

DOI: 10.19650/j.cnki.cjsi.J2514230

基于 DenseNet 轻量化的板式换热器板片 缺陷检测方法研究

苑玮琦^{1,2}, 丁志博^{1,2}

(1. 沈阳工业大学视觉检测技术研究所 沈阳 110870; 2. 辽宁省机器视觉重点实验室 沈阳 110870)

摘要:针对板式换热器板片表面微裂纹检测任务中因浅层特征丢失导致识别精度受限的问题,提出了一种基于轻量化密集连接卷积网络(DenseNet)的检测方法。微裂纹作为一种单一类别、多尺度分布的线状小目标集群,其核心挑战在于空间细节特征的充分学习与保持。主要创新点包括:首先,建立了感受野与缺陷尺寸匹配的理论模型,推导出层级配置的数学公式,并基于实际工业场景中的波纹板缺陷特性进行了模型实例化;其次,设计了一种细节增强机制,通过禁用下采样操作以保留关键空间特征,并采用堆叠 3×3 小卷积核的策略渐进式扩展感受野,有效平衡了特征分辨率与语义抽象程度;最后,构建了一种缺陷实例级评估策略,以符合国家标准对微裂纹“存在性判定”而非尺寸测量的实际需求。在沈阳工业大学基准库1(SUT-B1)数据集上的实验表明,该方法取得了94.69%的平均精度和92.60%的F1分数,漏检3例和误检5例。其性能表现不仅优于基线模型及主流轻量化模型中的最优结果,即平均精度94.53%和F1分数87.85%,验证了DenseNet结构在特征复用方面的优势;同时也超过了对比实验中的最优平均精度94.56%和最优F1分数90.90%,证明了结构优化策略的必要性。该方法在工业检测领域具有实用性与可扩展性,为类似微小缺陷识别任务提供了新的技术思路。相关代码已公开于:<https://github.com/zhuangzhaun/Lightweight-DenseNet>。

关键词:板式换热器板片;微裂纹检测;小目标检测;DenseNet轻量化

中图分类号:TP391.41 TH165 文献标识码:A 国家标准学科分类代码:510.40

Research on defect detection method for plate heat exchanger plates based on DenseNet lightweight

Yuan Weiqi^{1,2}, Ding Zhibo^{1,2}

(1. Computer Vision Group, Shenyang University of Technology, Shenyang 110870, China;

2. Key Laboratory of Machine Vision, Liaoning Province, Shenyang 110870, China)

Abstract: Aiming at the problem of limited recognition accuracy caused by the loss of shallow features in the detection of micro cracks on plate heat exchanger surfaces, this paper proposes a detection method based on a lightweight dense convolutional network (DenseNet) architecture. As a single-category, multi-scale distributed cluster of linear small objects, the core challenge of microcrack detection lies in the effective learning and preservation of spatial detail features. The main contributions are as follows: First, a theoretical model matching the receptive field to defect size is established, with mathematical formulas derived for hierarchical configuration, followed by model instantiation based on the characteristics of corrugated plate defects in real industrial scenarios. Second, a detail enhancement mechanism is designed, which preserves critical spatial features by disabling downsampling operations and progressively expands the receptive field through stacked 3×3 small convolutional kernels, effectively balancing feature resolution and semantic abstraction. Finally, a defect instance-level evaluation strategy is constructed to meet the national standard requirements, which focus on the "existence detection" of microcracks rather than size measurement. Experimental results on the Shenyang University of Technology Benchmark 1 (SUT-B1) dataset show that the proposed method achieves an average precision of 94.69% and an F1-score of 92.60%.

with only 3 missed detections and 5 false detections. Its performance not only surpasses that of baseline and mainstream lightweight models, which achieve namely, 94.53% AP and 87.85% *F1*-score—demonstrating the advantage of the DenseNet structure in feature reuse, but also exceeds the best performance in comparative experiments (94.56% AP and 90.90% *F1*-score), confirming both the advantage of DenseNet-based feature reuse and the necessity of the structural optimization strategy. The proposed approach demonstrates practicality and scalability in the field of industrial inspection, offering a new technical direction for similar fine defect recognition tasks. The related code is publicly available at: <https://github.com/zhuanzhaun/Lightweight-DenseNet>.

Keywords: plate heat exchanger plate; micro cracks detection; small object detection; DenseNet lightweight

0 引言

可拆卸板式换热器是通过堆叠具有波纹形状的金属片进行换热的器械。微裂纹是板式换热器板片在生产压制过程中会因冲压导致板片表面产生的一种微小尺寸线状缺陷。局部应力促使微裂纹成片式扩展,聚合成微裂纹的集群。这种微裂纹集群整体呈现出线状的灰度特征,本研究将其定义为微裂纹缺陷。当板片投入工作中,缺陷会由于无法承受注水后的压力而开裂,存在工作隐患。

国家标准金属弯曲试验方法^[1]中的附录 A 金属弯曲试验结果评定方法中指出:试样弯曲外表面金属基体上出现的细小微裂纹,其长度不大于 2 mm,或宽度不大于 0.2 mm 称之为微裂纹。国家标准板式热交换器第 1 部分:可拆卸板式热交换器^[2]规定微裂纹检测仅需判定缺陷存在性,不涉及长度参数测量。

从工业需求及国家标准中可知,在生产过程中,针对微裂纹的有效检测是质量控制的重要一环。目前生产环境下,板式换热器板片的缺陷检测只存在样机检测,还没有在线检测方法。如文献[3]使用 Canny 算法实现板式换热器板片的边缘检测,实现了缺陷区域定位;文献[4]通过多尺度凸线段绝对幅值完成线状缺陷检测。

当前基于神经网络的目标检测方法可分为 3 类:以文献[5-6]为代表的单阶段算法,结合残差网络或多尺度特征金字塔来强化特征学习,但存在参数优化困难、下采样导致浅层特征丢失等问题。以文献[7-8]为代表的双阶段算法,虽通过特征融合提升大目标检测能力,却因模型复杂度易引发过拟合,且低分辨率特征提取制约小目标识别。以文献[9-10]为代表的 Transformer 端到端算法,利用自注意力机制增强全局建模,但缺乏卷积先验知识导致小目标细节丢失,并高度依赖大规模训练数据。上述模型的共性缺陷为在应对小尺寸、多尺度单一目标检测时,普遍面临浅层特征丢失、模型过拟合、计算效率低的问题。

在小目标检测领域,多项研究通过不同技术路径提升了检测精度:文献[11]采用特征增强机制强化目标信

息提取,文献[12-13]聚焦轻量化架构设计以优化计算效率,文献[14]在检测头阶段实施结构创新增强定位能力,文献[15]则通过注意力优化策略改善特征聚焦效果,这些方法均提升了小目标识别性能。在轻量化模型方面,近年来主流解决方案包括但不限于:通过极简架构与动态卷积实现实时推理的 YOLOv8-nano (you only look once version 8-nano);基于神经架构搜索优化计算效率的轻量级高效检测器 (efficient detector-lite, EfficientDet-Lite) 系列;采用锚框自由机制降低内存占用的增量级纳米检测器 (nano detector-plus, NanoDet-Plus) 系列。然而,上述模型存在高分辨率细节损失与感受野失配的共性局限。

这种局限在现有感受野自适应方法中同样存在。例如:文献[16]通过并联空洞卷积去整合多尺度上下文形成空洞空间金字塔池化 (atrous spatial pyramid pooling, ASPP);文献[17]模拟人类视觉提出多尺度感受野增强模块 (receptive field block, RFB);文献[18]使用提升空间建模能力的动态区域卷积 (dynamic region-aware convolution, DRConv)。这些方法虽各有侧重,但仍未能解决前述问题。因此,建立一种物理尺寸与网络结构的映射关系,成为一种值得探索的解决路径。

针对上述挑战,密集连接卷积网络 (dense convolutional network, DenseNet) 的连接机制提供独特思路,例如:文献[19]减少网络层数优化梯度传播,文献[20]引入注意力机制提升泛化能力体现,文献[21]通过内存优化支持移动端部署;文献[22-23]在有限数据场景下验证了特征复用对于保留细节信息的有效性。

为此,本研究设计了一种基于 DenseNet 轻量化的板式换热器板片微裂纹缺陷检测算法。首先,建立感受野-缺陷尺寸的匹配理论模型,推导层级配置公式,通过尺寸倍率因子量化网络结构与缺陷尺度的适配关系,得出网络深度公式与层级分配准则;然后,禁用下采样与堆叠小卷积核设计特征增强机制,再后,在工业场景实例化,根据波纹板缺陷检测先验知识创建对应模型。最后,提出缺陷实例级评估策略,满足国家标准板式热交换器第 1 部分:可拆卸板式热交换器对微裂纹检测的只关注缺陷是否存在,并不关注缺陷长度的工业要求。

1 相关工作

1.1 小目标定义

当前研究将小目标的定义分为绝对尺寸和相对尺寸两种方式。

其中,绝对尺寸的指标如:Chen 等^[24]采用边长 < 32 pixels 或像素总数 < 1 024、Chen 等^[25]将边长 < 20 pixels 作为判定依据;相对尺寸的指标如:Liu 等^[26]将目标面积占比 < 1%、Zhu 等^[27]将目标面积占比 < 1.5% 作为判定依据。

1.2 微裂纹特征表述

板式换热器板片微裂纹的生成机制受应力分布、疲劳载荷与制造工艺协同作用,形成伪连续线状集群而非孤立裂纹,如图 1 所示。其核心特性为宏观线状形态实为空间离散的局部线段组合,且各局部线段具备梯度方向一致的线状灰度分布特征。

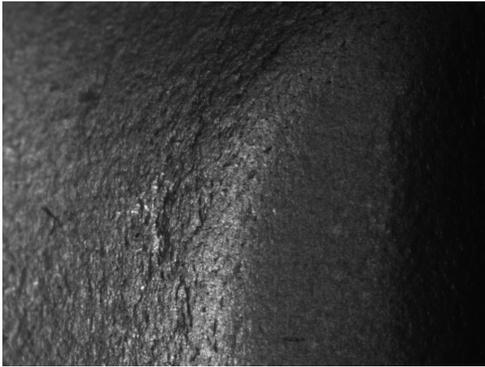


图 1 高倍率镜头下的缺陷

Fig. 1 Defect under high rite lens

缺陷的局部特征与全局特征差异如图 2 所示,左侧黑色整体区域呈现线状灰度特征,右侧白色局部采样区仍保持典型线状灰度特征。因此,局部特征对全局形态

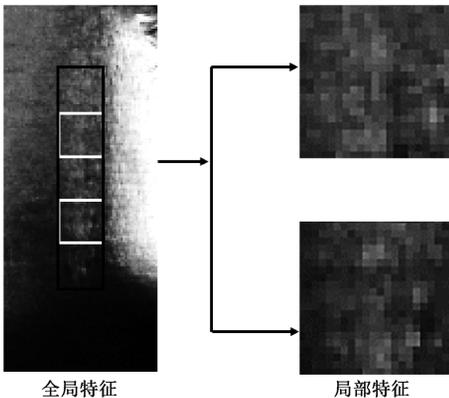


图 2 局部特征与全局特征对比

Fig. 2 Comparison of local and global features

没有依赖性,为轻量化检测的特征学习提供理论依据。为可视化清晰,本实例进行了对比度增强。

1.3 微裂纹形状表述

缺陷区域表征缺陷实际出现区域,用 F_d 表示。宽度界定在灰度不再下降为止,用 W_d 表示。

F_d 中极大值为 f_d ,其位置记为 D_d ;

缺陷极大值点 f_d 的左邻域用 F_c 表示, F_c 侧极小值为 f_c ,其位置记为 D_c ;

缺陷极大值点 f_d 的右邻域用 F_r 表示, F_r 侧极小值为 f_r ,其位置记为 D_r 。

若相邻像素存在多个极大值点(即当前像素与后续像素灰度值相等,且均高于前序及后续两个像素的灰度值),则判定这些点为极大值点。

缺陷宽度定义: $W_d = |D_r - D_c|$ 。

缺陷区域如图 3 所示,其中灰色虚线区域分别为缺陷的左邻域 F_c 与右邻域 F_r ,灰色实线区域为缺陷区域 F_d 。

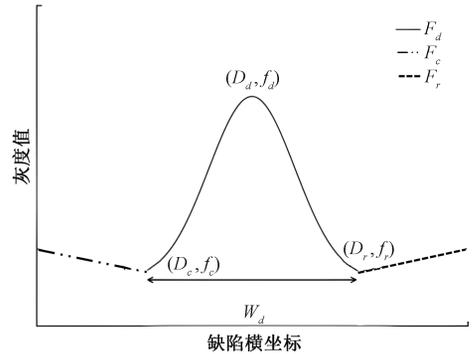


图 3 缺陷宽度示意图

Fig. 3 Diagram of defect width

通过对沈阳工业大学基准库 1 (Shenyang University of Technology Benchmark 1, SUT-B1) 中的数据进行测量,对缺陷特征的描述为:缺陷呈现为线条状,宽度范围保持 7~21 pixels。

7~21 pixels 宽的缺陷符合从绝对尺寸定义中小目标定义标准。线条状缺陷沿特定方向延伸,具有局部特征且在每一小段都能独立呈现,无需整体学习。

缺陷宽度特征如图 4 所示,图 4(a)、(c)、(e) 为宽度为 7、14、21 pixels 时的缺陷局部区域图像;图 4(b)、(d)、(f) 为缺陷经尺寸放大旋转,对比度增强后的示意图,对应图 4(a)、(c)、(e) 中的矩形框区域。图 4(g) 依次给出图 4(b)、(d)、(f) 中缺陷截面的灰度剖面信息,方向为上述图中横线所示方向且按照缺陷宽度定义以双虚线定位了不同缺陷的端点。从上述分析中明确了板式换热器板片上的微裂纹缺陷存在着多尺度且属于小目标的信息。

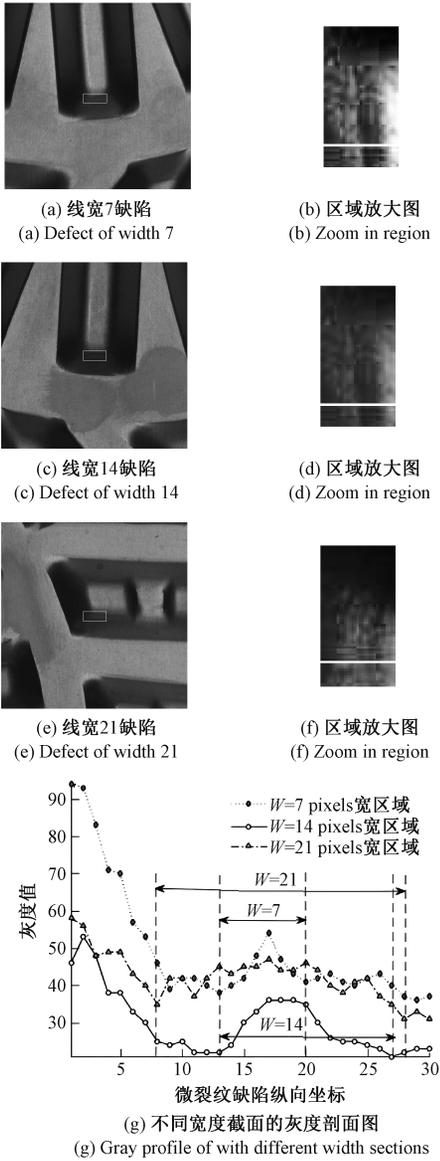


图4 不同宽度缺陷图像及对应截面灰度剖面图
Fig. 4 Defect images of different widths and corresponding section gray profile

1.4 非缺陷相似区域表述

由于板片中部分非缺陷区域与缺陷区域在灰度分布曲线中呈现出相似的特性,导致二者的类间差异性小,所以更加需要学习感受野内的浅层特征来强化其差异性。缺陷及相似区域的灰度剖面图如图5所示,图5(a)展示21 pixels宽,灰度分布为线状的相似区域,该区域由两个平面相交形成,呈现出锐角,锐角的顶部灰度分布为线状。图5(c)展示7 pixels宽的缺陷区域、图5(e)展示7 pixels宽的相似区域。其形成原因为受板材影响,表面粗糙未经过抛光处理凹凸

不平,导致灰度分布曲线中存在小尺寸凸起。图5(b)、(d)、(f)为对应图5(a)、(c)、(e)中的矩形框区域区域尺寸放大及对比度增强后的图像。图5(g)依次给出了图5(b)、(d)、(f)中对应区域的灰度剖面信息。

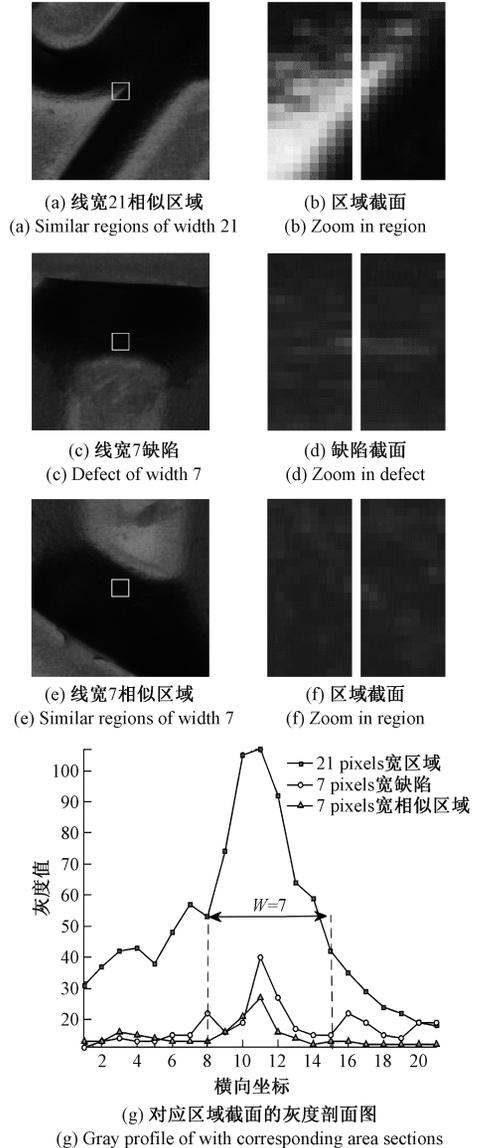


图5 缺陷及相似区域灰度剖面图
Fig. 5 Defect and similar regions section gray profile

从上述与缺陷相似的区域中可以看出,存在与缺陷在灰度分布上均呈现线状特征的相似区域,由于二者类间差异性较小,所以需要缺陷特征进行详尽的学习,恰好受缺陷物理特性影响,浅层特征是描述缺陷信息的关键。因此,通过对固定感受野内浅层特征的学习来区分缺陷与其相似区域。

2 检测网络

本章阐述缺陷检测网络的结构设计。首先,提出适配于单一类别多尺度小目标的感受野-缺陷尺寸匹配理论模型,推导层级配置公式,如式(1)~(6)所示;通过引

入尺寸倍率因子 β 量化网络结构与缺陷尺度的适配关系,建立网络深度计算准则与层级分配机制。其次,采用禁用下采样与堆叠 3×3 小卷积核的特征增强机制,以保留缺陷空间细节特征。最后,基于波纹板缺陷尺寸先验知识 ($W_{\min} = 7, W_{\max} = 21, \beta = 1.8$) 进行工业场景实例化,检测模型的构建如图 6 所示。

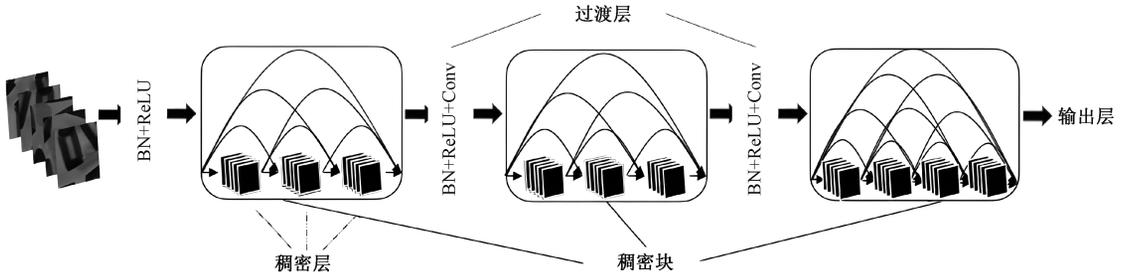


图 6 DenseNet-22 网络模型
Fig. 6 DenseNet-22 network model

2.1 DenseNet 模型

特征提取是整个模型的第 1 步,也是最重要的一步。从图像像素中提取有意义的目标特征是后续网络能有效检测出目标的前提。目标检测网络中的主干网络的功能就是实现特征提取。为了解决诸多相似区域的单一小目标检测,采用能够实现特征复用的 DenseNet 模型来设计主干网络。

2.2 网络设计原理与工业实例化

在解决单一类别多尺度小目标检测问题时,必须充分考虑目标的物理尺寸特征。主流模型结构通常感受野过大,层数过深;部分轻量化网络的不同尺寸池化层也容易导致特征信息流失。因此,需要结合检测目标的尺寸信息来指导层级结构设计、下采样取舍、卷积核尺寸选择等关键操作。在给出理论公式后,实例化波纹板缺陷检测的模型构建。

1) 感受野与缺陷尺寸匹配

设缺陷尺寸范围 (W_{\min}, W_{\max}), 步长为 1 时网络需分为 m 个 *Block*, 每个负责 (L_k, U_k), 即:

$$\sum_{k=1}^m n_k \approx W_{\max} \quad (1)$$

式中: L_k 与 U_k 分别是第 k 个 *Block* 的感受野下界与上界。

分层原则: 在特征金字塔网络 (feature pyramid network, FPN) 等多尺度架构中, 相邻特征层的尺寸倍率因子满足: $\frac{Scale_{k+1}}{Scale_k} \approx 2$, 即每个层级负责的尺寸范围是前一层级的近似 2 倍, 确保尺寸空间连续覆盖。

由此可得:

$$W_{\max} = W_{\min} \times 2^{m-1} \quad (2)$$

进行对数变换后, 可求解所需 *Block* 数量 m , 如式(3)所示。

$$m = \left\lceil \log_2 \frac{W_{\max}}{W_{\min}} \right\rceil + 1 \quad (3)$$

然而, 针对小目标检测, 需要更密集的尺寸划分以增强对小目标的捕捉能力。因此, 需将尺寸倍率因子从 2 调整为 β , ($1 \leq \beta \leq 2$)。同时, 小目标检测还需专门学习尺寸范围 ($0, W_{\min}$) 这一起始区间。改进后的 *Block* 数量 m 如式(4)所示。

$$m = \left\lceil \log_{\beta} \frac{W_{\max}}{W_{\min}} \right\rceil + 2 \quad (4)$$

此时, 每个 *Block* 负责的感受野 (对应缺陷尺寸范围), 如式(5)所示。

$$\begin{cases} Block_1 & [1 \quad W_{\min}) \\ Block_2 & [W_{\min} \quad W_{\min} \times \beta) \\ \vdots & \vdots \\ Block_m & [W_{\min} \times \beta^{m-2} \quad W_{\max}] \end{cases} \quad (5)$$

每个 *Block* 所需的卷积层数 n_k , 如式(6)所示。

$$n_k = \left\lceil \frac{U_k - L_k}{K - 1} \right\rceil \quad (6)$$

式中: K 为卷积核尺寸。

2) 下采样层与卷积核的细节增强

在小尺寸目标检测任务中, 目标通常具有较小的尺寸和较低的像素数量, 因此其对于空间信息的敏感度较高。如果对主干网络进行下采样, 将会导致分辨率的降低, 从而导致小目标的细节信息丢失, 使得模型难以精确地定位和识别这些目标。因此, 保持主干网络的原始分辨率可以更好地保留目标的细节信息, 提高小尺寸目标

检测的准确性和鲁棒性。

在小尺寸缺陷检测中,3×3 作为最小卷积核可以堆叠多层可逐步扩展感受野并精细整合细节特征,有效捕捉小目标,以及每层后的非线性激活函数使堆叠能引入更多非线性,增强模型表达能力,这对复杂细节的小目标检测尤为重要。同时,逐层构建特征的方式促进了低级特征的复用,相比大卷积核(如 5×5)更利于保留精细信息。对于小尺寸缺陷检测,缺陷信息过于集中在局部小尺寸的像素内,即固定范围内信息密度过高。

3)工业实例化

建立波纹板缺陷检测模型:

已知缺陷尺寸范围: ($W_{min} = 7, W_{max} = 21$),卷积核尺寸 $K = 3$,尺寸倍率因子 $\beta = 1.8$,可得 $m = 3$ 。每个 Block 负责的感受野范围如式(7)所示,各个 Block 所需卷积层数如式(8)所示。

$$\begin{cases} Block_1 & [1 \quad W_{min}) & [1 \quad 7) \\ Block_2 & [W_{min} \quad W_{min} \times \beta) & [7 \quad 12.6) \\ Block_3 & [W_{min} \times \beta \quad W_{max}) & [12.6 \quad 21) \end{cases} \quad (7)$$

其中,由于 $W_{min} \times \beta^2 > W_{max}$,所以 3 层就满足最大感受野的需求。

$$\begin{cases} Block_1 & n_1 = \left\lceil \frac{7-1}{3-1} \right\rceil = 3 \\ Block_2 & n_2 = \left\lceil \frac{12.6-7}{3-1} \right\rceil = 3 \\ Block_3 & n_3 = \left\lceil \frac{21-12.6}{3-1} \right\rceil = 4 \end{cases} \quad (8)$$

最终主干网络架构如表 1 所示。

表 1 主干网络架构

Table 1 Backbone network architecture

层名称	层结构	感受野/pixels
Block ₁	(1×1)×3	7×7
	(3×3)×3	
Transition ₁	(1×1)×1	7×7
Block ₂	(1×1)×3	13×13
	(3×3)×3	
Transition ₂	(1×1)×1	13×13
Block ₃	(1×1)×4	21×21
	(3×3)×4	

2.3 Faster R-CNN 模型

Faster R-CNN (faster region-based convolutional network)作为一种广泛使用的目标检测模型,引入了区域建议网络,提高了检测效率。其中锚框用于在输入图像的每个位置生成多个具有不同大小和纵横比的候选区域。微裂纹缺陷呈线状分布。由于缺陷长度不定,难以实现用任意锚框来完整囊括缺陷,但可以使用正方形锚框,包含缺陷的一部分来对结构进行简化。因为线状缺陷沿特定方向延伸,具有较小的宽度和较大的长度比。其具有局部线性特征,这些特征在每一小段都能独立呈现,无需整体学习。这样的局部特征使得检测模型能够更高效地捕捉和识别缺陷的细微部分,而不必依赖于对整个缺陷形状的全局理解。缺陷出现的区域及样本图像如图 7 所示。

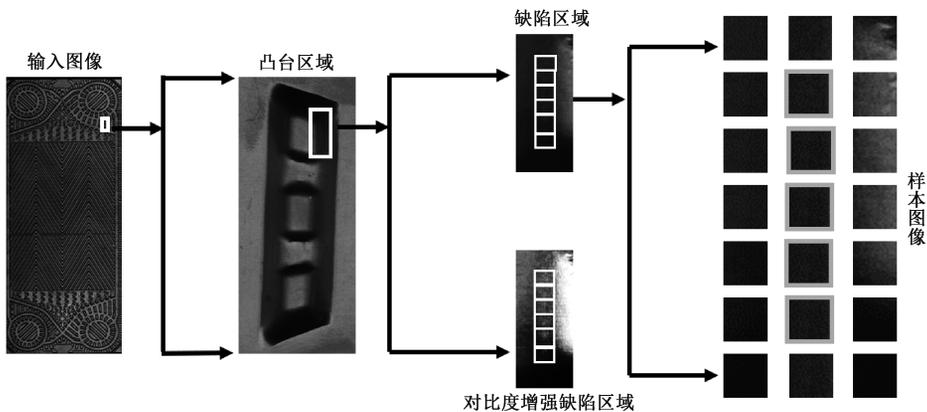


图 7 缺陷存在区域及正样本标签

Fig. 7 Defect areas and positive sample lab

3 检测网络试验结果及讨论

在本章中,首先,介绍所使用的数据集 SUT-B1;然

后,补充实现细节和评估指标;再后,对检测模型进行验证;最后,对实验结果进行分析和讨论。

3.1 数据集

为证明算法有效性,建立微裂纹图像库 SUT-B1,以

板式换热器板片为成像目标,尺寸为 1 000 mm×407 mm,微裂纹缺陷宽 0.29~0.88 mm。在真实生产环境下进行图像采集,如图 8 所示。采集系统搭建于自动化生产线上,相机工作距离为 1 185.11 mm,与镜头固定在检测移动平台上方的龙门架上,光源置于移动平台上方 35 mm 处,板材由滚轮带动前行,触发光电开关时,光源启动相机拍照。其中相机为 16 K 分辨率的线阵相机,镜头为线扫描镜头,光源为隧道光源。

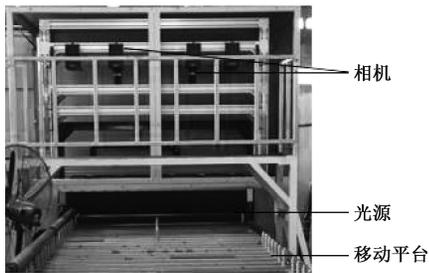


图 8 图像采集装置

Fig. 8 Image acquisition device

由于任一缺陷区域约占板片面积 0.000 2%,使用完整板片充当样本会产生大量冗余信息。因此,由先验知识可知缺陷出现于角孔区凸台,定位角孔区并截取 600 pixels×600 pixels,实际尺寸 33.22 mm×33.22 mm 的正方形区域,该区域是包含缺陷的凸台图像,去构筑正样本标签。正如第 1 章所述,缺陷呈线条状,宽度范围保持 7~21 pixels。因此样本标签只需框选住最大尺寸缺陷即可。考虑到缺陷左右邻域对缺陷的影响,将标签尺寸延拓到 24 pixels 宽。正样本及标签如图 9 所示,图 9(a)、(b)即为正样本输入图像,其中每组区域即为多个标签框堆叠而成的灰色区域即为一处缺陷实例,可知图 9(a)、(b)均为含有两处缺陷实例的图像。

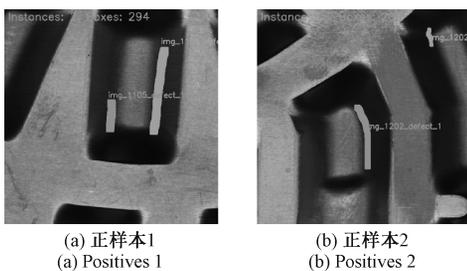


图 9 正样本及标签

Fig. 9 Positives and label

为评估本文算法在复杂工业环境下的鲁棒性与抗干扰能力,本研究在训练阶段引入了 4 类针对性强的数据增强策略,以模拟实际生产中的典型干扰场景,即:1)添加高斯噪声,模拟图像传感器在高温或低光照条件下产

生的电子噪声;2)添加亮度与对比度的随机扰动,模拟生产线上光照不均、光源老化或板片表面反光率不同带来的光照变化;3)模拟油污污染,通过添加随机深色块状区域,模拟板片表面被润滑油、冷却液等污染物部分遮盖的场景;4)混合以上 3 种干扰。通过上述增强手段,构建 4 个扩展训练集、测试集,用以验证模型的泛化能力。缺陷应用不同干扰的可视化效果如图 10 所示,图 10(a)~(e)依次展示原始数据、高斯噪声、光照扰动、模拟油污以及全部添加的混合干扰图像。

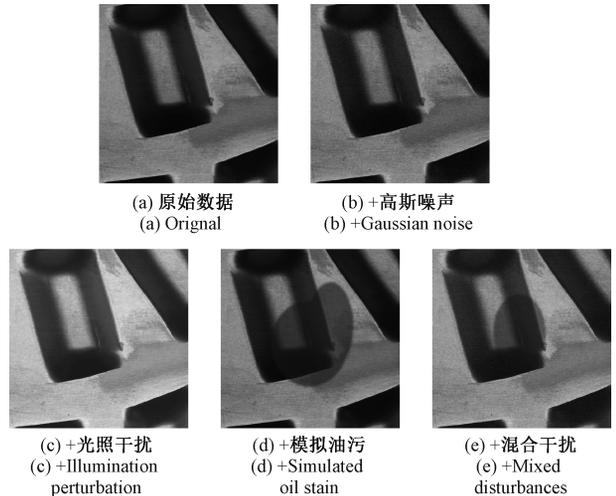


图 10 缺陷应用不同干扰的可视化效果

Fig. 10 Visualization of different disturbances applied to the defects

3.2 实验细节

主干网络不使用预训练模型去初始化,所有网络随机初始化,均不涉及下采样。训练到准确率为 95% 时停止,初始学习率为 0.001,每 1 000 次迭代后学习率降低 10%。采用随机梯度下降作为优化器,动量为 0.9,权衰减为 0.000 2。每批次迭代 1/10 的输入图像。Faster R-CNN 网络区域建议阶段只存在一组纵横比为 1:1 的锚点。

SUT-B1 训练集中包含 49 个缺陷实例,总计 4 428 个正样本标签,以及 10 572 个负样本标签。SUT-B1 测试集包含 53 个缺陷实例与 300 张无缺陷实例。模拟工厂的生产环境,后续实验在 NVIDIA RTX A2000 GPU 和 6×Intel(R) Xeon(R) CPU E5-2680 v4 @ 2.40 GHz 上实现的。

3.3 以缺陷实例为评估单元的检测评估策略

基于国家标准对波纹板缺陷检测的要求,预测框与目标区域存在交集即视为有效检测。当缺陷实例中任一局部区域被正确识别,即判定该实例检出成功。为消除局部特征学习引发的重复检测导致的评估偏差,本文提

出缺陷实例级评估策略(defect instance-level evaluation strategy, DIES)。其核心创新在于:将表征同一物理缺陷的局部真实边界框集合定义为评估单元,称为缺陷实例,取代传统方法中独立评估局部预测框的方式。

设数据集包含 N 个缺陷实例,第 k 个缺陷实例 D_k 包含 m_k 个局部真实框(ground truth, GT) g_{k,m_k} ,即:

$$D_k = \{g_{k,1}, g_{k,2}, \dots, g_{k,m_k}\}, k = 1, 2, \dots, N \quad (9)$$

模型输出的预测框集合为 B , 每个预测框 b_j 具有置信度为 s_j 。

$$B = \{b_1, b_2, \dots, b_p\} \quad (10)$$

当且仅当存在预测框 b_j 与实例 D_k 中的任意局部 GT 框 $g_{k,i}$ 满足匹配条件, 交并比(intersection over union, IoU)大于阈值时($\text{IoU}(b_j, g_{k,i}) \geq \text{Threshold}$), 判定 D_k 被成功检测。其中:

$$\text{list}(D_k) = \begin{cases} 1, & \exists b_j \in B, g_{k,i} \in D_k \text{ s. t. } \text{IoU}(b_j, g_{k,i}) \geq \text{Threshold} \\ 0, & \text{其他} \end{cases} \quad (11)$$

缺陷实例级评估策略实现流程如算法1所示。

算法1. 缺陷实例级评估策略伪代码

- 1) 输入参数: 预测框集合 $B = \{b_1, b_2, \dots, b_p\}$ 、
预测框置信度 $s_1 > s_2 > \dots > s_p$ 、
GT 框集合 $G = \{g_1, g_2, \dots, g_m\}$ 、
缺陷实例集合 $D = \{D_1, D_2, \dots, D_k\}$ 、
($D_k = \{g \in G \mid \text{defect_id}(g) = k\}$)、
交并比阈值 Threshold ;
- 2) 初始化: 创建记录列表, 长度为 P , 元素为 0;
- 3) 创建列表: 真正例标记列表 $TP_list = [0] \times p$
假正例标记列表 $FP_list = [0] \times p$
已匹配实例集合 $matched = \emptyset$
- 3) **For** $j = 1$ to P ;
- 4) 候选集:
 $C = \{\text{defect_id}(g) \mid g \in G, \text{IoU}(b_j, g) \geq \text{Threshold}\}$
- 5) 有效集:
 $V = C \setminus matched$
- 6) **If** $V \neq \emptyset$:
- 7) $k^* = \underset{k \in V}{\text{argmax}} (\underset{g \in D_k}{\text{argmax}} \text{IoU}(b_j, g))$
- 8) $TP_list[j] = 1$
- 9) $matched = matched \cup \{k^*\}$;
- 10) **Else**;
- 11) **If** $\text{IoU}(b_j, g) = 0$ **for all** $g \in G$:
- 12) $FP_list[j] = 1$
- 13) **end if**
- 14) **end if**
- 15) **end for**
- 16) 计算指标:

$$TP = |matched|$$

$$FP = \text{sum}(FP_list)$$

$$FN = N - TP$$

$$R = TP/N$$

$$P = TP/(TP + FP)$$

$$F1 = 2 \times (P \times R)/(P + R)$$

$$AP = \int_0^1 p_interp(r) dr, P_interp(r) = \max_{r > \bar{r}}$$

其中, 真正例(true positive, TP)表示实际检测出来的缺陷数; 假正例(false positive, FP)表示误检测出来的缺陷数, 称之为误检数; 假负例(false negative, FN)表示还没有检测出来的缺陷数, 称为漏检数。评价指标为: 召回率(recall, R)、精确率(precision, P)、平均精度(average precision, AP)和 $F1$ 分数($F1$ -score, $F1$)。

该策略采用实例级唯一匹配原则, 按预测置信度降序动态处理; 对每个预测框, 仅允许匹配未分配的真实缺陷实例(同一实例内取最优 IoU 框), 匹配成功的实例立即标记为已占用; 为保证实例不会被认定为假正例, 当候选实例集为空时, 仅完全零重叠的预测框被记为假正例。此机制通过双层最大化(实例间选最优实例, 实例内选最优 GT 框)确保空间定位精度, 同时严格遵守每个缺陷实例的单个匹配, 从根本上满足国家只要求检测到缺陷, 并不关注缺陷具体信息标准。使指标精准反映模型对独立实体的识别能力。

3.4 检测结果

本研究对 53 处缺陷实例与 300 张无缺陷实例进行测试。评估结果显示, 53 处缺陷实例中, 检测出 50 处, 即 $TP = 50$; 误检 5 例, 即 $FP = 5$; 漏检 3 例, 即 $FN = 3$ 。基于上述参数所得 $R = 94.34\%$, $P = 90.01\%$, $AP = 94.69\%$, $F1 = 92.60\%$ 。

本模型、基线模型、轻量化模型、DenseNet 模型变体以及本模型对比实验所得出的评价指标, 如表 2 所示。其中 Dense 层指各 Block 层数配置, 如“3, 3, 4”表示 3 个 Block 分别含 3/3/4 层; “下采样 1/2”指两个过渡层下采样状态, “F”表示关闭下采样, “T”表示开启下采样; 卷积核指主干网络卷积核尺寸, 如“3×3”表示 3×3 卷积核; 评价指标采用 R 、 P 、 AP 、 $F1$; “—”符号表示保持原始默认设置。

DenseNet-22 的检测结果如图 11 所示, 其中图 11(a)是只有一个缺陷实例的图像, 图 11(b)中的矩形表示该实例被成功检测, 三角形表示误检。图 11(c)是有 3 个缺陷实例的图像。图 11(d)的矩形展示了 3 处缺陷实例中有 2 处被检测出来, 圆形表示该处实例为漏检。

表 2 不同网络检测结果

Table 2 Detection results of different networks

网络	Dense 层	下采样 1/2	卷积核	$R/\%$	$P/\%$	$AP/\%$	$F1/\%$
DenseNet-22	3、3、4	F/F	3×3	94.34	90.91	94.69	92.60
ResNet-50	—	—	—	79.25	89.36	78.93	84.00
EfficientNet-B0	—	—	—	75.47	97.56	75.05	85.11
ShuffleNetV2	—	—	—	45.28	100.00	45.54	62.34
YOLOv8-nano	—	—	—	88.68	87.04	88.02	87.85
EfficientDet-Lite0	—	—	—	94.34	80.65	90.16	87.06
NanoDet-Plus-m-320	—	—	—	37.74	100.00	38.54	54.76
文献[19]	3、3、3	4×4×1/NAN	—	92.45	76.56	91.45	83.76
文献[21]	2、4、2	3×3×1/2×2×2	—	96.23	69.86	94.53	80.95
DenseNet-121	6、12、24、16	—	—	81.13	87.76	81.06	84.31
DenseNet-169	6、12、32、32	—	—	90.57	76.19	88.54	82.76
DenseNet-22	—	T/F	—	94.34	78.12	92.50	85.47
DenseNet-22	—	F/T	—	96.23	56.04	92.45	70.83
DenseNet-22	—	T/T	—	93.72	72.86	93.27	82.93
DenseNet-22	—	—	5×5	93.31	74.63	93.31	83.33
DenseNet-22	—	—	7×7	96.23	69.86	94.56	80.95

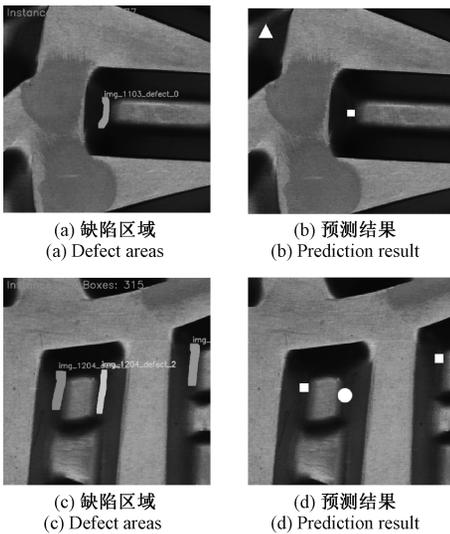


图 11 缺陷实例及预测结果

Fig. 11 Defect examples and prediction results

3.5 讨论

本节首先通过对比主流基线模型在微裂纹检测任务上的性能瓶颈,阐明了选择 DenseNet 作为主干网络的优势,即密集连接机制有效解决了浅层特征丢失问题。其次,通过与轻量化小目标检测模型及标准 DenseNet 变体的定量对比,揭示了模型结构轻量化对微裂纹检测任务性能的影响,论证了结构优化的必要

性。再次,通过系统性的参数实验,定量验证了所采用的无下采样、3×3 卷积核在保留空间细节、提升混合评价指标方面的作用,为后续专用算法设计提供了依据。最后,对模型的抗干扰能力与感受野匹配方法的差异化优势进行了验证。

1) 为什么选择 DenseNet 作为主干网络

在第 2 章中,本研究采用 DenseNet-22 作为 Faster R-CNN 的主干网络,通过浅层信息的复用,实现多尺度特征融合下的较小尺寸特征保留。为证明该网络相比于其余关注多尺度特征融合的基线主干网络在 SUT-B1 数据集上的优越性,选取残差网络(Residual Network-50, ResNet-50)、高效网络-B0(Efficient Network-B0, EfficientNet-B0)、混洗网络版本 2(Shuffle Network version 2, ShuffleNetV2)作为检测网络中的主干网络部分。

ResNet-50 其小目标捕捉能力较弱,主因是残差连接忽略浅层细节,且理论感受野 483×483 尺寸过大。在微裂纹检测场景中,过大的感受野引入冗余背景信息,干扰小目标特征学习,导致漏检。

EfficientNet-B0 其高精确率伴随低召回率,核心矛盾源于复合缩放策略对空间分辨率的压缩。在微裂纹检测任务中,深度可分离卷积与通道缩减导致浅层特征丢失,小目标在降采样过程中被稀释,引发漏检。

ShuffleNetV2 其低召回率源于通道混洗机制破坏特征连续性,且通道压缩导致小目标特征丢失。在微裂纹

检测中,浅层纹理信息因通道缩减与分组卷积被割裂,引发漏检。

因此,DenseNet-22 凭借跨层密集连接实现的浅层特征复用机制,以多尺度特征融合下的微小缺陷保留能力优于对比模型。其规避了 ResNet-50 的过大感受野、EfficientNet-B0 的空间压缩、ShuffleNetV2 的通道割裂导致小目标特征不可逆丢失,为检测提供特征基底。

2) 与轻量化小目标模型对比

因近些年来缺乏针对板式换热器板片缺陷检测的专用算法进行定量比较,为全面评估所提方法的性能,本研究选取了两类对比模型:(1)近年来工业界主流的轻量化目标检测网络,包括 YOLOv8-nano、EfficientDet-Lite 及 NanoDet-Plus,需要注意的是,EfficientDet-Lite 系列通过复合缩放生成不同大小的模型,本实验采用最轻量化的 Lite0 模型;NanoDet-Plus 系列也根据输入分辨率和模型宽度系数有着不同模型,本实验采用最轻量化的 NanoDet-Plus-m-320 模型;(2)文献中的同类轻量化小目标检测模型,如文献[19,21]旨在明确本研究方法在轻量化技术体系中的定位。

YOLOv8-nano 模型多次下采样的特性导致部分微小尺寸缺陷特征没有被学习到,形成部分漏检, R 降至 88.68%。

EfficientDet-Lite0 模型通过禁用空洞卷积和防止最后一层通道数缩放提高了浅层特征学习,但结构中的 7 个 Block 层级导致感受野膨胀,引入冗余噪声提高误检, P 较低为 80.65%。

NanoDet-Plus-m-320 模型的骨干网络是 ShuffleNetV2,特征连续性被通道混洗机制破坏,且模型瘦身的特征提取制约了多尺度特征融合能力,导致效果不佳,其 $F1$ 为 54.76%。

文献[19]的误检源于 4×4 尺寸的下采样。在缺陷检测中,3 层密集堆叠虽保留完整空间特征,但下采样吸收背景噪声,导致误检增多。

文献[21]其高召回与高误检反映出下采样操作虽提升感受野但割裂缺陷特征的连续性,导致缺陷特征在池化层被肢解、在密集层被混淆割裂。

上述模型揭示板片缺陷检测中轻量化模型的结构性缺陷,即追求 R 峰值需牺牲 P ,导致混合指标下降,而抑制噪声则破坏特征连续性。

本方法构建了基于缺陷物理特性的可解释轻量模型,将波纹板裂纹物理参数转化为可量化的网络结构参数,为工业小目标检测提供可复现,可解释的结构设计,克服了轻量化模型中压缩导致的特征丢失问题。

3) 与 DenseNet 标准模型对比

如 DenseNet-121/169 的标准深层模型虽具有大感受野,但过深的网络层次导致特征图在传递过程中不可逆

地丢失空间细节。为验证 Block 深度优化的必要性,表 2 的第 10 和 11 行对比了不同深度主干网络的性能。从 AP 与 $F1$ 的混合指标分析,DenseNet-22 的 AP 值达 94.69%,较主干网络 DenseNet-169 的 88.54% 提升 6.15%;DenseNet-22 的 $F1$ 值达 92.60%,较主干网络 DenseNet-121 的 84.31% 提升 8.29%。因此,Block 深度是决定微小目标检测性能的因子之一。

4) 下采样的需求

在小目标检测任务中,由于目标尺寸较小且像素数量有限,空间信息的保留会影响检测结果。下采样操作会压缩特征图分辨率,导致细节丢失。为证明 DenseNet-22 去除下采样的意义,表 2 的第 12~14 行对比了网络中下采样配置影响。从 AP 与 $F1$ 的混合指标分析,无下采样配置 (F/F) 的 AP 值达 94.69%,较配置 (T/T) 的 93.27% 提升 1.42%。无下采样配置的 $F1$ 达 92.60%,较配置 (T/F) 的 85.47% 提升 7.13%。可见,去除下采样可避免特征图分辨率损失,保留空间细节,提升混合评价指标。

5) 卷积核尺寸对比

通过堆叠多个 3×3 卷积层,网络能在保留高分辨率信息的同时逐步扩大感受野,逐层聚合局部细节,增强对小目标的捕捉能力。表 2 的第 15、16 行对比了不同卷积核尺寸的检测效果,从 AP 与 $F1$ 的混合指标分析, 3×3 卷积核配置的 AP 值达 94.69%,较配置 (7×7) 的 94.56% 提升 0.13%。 3×3 卷积核配置的 $F1$ 达 92.60%,较配置 (5×5) 的 83.33% 提升 9.27%。所以,优先采用堆叠 3×3 卷积替代大尺寸卷积核,通过分层特征融合实现感受野扩展与细节保留的协同优化,有助于提升混合评价指标。

6) 漏检与误检分析

实例检测结果有漏检与误检存在。

漏检现象主要归因于模型学习的特征局限于局部线状信息。此类信息在背景区域中同样存在,但缺陷的局部特征与其整体结构存在关联,而背景则不具备这种关联性。模型在测试阶段进行实例化检测时才引入这种局部与整体的关系。因此,在 Faster R-CNN 流程中的区域提议网络阶段时,缺陷区域得分低于具有类似局部特征的背景区域,导致其被低分淘汰,最终形成漏检。

在分析误检情况时发现,尽管某些区域在模型感受野内符合学习到的线状灰度分布特征,但由于真实缺陷需要由一组具有方向连续性的标签锚框组合才能完整表征,而模型生成的单一或少数离散预测框无法构成有效的缺陷实例。这表明模型在训练过程中未能充分掌握缺陷实例所必需的方向连续性组合特征,导致将符合局部线状特征但缺乏方向连续性的非缺陷区域错误判定为缺陷,反映出模型对方向连续性特征的学习不足。

7) 抗干扰能力分析

为验证模型在复杂工况下的稳定性,在 SUT-B1 测试集的基础上,应用了 3.1 节数据增强方法生成了 4 种干扰测试集,并与原始测试结果进行对比。所有测试均采用相同的模型权重及评估策略。测试结果如表 3 所示。单一干扰下模型仍保持较高性能,其中光照扰动对 R 无影响,仅使 P 降低,表明模型对光照变化具有适应性;然而油污污染导致 AP 下降,反映出物理遮挡对线状微小裂纹检测的影响。在混合干扰的极端条件下,模型 $F1$ 降至 83.49%,但 R 仍维持在 81.13%。该结果证实了本文所提无下采样架构与小卷积核堆叠策略在保留空间细节上的有效性。尽管混合干扰下性能有所衰减,但模型未出现灾难性失效,证明其具备工程化部署的鲁棒性基础。

表 3 抗干扰能力检测结果

Table 3 Results of anti-interference ability test

测试条件	R	P	AP	$F1$
原始测试集	94.34	90.91	94.69	92.60
+高斯噪声	88.68	85.45	86.59	87.03
+光照扰动	94.34	87.72	93.54	90.90
+模拟油污	84.91	91.84	82.55	88.24
+混合干扰	81.13	86.00	79.68	83.49

8) 感受野匹配模型的差异化优势验证

为凸显本文所提感受野匹配模型的独特性,系统性对比了主流感受野自适应方法,结果如表 4 所示。ASPP 通过空洞采样扩大感受野,但 7 pixels 微裂纹特征在采样间隔中被稀释,导致微小目标 R 降至 84.91%;RFB 的多尺度分支特征融合引发裂纹与相似纹理的误关联,造成误检率增加,使 P 仅为 59.46%;DRConv 的动态核权重学习在 53 个缺陷样本的小样本场景严重过拟合,将背景噪声误判为缺陷特征。相较于上述感受野匹配方法,本文的差异化优势在于:将裂纹宽度转化为可量化层级配置参数,区别于经验式调参方法;通过无下采样架构与 3×3 卷积堆叠,区别于空洞卷积和多尺度融合,实现特征保真。

表 4 感受野自适应方法在测试集上的性能对比

Table 4 Performance comparison of receptive field adaptive methods on test set

检测方法	R	P	AP	$F1$
本文方法	94.34	90.91	94.69	92.60
ASPP	84.91	88.24	82.17	86.53
RFB	83.02	59.46	79.66	69.31
DRConv	90.57	69.57	88.62	78.79

4 结 论

针对钢材表面微尺度裂纹缺陷检测中浅层特征提取不足的问题,提出了一种基于轻量化 DenseNet 结构的检测算法。该方法建立了缺陷物理尺寸与网络参数的定量关联模型,通过层级配置公式优化了小目标的识别能力。工程应用中,结合先验知识对模型参数进行实例化,使其更适应微裂纹的形态特征,从而提升检测性能。实验结果表明,所提方法在 SUT-B1 数据集上获得了优于主流对比模型的性能。综上所述,本方法通过结构与参数的协同设计,有效增强了微小缺陷的检测能力,为工业质量检测提供了解决方案。

参考文献

- [1] 国家质量技术监督局,全国钢标准化技术委员会. 金属弯曲试验方法: GB/T 232—1988[S]. 北京:中国标准出版社,1988.
The State Bureau of Quality and Technical Supervision, Technical Committee 183 on Steel of Standardization Administration of China. Metallic materials-bend test: GB/T 232—1988[S]. Beijing: China Standards Press, 1988.
- [2] 国家能源局,全国锅炉压力容器标准化技术委员会. 板式热交换器第 1 部分:可拆卸板式热交换器: NB/T 47004.1—2017[S]. 北京:北京科学技术出版社,2017.
National Energy Administration, China Standardization Committee on Boilers and Pressure Vessels. Plate heat exchangers—part 1: Plate-and-frame heat exchangers: NB/T47004.1—2017[S]. Beijing: Beijing Science and Technology Press, 2017.
- [3] 苑玮琦,赵佩瑶. 基于 Canny 的自适应换热器板片边缘检测方法[J]. 计算机技术与发展, 2021, 31(11): 81-85, 94.
YUAN W Q, ZHAO P Y. An adaptive edge detection method for plate of heat exchanger based on Canny[J]. Computer Technology and Development, 2021, 31(11): 81-85, 94.
- [4] 陈绍奇. 板式换热器板片缺陷检测方法研究[D]. 沈阳:沈阳工业大学,2022.
CHEN SH Q. Research on detection method of plate defects in plate heat exchanger[D]. Shenyang: Shenyang University of Technology, 2022.
- [5] MA CH, LI ZH G, XUE Y Y, et al. High-frequency dual-branch network for steel small defect detection[J].

- Arabian Journal for Science and Engineering, 2025, 50(10): 7409-7421.
- [6] LU J B, YU M M, LIU J Y. Lightweight strip steel defect detection algorithm based on improved YOLOv7 [J]. Scientific Reports, 2024, 14(1): 13267.
- [7] 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.
- LIU X, CHEN CH, SHUANG F. Multi-type insulator detection algorithm based on improved YOLOv7-tiny[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 101-110.
- [8] 张莹, 邓华宣, 王耀南, 等. 基于多通道特征融合学习的印制电路板小目标缺陷检测[J]. 仪器仪表学报, 2024, 45(5): 10-19.
- ZHANG Y, DENG H X, WANG Y N, et al. Small defects detection of PCB based on multi-channel feature fusion learning[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 10-19.
- [9] 张永宏, 许鑫豪, 尹贺峰, 等. MFSF-DETR: 一种基于多尺度特征移位融合的 PCB 缺陷与元件检测算法[J]. 仪器仪表学报, 2025, 46(8): 266-285.
- ZHANG Y H, XU X H, YIN H F, et al. MFSF-DETR: A PCB defect and component detection algorithm based on multi-scale feature shift fusion[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 266-285.
- [10] 赵云亮, 唐东林, 何媛媛, 等. 基于 CNN 融合 PGW-Attention 的金属表面缺陷识别方法[J]. 电子测量与仪器学报, 2024, 38(8): 46-55.
- ZHAO Y L, TANG D L, HE Y Y, et al. Metal surface defect recognition method based on CNN with PGW-Attention [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 46-55.
- [11] CAO Z H, WANG T, SUN P, et al. ScorePillar: A real-time small object detection method based on pillar scoring of LiDAR measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 8503313.
- [12] WANG W, MENG Y Z, LI SH, et al. HV-YOLOv8 by HDPconv: Better lightweight detectors for small object detection[J]. Image and Vision Computing, 2024, 147: 105052.
- [13] ZHOU W, WANG X D, FAN Y SH, et al. KDSMALL: A lightweight small object detection algorithm based on knowledge distillation [J]. Computer Communications, 2024, 219: 271-281.
- [14] JIANG L J, YUAN B X, DU J W, et al. MFFSODNet: Multiscale feature fusion small object detection network for UAV aerial images [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5015214.
- [15] LIU Q, LYU J, ZHANG C P. MAE-YOLOv8-based small object detection of green crisp plum in real complex orchard environments[J]. Computers and Electronics in Agriculture, 2024, 226: 109458.
- [16] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. 2018 European Conference on Computer Vision, 2018: 801-818.
- [17] LIU S T, HUANG D, WANG Y H. Receptive field block net for accurate and fast object detection [C]. 2018 European Conference on Computer Vision, 2018: 385-400.
- [18] CHEN J, WANG X J, GUO Z CH, et al. Dynamic region-aware convolution[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 8064-8073.
- [19] 孙晓春, 丁华, 牛锐祥, 等. 基于 LW-DenseNet 的采煤机摇臂齿轮故障诊断[J]. 煤炭工程, 2023, 55(11): 186-192.
- SUN X CH, DING H, NIU R X, et al. Fault diagnosis of rocker gear of shearer based on LW-DenseNet [J]. Coal Engineering, 2023, 55(11): 186-192.
- [20] 张国忠, 吕紫薇, 刘浩蓬, 等. 基于改进 DenseNet 和迁移学习的荷叶病虫害识别模型[J]. 农业工程学报, 2023, 39(8): 188-196.
- ZHANG G ZH, LYU Z W, LIU H P, et al. Model for identifying lotus leaf pests and diseases using improved DenseNet and transfer learning[J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(8): 188-196.
- [21] LIU M X, DENG H J, DONG W. Identification of mangrove invasive plant derris trifoliata using UAV images and deep learning algorithms[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 10017-10026.
- [22] CHENG L, YI J ZH, CHEN AI B, et al. Fabric material identification based on DenseNet variant networks [J]. The Journal of The Textile Institute, 2023, 114(10): 1527-1538.

- [23] DHEERAJ A, CHAND S. LWDN: Lightweight DenseNet model for plant disease diagnosis [J]. *Journal of Plant Diseases and Protection*, 2024, 131(3): 1043-1059.
- [24] CHEN ZH D, JI H B, ZHANG Y Q, et al. High-resolution feature pyramid network for small object detection on drone view [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2023, 34(1): 475-489.
- [25] CHEN SH J, JI L P, ZHU S CH, et al. MICPL: Motion-inspired cross-pattern learning for small-object detection in satellite videos [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 36(4): 6437-6450.
- [26] LIU B, JIANG W Q. LA-YOLO: Bidirectional adaptive feature fusion approach for small object detection of insulator self-explosion defects [J]. *IEEE Transactions on Power Delivery*, 2024, 39(6): 3387-3397.
- [27] ZHU ZH Q, ZHENG R ZH, QI G Q, et al. Small object detection method based on global multi-level perception and dynamic region aggregation [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2024, 34(10): 10011-10022.

作者简介



苑玮琦, 1982 年于湖南大学获得学士学位, 分别在 1988 年和 1997 年于东北大学获得硕士、博士学位, 现为沈阳工业大学的教授和博导, 主要研究方向为生物特征识别和机器视觉。

E-mail: yuan60@126.com

Yuan Weiqi received his B. Sc. degree from Hunan University in 1982, his M. Sc and Ph. D degrees both from Northeastern University in 1988 and 1997, respectively. He is currently a professor and doctoral supervisor at Shenyang University of Technology. His main research interests include machine vision detection and biometric identification.



丁志博(通信作者), 2016 年于沈阳工业大学获得学士学位, 现为沈阳工业大学视觉检测研究所博士研究生, 主要研究方向为机器视觉检测。

E-mail: 1695626118@qq.com

Ding Zhibo(Corresponding author) received his B. Sc. degree from Shenyang University of Technology in 2016. He is currently a Ph. D. candidate in Computer Vision Group at Shenyang University of Technology. His main research interest includes machine vision.