小位置偏差的过度惩罚问题, 本文在预测头阶段引入归一化 Wasserstein 距离度量机制, 替代传统的交并比损失函数。




Figure 4. Structure of NWD module

图 4. NWD 结构图

如图 4 所示, 该度量机制的核心思想是将离散的矩形边界框转化为连续的概率分布模型。对于任意给定的边界框, 设其中心坐标为  $cx$  与  $cy$ , 宽度为  $w$ , 高度为  $h$ 。该边界框的内切椭圆可被严密地建模为一个二维高斯分布  $\mathcal{N}(\mu, \Sigma)$ 。其中, 均值向量  $\mu$  决定了分布的空间中心位置, 协方差矩阵  $\Sigma$  决定了分布的空间尺度范围。其数学表达形式为:

$$\mu = \begin{bmatrix} cx \\ cy \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \frac{w^2}{4} & 0 \\ 0 & \frac{h^2}{4} \end{bmatrix} \quad (12)$$

通过这种连续化建模, 即便预测框与真实框在空间上呈现零重叠状态, 其对应的两个高斯分布之间依然存在平滑的概率密度重叠, 从而为网络参数的优化提供稳定的梯度反向传播路径。

设预测边界框对应的高斯分布为  $\mathcal{N}_1(\mu_1, \Sigma_1)$ , 真实边界框对应的高斯分布  $\mathcal{N}_2(\mu_2, \Sigma_2)$ 。两者之间的二阶 Wasserstein 距离平方  $W_2^2$  包含中心点偏差与几何形状偏差两个独立的度量分量。根据最优传输理论,

其距离计算公式被展开为：

$$W_2^2(N_1, N_2) = \|\mu_1 - \mu_2\|_2^2 + \text{Tr}\left(\Sigma_1 + \Sigma_2 - 2\left(\Sigma_1^{1/2}\Sigma_2\Sigma_1^{1/2}\right)^{1/2}\right) \quad (13)$$

基于对角协方差矩阵的特殊性质，上述迹运算可进一步简化。两框之间的绝对距离被精确分解为中心坐标的欧氏距离与宽高维度的尺度惩罚项：

$$W_2^2 = (cx_1 - cx_2)^2 + (cy_1 - cy_2)^2 + \frac{(w_1 - w_2)^2 + (h_1 - h_2)^2}{4} \quad (14)$$

由于 Wasserstein 距离本质上属于无上界的绝对空间距离度量，无法直接作为类似交并比的尺度不变相似性指标。因此，本文引入指数惩罚函数对其进行非线性归一化映射。为适配触控屏微小元器件的像素尺度，模型引入经验常数  $C$  调节分布的平滑度。最终的归一化 Wasserstein 距离定义如下：

$$\text{NWD} = \exp\left(-\frac{\sqrt{W_2^2 + \epsilon}}{C}\right) \quad (15)$$

其中  $\epsilon$  为防止数值计算溢出的极小常量。该机制使得模型在面对高频模糊与微小偏移时，依然能够输出平滑的定位惩罚值，提升了极端微小缺陷的召回率与整体检测精度[19]。

### 3. 实验与分析

#### 3.1. 实验环境配置与数据集

表 1 展示了所有模型所采用的训练平台及超参数配置。在本实验中，全部模型均基于 PyTorch 深度学习框架完成训练与测试，并使用 Python 语言实现数据集构建、模型评估、预测及结果可视化等相关功能。

**Table 1.** Experimental environment configuration  
**表 1.** 实验环境配置

| 配置            | 具体参数                                  |
|---------------|---------------------------------------|
| 操作系统          | Windows11 25H2                        |
| CPU           | 13th Gen Intel(R) Core(TM) i9-13900HX |
| 显卡            | GeForce RTX 4070                      |
| 显存            | 8 G                                   |
| 内存            | 16 G                                  |
| 深度学习框架        | Pytorch 2.5.0                         |
| Opencv-Python | 4.13.0                                |
| CUDA 版本       | 11.8                                  |
| CUDNN         | 9.1.0                                 |
| 编程语言          | Python3.10                            |

本文数据集采集自国内某显示屏制造企业的量产车间，依托产线定制的 AOI 外观检测设备进行实时获取。针对触控屏缺陷微小、背景纹理复杂且材质易反光等成像难点，如图 5 所示的硬件布置，本实验对采集设备进行了针对性配置：




Figure 5. Schematic diagram of light source setup  
图 5. 光源示意图


在相机选型上，为满足不低于两千万像素的成像分辨率需求，实验采用了 OPT-CCM20-GR10 型工业相机。该设备分辨率达  $5472 \times 3648$ ，成像精度为  $0.031 \text{ mm/pixel}$ ，充分保障了微小斑点的高保真采集。考虑到高像素相机对边缘畸变极为敏感，实验为其匹配了焦距为  $35 \text{ mm}$  的 OPT-CZP3528 工业镜头。这一搭配有效避免了视野边缘的缺陷形态失真，确保了图像全局特征的几何一致性。此外，针对玻璃基板与柔性电路板极易产生的镜面反射现象，实验选用了 OPT-FLZ330330KW 与 OPT-RIZ27270W-V1 白色散射 LED 组合光源。其多角度散射设计能有效抑制局部强光干扰，在维持整体照度的同时，显著增强了微弱缺陷与复杂背景的图像对比度。

受工业现场对产品良率的严格把控，初始采集的含显著斑点的样本数量有限，共计 381 幅高分辨率图像。该原始数据集涵盖了如表 2 所示的八类典型表面与装配缺陷。此类缺陷不仅尺度极其微小，且常与背景纹理高度融合，对特征提取构成了严峻挑战。

Table 2. Eight typical defect categories  
表 2. 八类典型缺陷

| 序号 | 检测项目    | 检测需求                  |
|----|---------|-----------------------|
| 1  | 粘膜纸     | 粘膜纸有无；是否在特定范围内。       |
| 2  | 喷码      | 喷码的信息是否清晰正确；是否在特定范围内。 |
| 3  | 泡棉      | 厚度是否达标；是否提供有效保护。      |
| 4  | 元器件     | 元器件是否损坏；确保符合设计规范。     |
| 5  | 标签纸     | 标签纸是否完整；是否在特定范围内。     |
| 6  | FPC 连接器 | FPC 连接器检测外围尺寸是否正常。    |
| 7  | 包边纸和保护纸 | 包边纸和保护纸是否完整；是否在特定区域内。 |
| 8  | 锡球喷溅    | 球喷溅是否存在，是否在特定范围内。     |

考虑到原始数据集样本相对不足，训练时易产生过拟合，本文通过添加高斯噪声、椒盐噪声、多角度随机运动模糊以及多重干扰混合等离线增强方式对数据集进行扩充。经上述处理后，数据集扩充至 1510 张高质量图像。



**Figure 6.** Schematic diagram of augmented images  
**图 6.** 扩充图像示意图

首先将数据按 8:2 的比例随机划分为相互独立的训练集与验证集，然后进行上述扩充至 1510 张。数据增强显著提升了样本特征的多样性，有助于深层网络对复杂背景下微小目标的特征学习与泛化。原始缺陷图像及其对应的增强图像如图 6 所示。

### 3.2. 实验参数设置与评价指标

根据实验硬件条件，本文设定了合适的超参数进行训练，具体设置如表 3 所示。为防止模型对固定批次数据的记忆依赖，实验在数据加载阶段启用了在线动态数据增强机制，实时提升模型对复杂目标形变的尺度不变性。同时，为公平比较各模型在触控屏上的检测性能，所有模型均从零开始训练，不使用预训练权值。

**Table 3.** Experimental hyperparameter settings  
**表 3.** 实验超参数设置

| Parameters | 参数        |
|------------|-----------|
| 输入图片尺寸     | 640 × 640 |
| 动量         | 0.937     |
| 权重衰减系数     | 0.0005    |
| 参数学习率      | 0.01      |
| 迭代次数       | 250       |
| 批样本大小      | 8         |

本文从检测精度与模型部署复杂度两个维度对算法进行量化评估。在检测精度方面，选取的评价指标包括精确率(P)、召回率(R)、平均精度(mAP@0.5)，以及考核更为严苛的平均精度均值(mAP@[0.5:0.95])。在模型部署复杂度方面，主要考察算法的总参数量(Params)与单图检测速度，分别反映模型的内存占用与实际检测速度。

### 3.3. 部分卷积模块的空间位置敏感性分析

为了评估部分卷积模块在网络结构中的最优部署位置，本文在基线模型的基础上设计了四组对比实验。实验分别将主干特征提取网络、颈部特征融合网络以及上述两处的传统卷积层替换为部分卷积模块。除替换位置不同外，各组实验的其余组件与超参数均保持严格一致，实验结果如表 4 所示。

表 4 数据显示，若对主干与颈部网络进行双重 PConv 替换，虽然单图检测耗时缩短至 5.2 ms，但 mAP@[0.5:0.95]却退化至 84.5%。这表明在浅层主干网络过度删减计算量会破坏底层纹理特征的提取能力，导致全局精度受损。相比之下，仅在颈部特征融合网络引入 PConv 模块时，算法的精确率与召回率

均达到最优，mAP@[0.5:0.95]提升至 85.5%，同时参数量降至 7.47 M，单图耗时缩短为 5.9 ms。因此，本文最终决定仅在颈部网络采用该轻量化策略，在有效降低模型复杂度的同时兼顾了检测精度的提升。

**Table 4.** Impact of PConv optimization position on algorithm performance  
**表 4.** PConv 优化位置对算法的影响

| 实验 | Backbone | Neck | P (%) | R (%) | mAP@0.5 (%) | mAP@[0.5:0.95] (%) | Params/M | Latency/ms |
|----|----------|------|-------|-------|-------------|--------------------|----------|------------|
| 1  |          |      | 95.9  | 97.7  | 98.5        | 85.0               | 8.04     | 6.9        |
| 2  | √        |      | 95.7  | 96.5  | 98.3        | 85.2               | 8.36     | 5.7        |
| 3  |          | √    | 96.3  | 97.7  | 98.4        | 85.5               | 7.47     | 5.9        |
| 4  | √        | √    | 96.2  | 97.5  | 98.0        | 84.5               | 6.86     | 5.2        |

3.4. 动态上采样模块的空间位置敏感性分析

表 5 的位置消融实验表明，若在特征融合网络的第 11 与第 14 层同时部署动态上采样模块，mAP@[0.5:0.95]由基线的 85.0%退化至 84.7%，且检测耗时为 6.5 ms。这说明对深层低分辨率特征使用动态插值不仅徒增计算冗余，还会削弱特征的判别力。相比之下，当仅在通向高分辨率探测头的第 14 层部署该模块时，mAP@[0.5:0.95]显著提升至 86.5%。这种在浅层高分辨率分支引入动态采样的策略，有效增强了算法对微小缺陷边缘的表征能力。因此，本文最终决定仅在第 14 层单独应用动态上采样机制，以实现检测精度与效率的最佳平衡。

**Table 5.** Impact of DySample optimization position on algorithm performance  
**表 5.** DySample 优化位置对算法的影响

| 实验 | Deployment Strategy | P (%) | R (%) | mAP@0.5 (%) | mAP@[0.5:0.95] (%) | Params/M | Latency/ms |
|----|---------------------|-------|-------|-------------|--------------------|----------|------------|
| 1  | Original Baseline   | 95.9  | 97.7  | 98.5        | 85.0               | 8.04     | 6.9        |
| 2  | Layer 14            | 96.1  | 99.0  | 98.5        | 86.5               | 8.93     | 7.0        |
| 3  | Layer 11 & 14       | 95.3  | 98.3  | 97.9        | 84.7               | 8.95     | 6.5        |

3.5. 消融实验

为进一步分析各改进模块在算法中的贡献与效果，本文通过消融实验进行验证，结果如表 6 所示。

**Table 6.** Comparison of ablation experiment results  
**表 6.** 消融实验结果对比

| 实验 | PConv | DySample | NWD LOSS | mAP@0.5 (%) | mAP@[0.5:0.95] (%) | Latency/ms |
|----|-------|----------|----------|-------------|--------------------|------------|
| 1  |       |          |          | 98.5        | 85.0               | 6.9        |
| 2  | √     |          |          | 98.4        | 85.5               | 5.9        |
| 3  |       | √        |          | 98.5        | 86.5               | 7.0        |
| 4  |       |          | √        | 98.6        | 86.2               | 6.9        |
| 5  | √     | √        |          | 98.0        | 86.0               | 6.2        |
| 6  | √     |          | √        | 98.2        | 86.3               | 5.8        |
| 7  |       | √        | √        | 98.5        | 86.4               | 6.2        |
| 8  | √     | √        | √        | 99.0        | 87.1               | 5.9        |

结果显示, PConv 与 NWD 损失二者结合可有效降低模型的复杂度, 增强细粒度特征的提取能力[20]。实验 7 充分验证了两个模块间的协同增益效应, 同步强化模型对微弱目标的检测能力。根据多组实验结果, 实验 8 集成所有改进模块的最终算法, 较原始基准模型 mAP@[0.5:0.95]达到 87.1%的精度, 同时检测速度稳定在 5.9 ms, 较基准提速约 14.5%, 在检测精度与检测速度上均实现突破, 有望实现工业场景微弱目标的高精度实时自动检测需求。

### 3.6. 特征可视化分析

为了更直观地验证本文所提 PConv 和 DySample 模块在触控屏微小缺陷检测中的有效性, 本文利用特征激活图对网络中间层的输出进行了可视化对比分析。特征图中的颜色越偏向深红色, 代表网络对该区域的特征响应越强烈; 颜色越偏向深蓝色, 则代表特征响应被抑制。

#### 3.6.1. PConv 模块有效性验证

引入 PConv 模块前后的特征激活对比如图 7 所示。基线模型由于触控屏背景复杂, 产生了大量空间冗余, 导致背景区域出现明显的黄绿色干扰响应。改进后的网络利用空间冗余性大幅过滤背景噪点, 使背景区域的无效响应显著降至深蓝色, 而强响应则精准锁定在 FPC 连接器和微小元器件上。这证实了 PConv 在轻量化的同时, 具有优秀的背景抗干扰和特征聚焦能力。




Figure 7. Comparison of feature activation maps of the PConv module

图 7. PConv 模块特征激活图对比

#### 3.6.2. DySample 模块有效性验证

动态上采样模块 DySample 的边缘恢复效果如图 8 所示。传统静态插值在上采样时容易造成高频信息扩散, 导致基线模型的特征边界模糊。采用 DySample 模块后, 网络通过自适应采样机制精细重建高频区域, 使 FPC 引脚及精密组件的轮廓呈现出清晰、连续的深红色聚焦响应。这表明 DySample 能够有效缓解微小目标的语义模糊, 大幅提升边缘细节的表征能力。




Figure 8. Comparison of feature activation maps of the DySample module

图 8. DySample 模块特征激活图对比

3.7. 对比实验与泛化性分析

为全面评估算法的综合性能，表 7 展示了 PDN-YOLO 与当前主流目标检测算法在同等实验环境下的对比结果。受限于庞大的参数规模，Faster R-CNN 与 DETR 等重型网络的单图前向检测耗时均超过 26.0 ms。由于在捕捉微弱局部纹理时易发生特征流失与尺度不匹配，这类模型在严苛的 mAP@[0.5:0.95]指标上最高仅有 77.3%。相比之下，本文提出的 PDN-YOLO 在维持 8.2 M 轻量级参数的同时，将单图检测时间压缩至 5.9 ms，充分满足了工业现场的高实时性需求。同时，该模型在 mAP@[0.5:0.95]这一核心指标上达到了 87.1%的最优水平，较基线 YOLOv10s 提升了 2.1 个百分点。综上所述，PDN-YOLO 在触控屏微小缺陷检测任务中展现出了突出的综合优势，实现了精度与速度的有效平衡。

Table 7. Performance comparison of different algorithms  
表 7. 不同算法性能对比

| 模型          | Params/M | mAP@0.5 (%) | mAP@[0.5:0.95] (%) | Latency/ms |
|-------------|----------|-------------|--------------------|------------|
| FasterR-cnn | 44.6     | 86.8        | 66.1               | 26.4       |
| DETR        | 41.3     | 99.0        | 75.3               | 26.7       |
| RT-DETR     | 36.4     | 98.7        | 77.3               | 28.5       |
| YOLOv10s    | 8.04     | 98.5        | 85.0               | 6.9        |
| PDN-YOLO    | 8.2      | 99.0        | 87.1               | 5.9        |

为评估多维数据增强策略对模型泛化能力的提升效果，本文将原始测试集进行增强，在相应的测试集上进行鲁棒性实验。实验结果如表 8 所示，模型在原始图像(ORIGIN)上的 mAP@[0.5:0.95]为 87.1%。在引入高斯噪声(GAUSS)与椒盐噪声(SP)的情况下，该指标分别保持在 86.9%与 87.2%，未出现显著波动；在边缘高频信息受损的模糊(BLUR)与混合退化(MIX)场景中，小幅下降至 85.9%与 86.4%。

Table 8. Robustness evaluation  
表 8. 鲁棒性评估

| Test Environment | P (%) | R (%) | mAP@0.5 (%) | mAP@[0.5:0.95] (%) |
|------------------|-------|-------|-------------|--------------------|
| ORIGIN           | 96.0  | 98.9  | 99.0        | 87.1               |
| BLUR             | 99.2  | 98.9  | 99.1        | 85.9               |
| GAUSS            | 99.0  | 98.3  | 99.2        | 86.9               |
| SP               | 99.4  | 99.2  | 99.2        | 87.2               |
| MIX              | 98.5  | 98.9  | 99.0        | 86.4               |

此外，在上述退化场景中，模型的精确率稳定在 98.5%以上，整体表现甚至优于原始环境。这说明数据增强策略发挥了实质性作用：训练中引入的复杂噪声迫使网络降低了对清晰背景纹理的依赖，成功将缺陷特征与环境干扰解耦。同时，这种混合数据训练机制并未引发过拟合，而是将噪声转化为隐式的正则化条件，有效过滤了容易导致误检的杂乱纹理[21]。上述结果表明，本文所提方法使模型具备了抵挡不同噪声分布的特征提取能力，在复杂多变的工业视觉场景中表现出较高的应用可靠性。

3.8. 模型训练收敛性与综合评估曲线分析

为验证 PDN-YOLO 模型的训练稳定性与特征学习能力，本文绘制了模型在整个训练周期内的损失函

数变化轨迹与多维精度评估曲线如图 9 所示。从损失函数曲线图像可以看出，模型的边界框回归损失与分类损失在训练初期下降较快，并在约两百个迭代周期后逐渐趋于稳定。整个训练过程未出现明显的震荡或发散现象，这表明优化算法在特征空间中进行了有效的运算，模型展现出良好的收敛性与训练稳定性。此外，从多维精度评估曲线可得，模型的精确率、召回率以及平均精度均值在训练初期迅速提高，并在后续迭代处于高位，无明显回落现象，进一步证明了模型具备优异的目标检测性能与特征泛化能力。




Figure 9. Curves of loss function and evaluation metrics  
图 9. 损失函数和评价指标曲线图

3.9. 各类别缺陷检测性能精细化评估

表 9 展示了模型对八类典型缺陷的细粒度检测结果。PDN-YOLO 的总体  $mAP@0.5$  与  $mAP@[0.5:0.95]$  分别达到 99.0%和 87.1%，且各缺陷类别的  $mAP@0.5$  均保持在 97.5%以上，证明模型在复杂工业背景下具备优异的特征辨识能力，能有效控制漏检与误检。从具体类别来看，对比度高且轮廓清晰的“泡棉”和“标签纸”取得了 97.1%与 92.1%的较高  $mAP@[0.5:0.95]$ 得分。相比之下，“粘膜纸”因呈半透明状易与柔性板基材混叠，而“FPC 连接器”含有密集微小的金属引脚。由于这两类缺陷对边界回归精度的要求更为苛刻，其对应指标分别回落至 81.0%与 81.1%。

Table 9. Detection results of eight typical defect categories  
表 9. 八类典型缺陷检测结果

| Class   | P (%) | R (%) | $mAP@0.5$ (%) | $mAP@[0.5:0.95]$ (%) |
|---------|-------|-------|---------------|----------------------|
| all     | 96.0  | 99.0  | 99.0          | 87.1                 |
| 锡球喷溅    | 97.4  | 99.6  | 99.5          | 86.1                 |
| 喷码      | 96.1  | 98.6  | 99.5          | 85.5                 |
| 泡棉      | 94.7  | 100   | 99.5          | 97.1                 |
| 包边纸和保护纸 | 96.7  | 98.9  | 99.0          | 88.0                 |
| 标签纸     | 93.5  | 96.9  | 98.5          | 92.1                 |
| 元器件     | 97.2  | 99.3  | 98.7          | 86.2                 |
| 粘膜纸     | 96.2  | 98.3  | 97.5          | 81.0                 |
| FPC 连接器 | 96.0  | 100   | 99.5          | 81.1                 |

图 10 展示了模型在实际检测背景下的检测结果。在面临金属反光、密集排线及材质纹理交叠等干扰时，PDN-YOLO 仍能较好地实现多尺度缺陷的边界框回归。尤其在处理特征不显著的“粘膜纸”和“锡球喷溅”时，模型分别输出了 0.89 与 0.88 的预测置信度；而对于特征显著的“泡棉”，置信度达 0.96。上述结果与定量指标相吻合，证实 PDN-YOLO 具备较强的跨尺度适应能力与鲁棒性，符合实际工业检测的高精度需求。




Figure 10. Detection results  
图 10. 检测结果

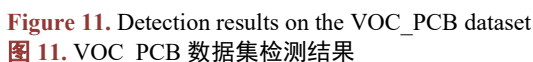
3.10. 公开数据集泛化性能验证

为了进一步检验模型在复杂色彩背景及跨领域场景下的泛化性能，本文引入北京大学智能机器人开放实验室的全彩 PCB 公开数据集进行测试。该数据集具有鲜艳的绿色背景和密集的金属布线，包含漏孔、鼠咬、开路等六类细微缺陷，对算法的抗干扰与细粒度特征提取能力提出了更高要求。

定量测试结果如表 10 所示。面对复杂的绿色背景干扰，PDN-YOLO 模型展现出卓越的鲁棒性，全类 mAP@0.5 达 98.6%，精确率与召回率分别达到 97.7%和 96.5%。此外，图 11 的实际检测效果表明，即使在密集的焊盘等高频背景边缘干扰下，模型依然能对漏孔、伪铜等极微小缺陷实现高置信度的精准定位。这一跨领域验证充分证明，本文提出的模型在广泛的电子元器件微弱疵点检测任务中具备通用性。

Table 10. Defect detection results on the VOC\_PCB dataset  
表 10. VOC\_PCB 数据集缺陷检测结果

| Class           | Images | Instances | Box (P) | R     | mAP@0.5 | mAP@[0.5:0.95] |
|-----------------|--------|-----------|---------|-------|---------|----------------|
| all             | 267    | 534       | 0.977   | 0.965 | 0.986   | 0.728          |
| missing_hole    | 267    | 88        | 0.960   | 0.989 | 0.993   | 0.725          |
| mouse_bite      | 267    | 93        | 0.979   | 984   | 0.994   | 0.765          |
| open_circuit    | 267    | 104       | 0.989   | 0.962 | 0.994   | 0.741          |
| short           | 267    | 74        | 1       | 0.941 | 0.985   | 0.747          |
| spur            | 267    | 97        | 0.948   | 0.948 | 0.964   | 0.700          |
| spurious_copper | 267    | 78        | 0.987   | 0.969 | 0.991   | 0.687          |



本文针对触控屏组件表面缺陷尺度较小、对比度低且易与柔性电路背景混淆等检测难点，提出了一种基于改进 YOLOv10s 架构的缺陷检测算法 PDN-YOLO。首先，引入部分卷积 PConv 对颈部特征融合网络进行轻量化重构。该策略通过利用特征图的空间冗余性，在保留深层感受野的前提下，实现了前向传播中计算量与内存访问成本的有效降低。其次，采用动态上采样模块 DySample 替代静态几何插值算子。该机制引导网络将采样空间聚焦于缺陷的边缘区域，改善了复杂背景噪声的干扰问题，较好地还原了微小元器件的轮廓。最后，在预测端引入归一化 Wasserstein 距离 NWD 损失函数。通过将离散的边界框建模为连续的高斯分布，缓解了传统交并比损失对微小位置偏差敏感的度量问题，进一步增强了网络对微弱目标的定位能力。

## 基金项目

## 参考文献

- DOI: 10.12677/csa.2026.167251

- for Defect Detection in Industrial Applications. *IEEE Access*, **12**, 94250-94295. <https://doi.org/10.1109/access.2024.3425166>
- [5] Tang, J., Liu, S., Zhao, D., Tang, L., Zou, W. and Zheng, B. (2023) PCB-YOLO: An Improved Detection Algorithm of PCB Surface Defects Based on YOLOv5. *Sustainability*, **15**, Article 5963. <https://doi.org/10.3390/su15075963>
  - [6] Gong, L., Chen, H., Chen, Y., Yao, T., Li, C., Zhao, S., *et al.* (2025) DPNet: Dynamic Pooling Network for Accurate and Efficient Size-Aware Tiny Object Detection. *IEEE Internet of Things Journal*, **12**, 26387-26400. <https://doi.org/10.1109/jiot.2025.3559921>
  - [7] Lin, S., Zhong, L., Chen, S. and Wang, D. (2026) Tiny Object Detection via Normalized Gaussian Label Assignment and Multi-Scale Hybrid Attention. *Remote Sensing*, **18**, Article 396. <https://doi.org/10.3390/rs18030396>
  - [8] Zhao, S., Chen, J. and Ma, L. (2024) Subtle-YOLOv8: A Detection Algorithm for Tiny and Complex Targets in UAV Aerial Imagery. *Signal, Image and Video Processing*, **18**, 8949-8964. <https://doi.org/10.1007/s11760-024-03520-7>
  - [9] Wang, Y., Wu, B., Zhang, L., Wang, Z., Liu, J., Dong, J., *et al.* (2025) Enhanced PCB Defect Detection via HSA-RTDETR on RT-DETR. *Scientific Reports*, **15**, Article No. 31783. <https://doi.org/10.1038/s41598-025-11394-z>
  - [10] Chen, J., Kao, S., He, H., Zhuo, W., Wen, S., Lee, C., *et al.* (2023) Run, Don't Walk: Chasing Higher FLOPS for Faster Neural Networks. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Vancouver, 17-24 June 2023, 12021-12031. <https://doi.org/10.1109/cvpr52729.2023.01157>
  - [11] Liu, W., Lu, H., Fu, H. and Cao, Z. (2023) Learning to Upsample by Learning to Sample. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV)*, Paris, 1-6 October 2023, 6004-6014. <https://doi.org/10.1109/iccv51070.2023.00554>
  - [12] Xu, C., Wang, J., Yang, W., Yu, H., Yu, L. and Xia, G. (2022) Detecting Tiny Objects in Aerial Images: A Normalized Wasserstein Distance and a New Benchmark. *ISPRS Journal of Photogrammetry and Remote Sensing*, **190**, 79-93. <https://doi.org/10.1016/j.isprsjprs.2022.06.002>
  - [13] Hu, H.Y., Tong, J.W., Wang, H.B. and Lu, X.Y. (2025) EAD-YOLOv10: Lightweight Steel Surface Defect Detection Algorithm Research Based on YOLOv10 Improvement. *IEEE Access*, **13**, 55382-55397. <https://doi.org/10.1109/access.2025.3552683>
  - [14] 王海涛, 艾晨, 谭福, 高硕. 面向遥感小目标检测的实例间特征聚合方法研究[J]. 宇航学报, 2025, 46(7): 1467-1474.
  - [15] 邓文斌, 郭怡希, 林源强, 等. PCB-YOLO: 改进 YOLOv8n 的 PCB 微小缺陷轻量化检测方法[J]. 光电工程, 2026, 53(2): 134-151.
  - [16] Li, Y., Xu, S., Zhu, Z., Wang, P., Li, K., He, Q., *et al.* (2023) EFC-YOLO: An Efficient Surface-Defect-Detection Algorithm for Steel Strips. *Sensors*, **23**, Article 7619. <https://doi.org/10.3390/s23177619>
  - [17] Wang, J., Chen, K., Xu, R., Liu, Z., Loy, C.C. and Lin, D. (2022) CARAFE++: Unified Content-Aware Reassembly of Features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **44**, 4674-4687.
  - [18] Wang, Q., Yang, L., Zhou, B., Luan, Z. and Zhang, J. (2023) YOLO-SS-Large: A Lightweight and High-Performance Model for Defect Detection in Substations. *Sensors*, **23**, Article 8080. <https://doi.org/10.3390/s23198080>
  - [19] Jia, L., Chen, Y., Zhang, S., Liang, X. and Lu, J. (2025) YOLO-BiNWD: Small Object Detection Algorithm for Screen Defect Based on Improved YOLOv10. *Journal of Computers*, **36**, 97-112. <https://doi.org/10.63367/199115992025083604007>
  - [20] Shen, P., Mei, K., Cao, H., Zhao, Y. and Zhang, G. (2025) LDDFSF-YOLO11: A Lightweight Insulator Defect Detection Method Focusing on Small-Sized Features. *IEEE Access*, **13**, 90273-90292. <https://doi.org/10.1109/access.2025.3569970>
  - [21] 董庆宽, 何浚霖. 基于信息瓶颈的深度学习模型鲁棒性增强方法[J]. 电子与信息学报, 2023, 45(6): 2197-2204.