

# LIDD-Net: 基于深度学习的轻量级工业产品缺陷检测方法

沙晓鹏, 谢德瀚, 郭周鹏, 孙凯

(东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004)

**摘要:** 工业产品中存在各种缺陷,且不同类型缺陷之间存在着高度相似、尺度变化大、背景信息复杂等问题。为解决这些问题,本文提出了轻量级工业缺陷检测网络(LIDD-Net)。针对相似度高的不同种类缺陷,LIDD-Net设计了通道交互分离骨干网络,在降低模型计算量的同时提高了特征提取能力;针对不同尺度的缺陷,LIDD-Net提出了轻量化特征融合网络RepGhostPAN,在能融合图像中多尺度特征的同时提高了推理速度;针对检测背景的复杂性,LIDD-Net提出了轻量辅助训练模块,通过使用辅助训练头和动态软标签分配策略,可更好地区分目标缺陷与复杂背景。通过在钢材缺陷、铝缺陷和轮胎缺陷数据集的实验结果表明,LIDD-Net在参数量仅为 $0.62 \times 10^6$ 的情况下分别获得了98.3%、98.1%和96.1%的mAP@0.5,可以满足工业现场实际需求。

**关键词:** 工业缺陷检测;轻量化检测网络;特征融合;结构重参数化;注意力机制

中图分类号: TP 391.4

文献标志码: A

文章编号: 1005-3026(2025)10-0018-09

## LIDD-Net: Lightweight Industrial Product Defect Detection Method Based on Deep Learning

SHA Xiao-peng, XIE De-han, GUO Zhou-peng, SUN Kai

(School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China. Corresponding author: SHA Xiao-peng, E-mail: shaxiaopeng@neuq.edu.cn)

**Abstract:** In industrial products, various types of defects often exhibit high inter-class similarity, large scale variations, and complex backgrounds. To address these challenges, a lightweight industrial defect detection network (LIDD-Net) was proposed. To handle highly similar defect types, in LIDD-Net, a channel interaction separation backbone network was introduced, which enhanced feature extraction while reducing the computational cost of the model. To address multi-scale defect variations, a lightweight feature fusion network was developed, namely RepGhostPAN, to efficiently integrate multi-scale features in the image and accelerate inference. For complex detection backgrounds, a lightweight auxiliary training module was proposed, leveraging an auxiliary training head and a dynamic soft label assignment strategy to better distinguish target defects from complex backgrounds. Experiments on steel, aluminum, and tire defect datasets demonstrate that LIDD-Net achieves mAP@0.5 scores of 98.3%, 98.1%, and 96.1%, respectively, with only  $0.62 \times 10^6$  parameters, meeting practical industrial requirements.

**Key words:** industrial defect detection; lightweight detection network; feature fusion; structural reparameterization; attention mechanism

工业产品缺陷检测是保障产品质量、维持生产稳定的重要技术之一。以往的缺陷检测需要人工筛查,检测成本高、效率低,在缺陷种类较多时

难以满足检测需要。随着深度学习技术的快速发展,工业缺陷检测技术得到了提升。深度学习方法在处理背景复杂、缺陷微弱的工业图像时展

收稿日期: 2024-03-12

基金项目: 河北省中央引导地方科技发展资金项目(246Z2002G); 中央高校基本科研业务费专项资金资助项目(2025GFZD002)。

作者简介: 沙晓鹏(1983—),女,河北邢台人,东北大学秦皇岛分校副研究员。

现出了卓越的性能优势,逐渐在该领域占据主导地位.

近年来,学者们针对缺陷检测提出了多种检测网络.Shen等<sup>[1]</sup>提出了CRNet检测网络,设计了一个多尺度关系探索模块,可以充分挖掘缺陷与背景信息之间的耦合关系,从而获得更有效的语义特征.Zong等<sup>[2]</sup>提出了Co-DETR检测网络,通过训练由一对多标签分配监督的并行辅助头,增强模型在端到端检测器中的学习能力.Yu等<sup>[3]</sup>提出了YOLO-FaceV2检测网络,通过设计的多尺度特征提取模块RFEM,有效增强了模型对多尺度特征的提取能力.这些检测方法的出现提高了工业缺陷检测的精度.由于这些缺陷检测网络模型复杂度较高,推理速度慢,在算力有限的工业环境中部署相对困难.Ding等<sup>[4]</sup>提出了RepVGG,通过使用等价替换的简单模型进行推理,有效加快了模型推理速度.Lei等<sup>[5]</sup>提出了可用于电池集电器缺陷检测的轻量化网络DGNet,在保证检测精度的同时减少了模型的参数冗余.Ye<sup>[6]</sup>提出了基于ShuffleNetV2的改进网络AUGShuffleNet,有效减少了特征提取网络的参数量.但是现有的轻量化缺陷检测网络在面对相似度高、尺度变化剧烈、背景信息复杂的工业产品缺陷时,容易出现错检漏检现象.

为应对上述挑战,本文提出了一种基于深度学习的轻量级工业缺陷检测网络(lightweight

industrial defect detection network, LIDD-Net).首先,设计了轻量辅助训练模块(lightweight auxiliary training module, LATM),通过辅助训练头(auxiliary training head, ATH)融合多个层次的特征,提取更多的上下文信息以提高模型对背景复杂缺陷的检测能力;其次,设计了通道交互分离骨干网络(channel interaction separation backbone network, CISB-Net),在降低模型计算量的同时提高网络对多种类缺陷的特征提取能力;最后,设计了RepGhostPAN特征融合网络,利用多分支结构提高了网络对不同尺度缺陷的检测能力,同时通过结构重参数化方法加快模型推理速度.

## 1 LIDD-Net 网络设计

LIDD-Net网络的整体框架如图1所示,该网络主要由CISB-Net、RepGhostPAN、目标检测头和LATM组成.其中,CISB-Net可对相似度高的产品缺陷进行特征提取;RepGhostPAN可以将不同分辨率的特征图进行多尺度融合;最后将经过特征网络融合后的特征图分别输入目标检测头中计算损失值.在训练阶段,通过使用本文提出的LATM进行动态标签匹配,并将ATH与目标检测头的输出融合后输入Loss来计算损失值,可以加快模型训练时的收敛速度.

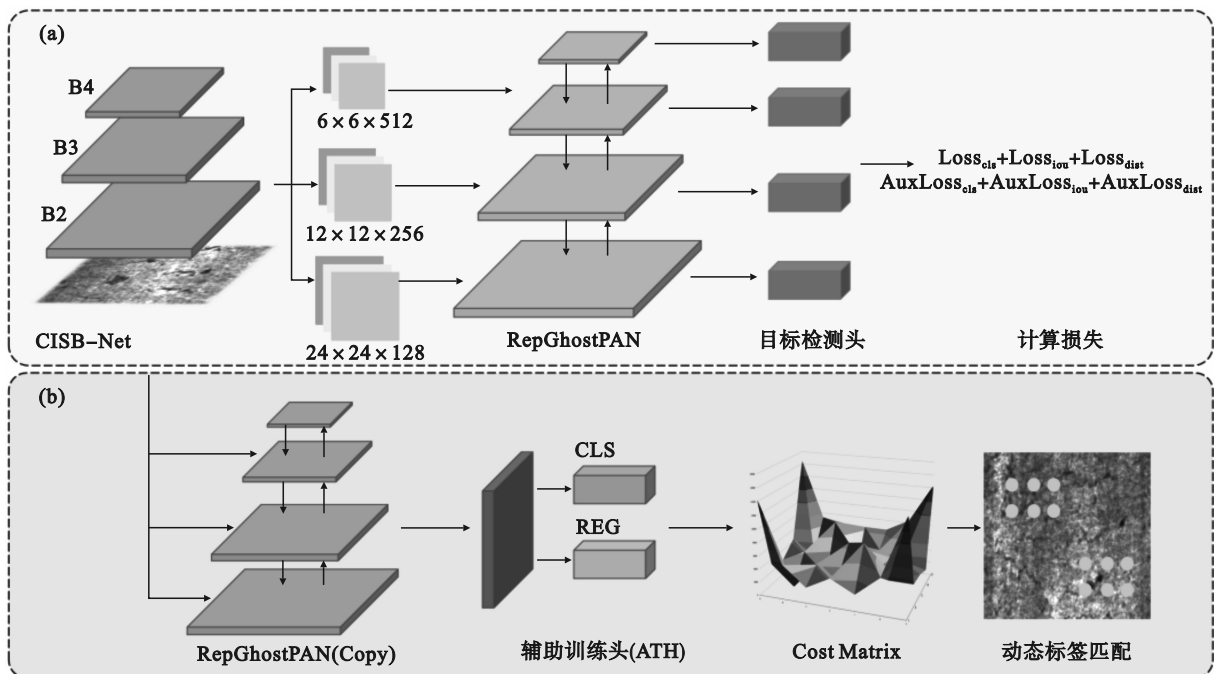


图 1 LIDD-Net 总体结构

Fig. 1 Overall structure of LIDD-Net

(a)—LIDD-Net推理阶段结构;(b)—LATM结构.

### 1.1 通道交互分离骨干网络(CISB-Net)

轻量级目标检测方法常用的主流特征提取网络有 ShuffleNetV2, MobileNet 以及 ResNet 等, 这些网络采用轻量化结构的设计, 大幅降低了模型的计算量与参数量, 但是这些特征提取网络在面对相似的工业缺陷目标时, 容易出现漏检错检现象. 针对该问题, 本文设计了通道交互分离骨干网络(CISB-Net), 可同时满足精度和速度的需求.

CISB-Net 的轻量化特征提取能力主要通过本文设计的通道分离增强模块(channel separation enhancement, CSE)和多尺度特征融合模块(multi-scale feature fusion module, MSFFM)实现. 其中 CSE 分为 CSE-A 和 CSE-B. 如图 2 所示, CISB-Net 由 4 层特征提取模块组成, 第 1 层 B1 由  $3 \times 3$  卷积和最大池化层组成; 第 2 层 B2 由 1 个 CSE-A 和 3 个 CSE-B 组成; 第 3 层 B3 由 1 个 CSE-A 和 7 个 CSE-B 组成; 第 4 层 B4 由 1 个 CSE-A, 3 个 CSE-B 和 1 个 MSFFM 模块组成. B2, B3, B4 分别输出尺寸依次减半、通道数依次翻倍的不同深度的特征图, 随后将特征图输入 RepGhostPAN 网络中进行特征融合.




图 2 通道交互分离骨干网络结构

Fig. 2 Structure of channel interaction separation backbone network

#### 1.1.1 通道分离增强模块(CSE)

如图 3b 所示, CSE-B 首先通过通道分离(Channel Split)将输入通道  $C$  按照分离比  $6:5:5$  分离为 3 组通道  $C_1, C_2, C_3$ , 通道  $C_2$  经过  $1 \times 1$  普通卷积和  $3 \times 3$  深度卷积进行特征提取, 其中普通卷积可以提取局部特征, 而深度卷积可以提取更加抽象的全局特征, 将两者结合获取检测目标的多尺度特征信息, 有利于目标检测中的多尺度目标识别, 同时深度卷积减少了参数量, 提高了模型的计算效率. 通道  $C_2$  经过特征提取后通过 Chunk 操作按照分离比  $1:1$  分离为 2 组通道  $C_4, C_5$ , 两次分离通道可以有效解决特征提取网络通道冗余问题, 加快模型推理速度.

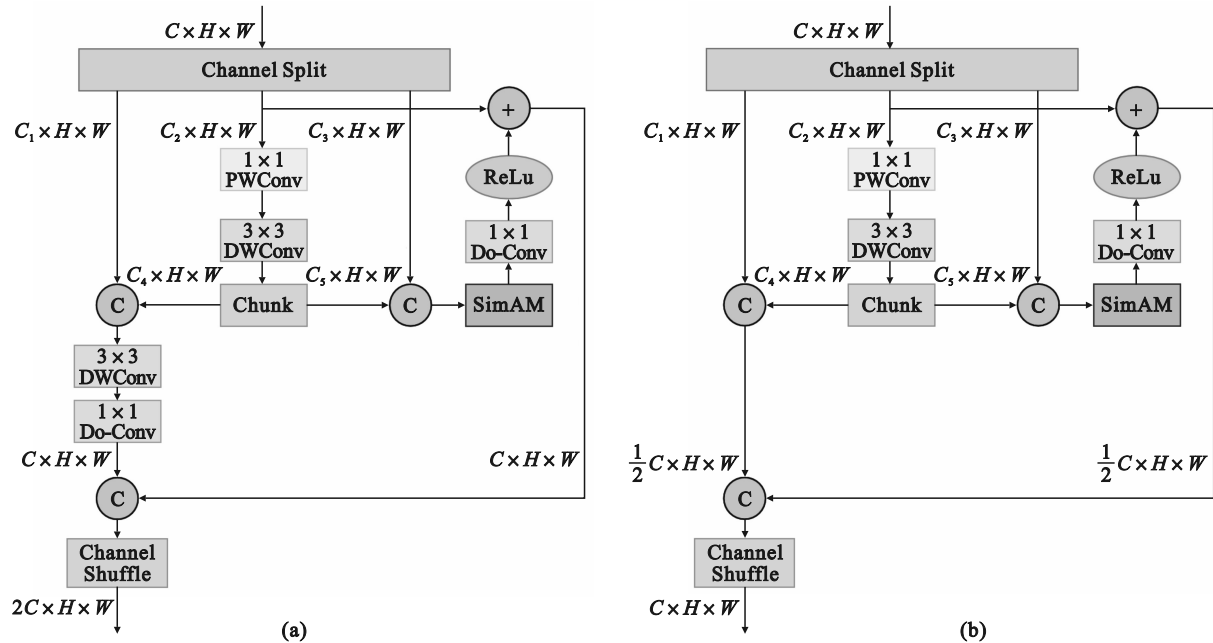


图 3 通道分离增强模块结构

Fig. 3 Channel separation enhancement module structure

(a)—CSE-A 结构; (b)—CSE-B 结构.

分离后的通道  $C_5$  与  $C_2$  融合后输入 SimAM 模块来进一步提高模型性能. SimAM<sup>[7]</sup>通过计算不同缺陷目标之间的相似性, 并根据相似性权重对特征进行加权, 使得模型可以更好地区分相似的

缺陷目标. 加权后的特征通过 Do-Conv 进行进一步的特征提取. Do-Conv<sup>[8]</sup>通过在普通卷积中嵌入额外的 DWConv 操作, 形成一个过度参数化的卷积层, 使得模型能够更好地捕捉图像特征, 从

而提高对相似缺陷目标检测的准确性. 然后通过 Add 操作将通道  $C_2$  和增强后的通道  $C_3$  融合, 加快模型的收敛速度. 最后所有分离的通道通过 Concat 操作融合在一起, 经过通道混洗(Channel Shuffle)后输出. 如图 3a 所示, CSE-A 在 CSE-B 的基础上加入通道升维部分调整特征提取模块的输入通道. 为了减少模型的计算量和提高推理速度, 采用 Do-Conv 代替普通卷积来进行通道升维.

### 1.1.2 多尺度特征融合模块(MSFFM)

如图 4 所示, MSFFM 由 3 个空洞卷积分支、1 个平均池化分支和 1 个残差分支组成. 空洞卷积分支分别使用了 3 个不同空洞率的空洞卷积来生成多尺度特征图, 使得模型能够更加全面地捕获缺陷目标的语义信息. 不同空洞卷积分支之间使用共享权重的方法来减少参数量, 通过共享权重, 不同空洞率的卷积分支可以学习到通用的特

征表示, 从而在减少存储需求的同时提高了模型的泛化能力<sup>[9]</sup>. 残差连接的引入进一步增强了模型的稳定性, 有助于缓解梯度消失问题. 平均池化分支通过对输入特征图的平均池化操作, 降低了空间分辨率, 保留了每个通道的平均值, 从而在降低计算复杂度的同时保持关键特征. 这有助于提高训练和推理的效率, 为处理大规模数据集或实时推理任务提供了优越性能.

为了进一步压缩特征图并增强模型的代表能力, 引入 Do-Conv 模块将通道数压缩为输入通道数的 1/16. 通过降低通道数量, 有效地减少了模型的参数量, 提高了计算效率. 随后通过上采样操作重新恢复特征图的尺寸, 使用 Do-Conv 操作恢复通道数. 这种漏斗卷积结构在压缩和恢复通道数的过程中, 使得模型能够更加灵活地捕捉图像特征, 在保持模型准确性的同时降低了模型的复杂度.

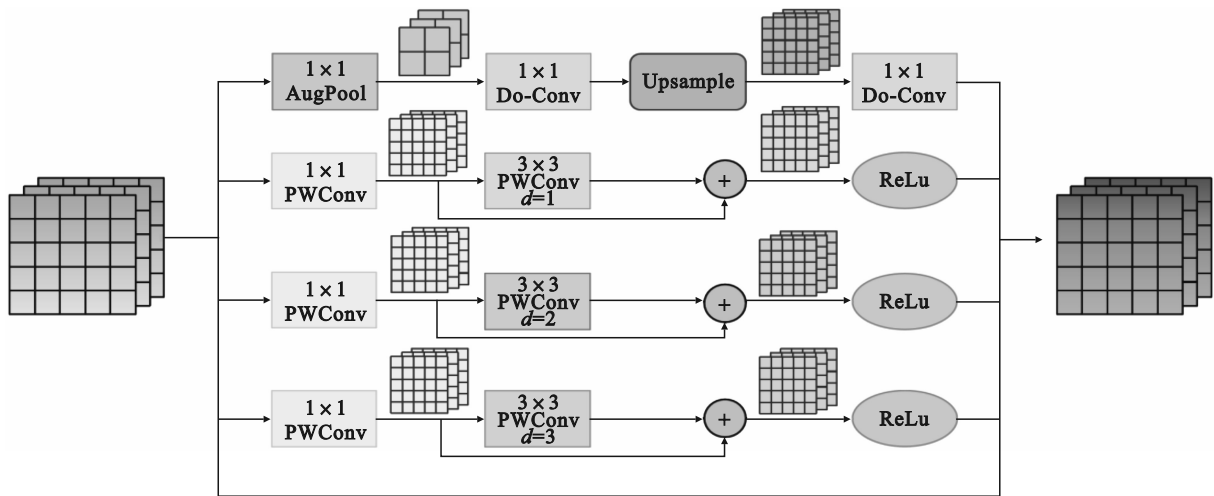


图 4 多尺度特征融合模块结构

Fig. 4 Structure of multi-scale feature fusion module

### 1.2 轻量化特征融合网络(RepGhostPAN)

为了解决缺陷检测网络在面对尺度变化大的缺陷目标时检测精度差的问题, 本文提出了 RepGhostPAN 特征融合网络. 将经过 CISB-Net 特征提取网络输出的特征图输入到 RepGhostPAN 网络进行特征融合. 如图 5 所示, 特征图在经过  $1 \times 1$  卷积通道压缩后, 首先进行金字塔特征融合, RepGhostPAN 在金字塔特征融合基础上增加了一个自底向上的路径, 将浅层的底部特征下采样后与深层的顶部特征进行融合, 使得浅层特征图的定位信息能够更好传递到深层特征图, 有效提高了检测精度<sup>[10]</sup>. 考虑到在工业产品缺陷检测中, 需要检测模型推理速度快、计算

量小, 同时可以准确检测出不同尺度的缺陷, 因此本文在 RepGhostPAN 中使用 RepGhostBlock 代替传统的卷积进行特征融合.

RepGhostBlock 训练时的结构如图 6a 所示, 由 Ghost 卷积和多分支部分组成. Ghost 卷积<sup>[11]</sup>可以有效降低模型计算量, 但是在处理尺度变化大的缺陷目标时性能不足, 因此本文在 Ghost 卷积的基础上加入了多分支部分. 多分支部分由 3 种分支结构组成, 分别为 1 个单分支、4 个  $1 \times 1$  卷积分支和 4 个  $3 \times 3$  卷积分支. 利用多分支结构使得网络能够同时处理多个尺度的特征, 能够更好地融合图像中不同尺度缺陷的信息. 训练阶段中所有分支结构的输出如式(1)~式(3)所示.



态调整标签, 有助于模型更好地适应和区分缺陷目标与背景.

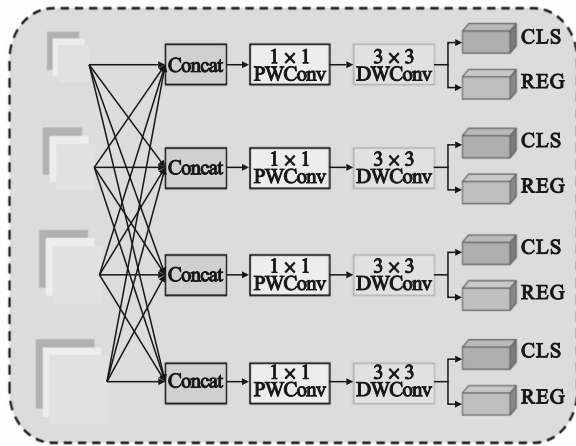


图 7 辅助训练头结构

Fig. 7 Auxiliary training head structure

## 2 实验结果与分析

### 2.1 环境配置

本文实验的主要环境配置如表 1 所示.

操作系统	Microsoft Windows 11
CPU	Intel Core i5-13600
GPU	NVIDIA GeForce RTX 4090, CUDA=12.2
运行环境	Python 3.8, PyTorch 1.13

### 2.2 评价指标

在本文中, 使用所有目标类别加权的平均精度(mAP)评价 LIDD-Net 的整体检测性能, 包括 mAP@0.5 和 mAP@0.5:0.95. 为了验证 LIDD-Net 在轻量化方面的优势, 本文还引入了模型参数量 (Params) 以及浮点运算次数 (FLOPs) 作为评估指标.

### 2.3 数据集与预处理

本文分别在 NEU-DET 钢表面缺陷数据集、铝表面缺陷数据集和轮胎缺陷数据集上进行实验.

NEU-DET 钢表面缺陷数据集共包含 1 800 张图像. 由于该数据集中的原始数据量较小, 模型在训练过程中可能无法收敛并达到预期效果, 因此本文采用随机旋转, 翻转和亮度变化方法扩充数据集, 扩充后的数据集共包含 9 000 张缺陷图片. 图 8a 中的缺陷类型分别为开裂、氧化铁皮压入和点蚀. 开裂缺陷的特征为细小裂纹; 氧化铁皮压入缺陷的特征为不规则突起; 点蚀缺陷的

特征为不规则斑点. 这些不同种类的缺陷之间相似度高、颜色相近、尺度相似, 需要检测网络捕捉不同种类缺陷之间的细微差异. 铝表面缺陷数据集共包含 1 400 张缺陷图片. 图 8b 中的缺陷类型分别为针孔、脏污和褶皱. 针孔缺陷尺度最小, 平均像素面积为  $18 \times 18$ ; 脏污缺陷呈不规则椭圆形, 平均像素面积为  $90 \times 70$ ; 褶皱缺陷尺度最大, 平均像素面积为  $320 \times 80$ . 铝表面不同缺陷之间尺度变化很大, 这在一定程度上增加了检测的难度. 轮胎缺陷数据集共包含 1 903 张缺陷图片, 图 8c 中的缺陷类型分别为胎面帘线重叠、胎侧帘线开裂和胎面帘线开裂. 胎面帘线重叠缺陷处的帘线分布紧凑; 胎侧帘线开裂缺陷处的帘线分布松散; 胎面帘线开裂缺陷处的帘线呈现出一个裂口. 这些轮胎表面缺陷与背景环境相似, 需要检测网络可以捕捉缺陷与背景环境之间的细微差异.




图 8 工业产品缺陷示例

Fig. 8 Examples of defects in industrial products

(a)—钢表面缺陷; (b)—铝表面缺陷;

(c)—轮胎表面缺陷.

### 2.4 消融实验

为了有效地评估本文提出方法的合理性, 基于 NEU-DET 钢表面缺陷数据集对 LIDD-Net 的不同部分进行了消融实验.

消融实验结果如表 2 所示. 首先在 BaseLine 网络的基础上加入了本文设计的 LATM 模块, LATM 有助于模型更好地区分缺陷目标与复杂背景, 而且 LATM 只在训练阶段使用, 因此不会增加模型的参数量以及复杂度. 由实验数据可知, 在加入 LATM 后, mAP@0.5 增加 1.31%, 同时参

数量和 FLOPs 没有增加. 然后加入本文设计的 CISB-Net 特征提取网络, CISB-Net 通过降低通道冗余加快模型推理速度, 同时提高了对相似缺陷的检测精度. 由实验数据可知, 加入 CISB-Net 后, 在 NEU-DET 数据集上的  $mAP@0.5$  增加 1.44%, 同时参数量减少 47.1%, FLOPs 减少 32.8%. 最后

加入本文设计的 RepGhostPAN 特征融合网络, RepGhostPAN 可以更好地融合图像中不同尺度缺陷的信息, 同时通过结构重参数化方法降低模型复杂度. 由实验数据可知, 在加入 RepGhostPAN 后,  $mAP@0.5:0.95$  增加 0.84%, 参数量仅增加  $0.0084 \times 10^6$ , FLOPs 仅增加  $0.7 \times 10^6$ .

表 2 NEU-DET 数据集消融实验  
Table 2 Ablation experiment on NEU-DET dataset

模型	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	Params $\times 10^{-6}$	FLOPs $\times 10^{-9}$
BaseLine	95.37	64.78	1.1718	0.1632
+LATM	96.68	66.76	1.1718	0.1632
+CISB-Net	98.06	72.42	0.6203	0.1097
+RepGhostPAN	98.30	73.26	0.6287	0.1104

## 2.5 对比实验

将本文提出的方法 LIDD-Net 在 3 个不同数据集上与工业界主流的目标检测算法进行对比实验, 从检测精度、模型参数量、模型复杂度等方面来验证该模型的有效性. 由于不同数据集中图片分辨率差异较大, 为保证检测效果, 在 3 个数据集上进行训练和推理时模型输入图片的分辨率分别调整为  $192 \times 192$ ,  $320 \times 320$  以及  $480 \times 480$ . LIDD-Net 网络参数设置如下: batch\_size 为 32, grad\_clip 为 35, 优化器为 AdamW, 学习率为 0.001, weight\_decay 为 0.05, epochs 为 300. 在所有实验中均统一为上述参数. 由表 3~表 5 可知, 与目前主流的目标检测方法相比, LIDD-Net 保持了较高的检测精度, 同时具有较低的模型参数量和计算量. 在 NEU-DET 钢表面缺陷数据集实验中, LIDD-Net 与 YOLOX-Nano, YOLOv8n, PP-PicoDet-S 和 TOOD 等检测方法相比,  $mAP@0.5$

分别提高 2.38%, 9.07%, 4.86% 和 8.93%, 同时参数量分别降低  $0.27 \times 10^6$ ,  $2.38 \times 10^6$ ,  $0.36 \times 10^6$  和  $30.60 \times 10^6$ . 在铝表面缺陷数据集实验中, LIDD-Net 与 Nanodet, Foveabox 和 YOLOv5n 检测方法相比,  $mAP@0.5$  分别提高 2.28%, 14.50% 和 0.64%, 同时参数量分别降低  $0.3 \times 10^6$ ,  $35.61 \times 10^6$ ,  $1.14 \times 10^6$ . 在轮胎缺陷数据集实验中, YOLO-Fastestv2 的参数量和模型计算量低于 LIDD-Net, 但其精度无法满足工业检测需求, 错检漏检率高. YOLOv8n 的检测精度与 LIDD-Net 接近, 但其对工业检测环境中的硬件性能要求过高. 综上所述, 本文提出的检测方法平衡了检测精度和模型复杂度, 充分说明本文方法能够准确检测复杂相似的缺陷目标, 并满足工业检测环境高实时性的要求. 图 9 为 LIDD-Net 在不同数据集实验中的检测结果, 可以看出 LIDD-Net 可以准确定位并标识出各类缺陷.

表 3 NEU-DET 数据集对比实验  
Table 3 Comparison experiment on NEU-DET dataset

网络	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	Params $\times 10^{-6}$	FLOPs $\times 10^{-9}$
YOLOv5n	93.28	59.10	1.7720	0.3821
YOLOv8n	90.43	57.93	3.0068	0.7380
YOLO-Fastestv2	88.02	55.72	0.2376	0.0034
YOLOX-Nano	95.92	61.14	0.8977	0.1149
PP-PicoDet-S	93.44	64.12	0.9894	0.4628
Nanodet	94.02	61.64	0.9285	0.1245
Nanodet-plus	96.62	66.79	1.1726	0.1665
TOOD	89.37	63.42	31.234	6.3593
Foveabox	90.76	56.53	36.244	7.1298
LIDD-Net	<b>98.30</b>	<b>73.26</b>	<b>0.6287</b>	<b>0.1104</b>

表 4 铝表面缺陷数据集对比实验  
Table 4 Comparison experiment on aluminum surface defect dataset

网络	mAP@0.5/%	mAP@0.5:0.95/%	Params $\times 10^{-6}$	FLOPs $\times 10^{-9}$
YOLOv5n	96.48	51.89	1.772 0	1.061 4
YOLOv8n	95.53	50.82	3.006 8	2.049 9
YOLO-Fastestv2	80.51	44.83	0.237 6	0.094 4
YOLOX-Nano	91.69	50.99	0.897 7	0.319 2
PP-PicoDet-S	96.24	51.64	0.989 4	0.730 2
Nanodet	95.84	51.31	0.928 5	0.345 6
Nanodet-plus	96.43	50.82	1.172 6	0.462 1
TOOD	82.74	43.62	31.234	17.578
Foveabox	83.62	43.86	36.244	19.793
LIDD-Net	<b>98.12</b>	<b>52.76</b>	<b>0.628 7</b>	<b>0.306 4</b>

表 5 轮胎缺陷数据集对比实验  
Table 5 Comparison experiment on tire defect dataset

网络	mAP@0.5/%	mAP@0.5:0.95/%	Params $\times 10^{-6}$	FLOPs $\times 10^{-9}$
YOLOv5n	94.82	54.12	1.772 0	2.388 2
YOLOv8n	95.33	55.62	3.006 8	4.612 2
YOLO-Fastestv2	84.48	49.87	0.237 6	0.212 4
YOLOX-Nano	94.52	54.38	0.897 7	0.717 7
PP-PicoDet-S	90.80	54.32	0.989 4	1.462 5
Nanodet	93.54	54.46	0.928 5	0.778 5
Nanodet-plus	94.86	55.56	1.172 6	1.040 1
TOOD	90.24	53.22	31.234	39.742
Foveabox	86.36	50.62	36.244	44.586
LIDD-Net	<b>96.13</b>	<b>56.32</b>	<b>0.628 7</b>	<b>0.689 9</b>




图 9 LIDD-Net 的检测结果

Fig. 9 Detection results of LIDD-Net

(a)—钢表面缺陷；(b)—铝表面缺陷；(c)—轮胎表面缺陷。

### 3 结 论

1) 本文提出了一种针对工业产品缺陷检测的轻量化检测网络 LIDD-Net. 该网络通过提出轻量辅助训练模块 LATM, 引入动态软标签匹配策略以提高模型对复杂背景中缺陷的检测能力. 通过设计 CISB-Net 特征提取网络, 在降低网络冗余的同时加强了对相似缺陷特征的提取能力.

2) 提出了 RepGhostPAN 特征融合网络, 使用多分支结构并引入结构重参数化方法以提高模型对缺陷尺度变化的适应能力.

3) 在 3 个公开数据集上对 LIDD-Net 与其他检测网络进行了比较. 实验结果表明, 本文提出的 LIDD-Net 在公开数据集上获得了更优的性能, 有效平衡了检测精度和模型复杂度, 满足工业检测环境的实际需求.

## 参考文献:

- [ 1 ] Shen X K, Liu J H, Jiang L, et al. A novel weld defect detection method for intelligent magnetic flux leakage detection system via contextual relation network[J]. *IEEE Transactions on Industrial Electronics*, 2024, 71 (6) : 6304-6314.
- [ 2 ] Zong Z F, Song G L, Liu Y. DETRs with collaborative hybrid assignments training[C]// Proceedings of the IEEE Conference on International Conference on Computer Vision. Paris, 2023: 6725-6735.
- [ 3 ] Yu Z P, Huang H B, Chen W J, et al. YOLO-FaceV2: a scale and occlusion aware face detector [J]. *Pattern Recognition*, 2024, 155: 110714.
- [ 4 ] Ding X H, Zhang X Y, Ma N N, et al. RepVGG: making VGG-style convnets great again [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual, 2021: 13733-13742.
- [ 5 ] Lei Y, Chen Y R, Hai T, et al. DGNet: an adaptive lightweight defect detection model for new energy vehicle battery current collector[J]. *IEEE Sensors Journal*, 2023, 23: 29812-29830.
- [ 6 ] Ye L Q. AugShuffleNet: communicate more, compute less [EB/OL]. (2022-03-13) [2022-08-21]. <https://arxiv.org/abs/2203.06589.pdf>.
- [ 7 ] Yang L X, Zhang R Y, Li L D, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks [C]// International Conference on Machine Learning. Virtual, 2021: 11863-11874.
- [ 8 ] Cao J M, Li Y Y, Sun M C, et al. Do-Conv: depthwise over-parameterized convolutional layer [J]. *IEEE Transactions on Image Processing*, 2022, 31: 3726-3736.
- [ 9 ] Filippas D, Nicopoulos C, Dimitrakopoulos G. Streaming dilated convolution engine [J]. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 2023, 31: 401-405.
- [ 10 ] Shamsolmoali P, Chanussot J, Zareapoor M, et al. Multipatch feature pyramid network for weakly supervised object detection in optical remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-13.
- [ 11 ] Han K, Wang Y H, Tian Q, et al. Ghostnet: more features from cheap operations [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual, 2020: 1580-1589.
- [ 12 ] Mishra R, Gupta H P. Designing and training of lightweight neural networks on edge devices using early halting in knowledge distillation [J]. *IEEE Transactions on Mobile Computing*, 2024, 23: 4665-4677.