

# 一种轻量级高效 X 射线焊缝图像缺陷检测方法

王睿<sup>1,2</sup>, 高少泽<sup>1</sup>, 刘卫朋<sup>1</sup>, 王刚<sup>2</sup>

(1. 河北工业大学, 人工智能与数据科学学院, 天津, 300131; 2. 哈尔滨工业大学, 先进焊接与连接国家重点实验室, 哈尔滨, 150001)

**摘要:** 针对当前深度学习模型在焊缝缺陷检测工作中成本高、速度慢、不易在终端部署应用等问题, 提出一种效果良好的轻量级高效模型 (lightweight and high-precision optimized detection model, LHODM). 首先, 搭建新型主干网络并设计超轻量卷积 ULConv 作为网络基础卷积, 降低模型深度, 用 Depthwise 操作生成更多有效冗余特征映射, 减少参数与运算量. 其次, 设计高效轻量级专注模块 ELCC, 在响应模型轻量化前提下, 考虑焊缝缺陷分布特性与成像规律, 从水平和垂直两个方向捕获孤立区域关系, 结合轻量级上采样算子 CARAFE, 使模型特征重组时具有更大的感受野, 更有效地利用环境周围信息, 弥补轻量化造成的精度损失. 最后, 为提高收敛速度和损失函数效率, 设计 OS-IoU 损失函数, 考虑期望回归向量之间的夹角, 重新定义惩罚项及相关性, 强化距离损失和形状损失关注程度. 结果表明, LHODM 模型检测准确率和检测速度达到 91.62% 和 63.47 帧/s, 参数量仅为 3.99 M, 有效解决了焊缝缺陷检测工作中成本高和速度慢的问题.

**创新点:** (1) 提出了新型主干网络与超轻量卷积, 实现网络轻量化.

(2) 提出了高效轻量级专注模块, 解决因焊缝分布特性导致的检测精度损失.

(3) 分析了轻量级上采样算子, 缓解图像低对比度造成的无法全面利用环境信息现象.

(4) 提出了新型损失函数, 强化距离损失和形状损失, 提高模型效率.

**关键词:** 缺陷检测; 焊缝; 深度学习; 目标检测; 轻量化

**中图分类号:** TG 441 **文献标识码:** A **doi:** 10.12073/j.hjxb.20230630003

## A lightweight and efficient X-ray weld image defect detection method

WANG Rui<sup>1,2</sup>, GAO Shaoze<sup>1</sup>, LIU Weipeng<sup>1</sup>, WANG Gang<sup>2</sup>

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin, 300131, China; 2. State Key Laboratory of Advanced Welding and Joining, Harbin Institute of Technology, Harbin, 150001, China)

**Abstract:** In response to the high cost, slow speed, and difficulty in deploying deep learning models in weld defect detection, this paper proposes a lightweight and high precision optimized detection model (LHODM) with good performance. Firstly, a new backbone network is built and an ultra lightweight convolutional ULConv is designed as the network foundation convolution to reduce model depth, and Depthwise operation was used to generate more effective redundant feature mappings, reducing the amount of parameters and computation. Secondly, an efficient and lightweight dedicated module ELCC is designed. Under the premise of lightweight response model, the distribution characteristics of weld defects and imaging rules are considered, and the relationship between isolated areas is captured from both horizontal and vertical directions. Combined with the lightweight up-sampling operator CARAFE, the model has a larger receptive field during feature recombination, makes more effective use of ambient information, and makes up for the loss of lightweight accuracy. Finally, in order to improve convergence speed and loss function efficiency, an OS-IoU loss function is designed, taking into account the angle between the expected regression vectors, redefining the penalty term and correlation, and strengthening the attention to distance loss and shape loss. The results showed that the LHODM model achieved detection accuracy and speed of 91.62% and 63.47 frames per second, with a model memory cost of only 3.99 million, effectively solving the problems of high cost and slow speed in weld defect detection work.

**Highlights:** (1) A new backbone network and ultra lightweight convolution were proposed to achieve network lightweighting.

(2) An efficient and lightweight focused module was proposed to address the loss of detection accuracy caused by the distribution characteristics of weld seams.

(3) Lightweight upsampling operators were analyzed to alleviate the phenomenon of insufficient utilization of environmental information caused by low image contrast.

(4) A new loss function was proposed to enhance distance loss and shape loss, and improve model efficiency.

**Key words:** defect detection; weld; deep learning; object detection; lightweight

## 0 序言

焊接技术是工业热工艺加工当中使用率较高的技术之一,在实际工业中,由于材料本身和外部环境等问题,会在焊接部位形成不同程度的缺陷,如未熔合、裂纹等<sup>[1]</sup>,拥有可靠的焊缝缺陷检测技术对保证工艺质量具有重大意义.在传统的焊缝图像缺陷检测工作中,主要以人工检测 X 射线焊缝图像为主<sup>[2]</sup>,由于焊缝缺陷形成复杂,且易受检测人员主观判断影响,给检测工作带来很大困难<sup>[3]</sup>.随着智能技术的推进,深度学习模型在焊缝缺陷检测领域表现突飞猛进,卷积神经网络通过反向传播学习目标特征,可以有效解决 X 射线焊缝缺陷检测问题.国内外学者就此问题进行了研究,Xu 等人<sup>[4]</sup>基于卷积神经网络的迁移学习,研究设计域间异构迁移学习方法,对焊缝缺陷检测进行探索.Liang 等人<sup>[5]</sup>采用卷积注意力模块,提出跨模态注意关注焊缝图像的关键区域,提高了焊缝缺陷检测的精度.Razfar 等人<sup>[6]</sup>使生成对抗网络和深度卷积神经网络结合,提高了低对比度的焊缝图像检测效果.但上述几种模型参数量大、浮点运算多,在提升检测精度的同时增大了计算量,造成了成本高、检测速度低和实用性较差等棘手难题.

在实际生产中,由于需要更快速地处理数据,避免与远程服务器交换不可靠的数据,大多应用需要在靠近数据源的边缘设备上本地部署模型,性能与成本也因此受到限制.高性能模型成本极高,快速检测的轻量级模型又伴随一定精度损失,越来越多的学者对于模型轻量化的问题进行研究.Liu 等人<sup>[7]</sup>设计了高效特征提取模块,低成本处理输入数据,提升了网络在焊缝缺陷检测工作中的工业实用性.Zhu 等人<sup>[8]</sup>改进了 RenNet 网络从而实现模型轻量化,结合注意力机制和边界抗混叠模块,获得了不错的焊缝缺陷检测速度.Yang 等人<sup>[9]</sup>提出一个小尺寸预训练 SqueezeNet 模型,并将其部署到树莓派

嵌入式系统中,响应时间缩短.上述模型实现了参数量下降、检测速度上升,但是检测精度也因未全面学习缺陷特征而下降,现阶段模型仍存在难以合理平衡精度和检测速度的问题.

针对平衡精度和检测速度的问题,本文优先从网络轻量化入手,搭建新型主干网络,降低模型深度,设计超轻量卷积方式,使用 Depthwise 卷积用更少代价生成更多有效冗余特征映射,减少模型参数量和浮点运算数,实现网络轻量化.模型轻量化伴随精度损失是由于焊缝缺陷分布散乱的特征和部分缺陷种类成像间断导致未全面学习缺陷特征所致,适当的跨通道交互可以在显著降低模型复杂度的同时保持性能.因此,设计高效轻量级专注模块,从水平和垂直两个方向捕获孤立区域关系,结合轻量级上采样算子,使模型特征重组时具有较大感受野,更好地利用周围信息,弥补网络轻量化造成的精度损失.最后,设计 OS-IoU 损失函数,提高损失函数效率,强化距离损失和形状损失关注程度,重新定义惩罚项及相关性,提高模型预测精度.总之,本文采用先轻量化后弥补精度损失的方案,提出了一种轻量级高效 X 射线焊缝图像缺陷检测方法(LHODM),对 X 射线焊缝缺陷检测工作的相关研究及实际应用具有一定的指导意义.

## 1 试验方法

文中设计的 LHODM 模型结构如图 1 所示,依据参考文献[10]的 YOLOv5s 网络架构设计新型主干网络,如图 1(a)所示,由 1 个常规卷积与 4 个 ULConv 卷积组成,该操作有效降低了模型深度和模型参数量,方便模型在嵌入式设备终端部署,完成焊缝检测工作.通过对比深度神经网络提取特征图发现存在较多相似特征图,而丰富甚至冗余的特征信息通常可以保证网络对输入的全面理解.由此设计 ULConv 卷积,使用廉价操作生成更多特征映

射,缓解生成相似特征的卷积带来的参数量增加问题,降低计算成本,同时充分揭示内在特征背后信息.图 1 中的 ULConv 结构由 Lweightconv 和 C3Lweight 组成,其中核心组件 Lweight 由常规卷积生成不含冗余的特征图 1,再由特征图 1 通过

Depthwise 卷积生成特征图 2<sup>[11]</sup>,Depthwise 卷积中卷积核只与一个特征通道卷积,改变特征图大小而不改变通道数,缩减卷积成本,最后将特征图 1 和特征图 2 拼接.改进后的卷积方式参数量大幅减少,降低了模型对内存和计算资源的需求.

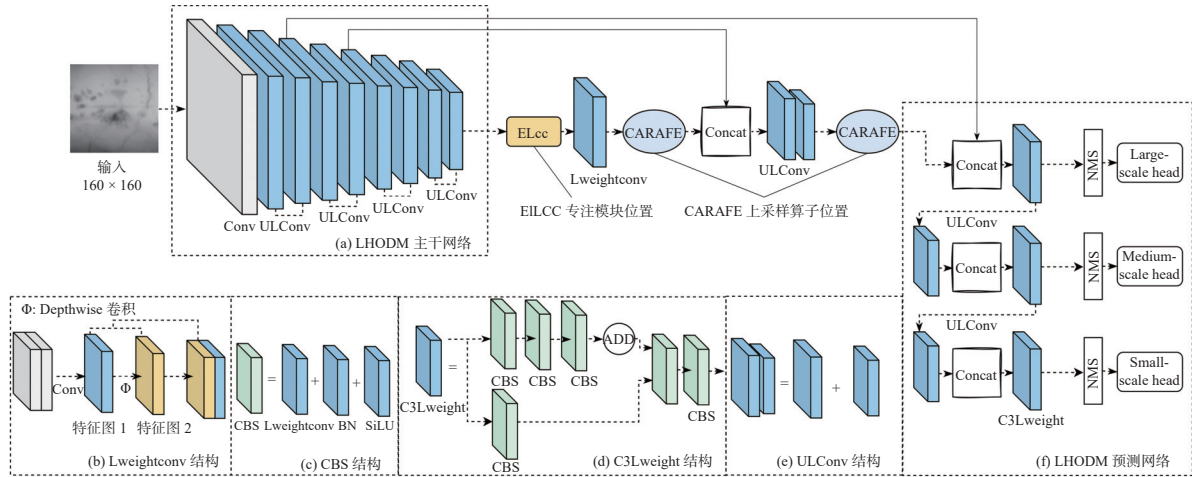


图 1 LHODM 模型结构图

Fig. 1 Model structure diagram of LHODM

模型轻量化会带来精度损失的问题,为弥补精度损失,考虑到适当的跨通道交互可以显著降低模型复杂度的同时保持性能,设计高效轻量化专注模块 ELCC,该模块只涉及少量参数,结构如图 2 所示.由于焊缝缺陷具有分布散乱且缺陷不连通特点,对于维度为  $W \times H \times C$  的输入特征图,通过条纹池化将输入特征图分别进行水平条纹池化处理和垂直条纹池化处理,得到双方向上的对应单列池

化特征,分别使用一个 1D 卷积,将单列池化特征进行同方向扩展,最后将水平方向的条纹池化扩展图与垂直方向的条纹池化扩展图进行融合.经过一个  $1 \times 1$  卷积和 Sigmoid 层,与原输入进行对应元素相乘,得到最终输出.完成对空间信息进行压缩操作后,获得  $1 \times 1 \times C$  的中间特征图.对压缩后特征图,使用自适应动态卷积核做  $1 \times 1$  卷积进行通道特征学习,学习不同通道之间的重要性.




图 2 ELCC 模块原理图

Fig. 2 Schematic diagram of ELCC module

学习完成后将通道注意力特征图和原始输入特征图进行通道相乘,最终输出具有通道专注的特征图.条纹池化可以捕获孤立区域的长距离关系,在空间维度上保持较窄的内核形状,便于捕捉局部上下文信息,防止无关区域干扰标签预测,ELCC 模块的设计,不仅响应轻量化需求,还有效缓解主干网络轻量化带来的精度损失问题.

传统上采样具有诸多不足,如最近邻上采样和双线性上采样仅通过像素点空间位置来决定上采样核<sup>[12-13]</sup>,没有利用到语义信息,且感知域很小,如文献[14]的 Deconvolution,对于特征图每个位置都是应用相同上采样核,不能捕捉到特征图内容信息,且引入了大量参数和计算量.理想上采样应具有较大感受野,可以更好地利用周围信息,具

备轻量化特点且和特征图语义信息相关. CARAFE 算子首先利用输入特征图来预测上采样核, 每个位置上采样核均不相同, 基于预测的上采样核进行特征重组. 同时, CARAFE 参数量低、运算量小, 响应轻量化需求. CARAFE 分为两个模块, 分别是上采样核预测模块和特征重组模块, 结构如图 3 所示. 上采样核预测模块, 对于形状为  $H \times W \times C$  的输入特征图, 使用一个  $1 \times 1$  卷积将通道数压缩到  $C_m$ , 该步骤是为了减少后续计算量. 对压缩后的输入特征图, 使用卷积预测上采样核, 输入通道数为  $C_m$ , 随后将通道维在空间维展开, 得到新上采样核, 最后利用 softmax 方法进行归一化, 使卷积核权重和为 1. 特征重组模块, 对于输出特征图中全部位置, 将其映射回输入特征图, 取出以之为中心的  $K_{up} \times K_{up}$  区域与预测出该点上采样核做点积运算, 得到输出值, 相同位置的不同通道共享用一个上采样核<sup>[15]</sup>.

传统边界框损失函数 CIoU, 并没有考虑真实框和预测框之间的方向, 导致模型收敛速度缓慢或无法有效收敛. 为进一步考虑真实框和预测框之间的向量角度, 本文设计 OS-IoU 损失函数如图 4 所示, 重新定义惩罚项及其相关性, 考虑期望回归向量之间的夹角, 强化距离损失和形状损失关注程度. OS-IoU 损失函数包含 4 个部分, 分别为角度损失、距离损失、形状损失和 IoU 损失. OS-IoU 角度损失  $\Lambda$  的示意图如图 4(a) 所示, 公式为

$$\Lambda = 1 - 2 \times \sin^2 \left( \arcsin \left( \frac{c_h}{\sigma} \right) - \frac{\pi}{4} \right) \quad (1)$$

$$\Lambda = \cos \left( 2 \times \left( \arcsin \left( \frac{c_h}{\sigma} \right) - \frac{\pi}{4} \right) \right) \quad (2)$$

$$c_h = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y}) \quad (3)$$

$$\sigma = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2} \quad (4)$$

式中:  $\sigma$  为真实框和预测框中心点距离;  $c_h$  为真实框




图 3 CARAFE 原理图

Fig. 3 Schematic diagram of CARAFE




图 4 OS-IoU 损失

Fig. 4 OS-IoU loss .(a) angle loss; (b) distance loss; (c) IoU loss



和预测框中心点的高度差;  $(b_{c_x}^{\text{gt}}, b_{c_y}^{\text{gt}})$  为真实框中心坐标;  $(b_{c_x}, b_{c_y})$  为预测框中心坐标。

OS-IoU 距离损失  $\Delta$  的示意图如图 4(b) 所示, 公式为

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma \rho_t}) = 2 - e^{-\gamma \rho_x} - e^{-\gamma \rho_y} \quad (5)$$

$$\rho_x = \left( \frac{b_{c_x}^{\text{gt}} - b_{c_x}}{c_w} \right)^2 \quad (6)$$

$$\rho_y = \left( \frac{b_{c_y}^{\text{gt}} - b_{c_y}}{c_h} \right)^2 \quad (7)$$

$$\gamma = 2 - \Delta \quad (8)$$

式中:  $c_w$  为真实框和预测框最小外接矩形的宽;  $\gamma$ ,  $\rho_x$ ,  $\rho_y$  为公式的中间量。

OS-IoU 形状损失  $\Omega$  的公式为

$$\Omega = (1 - e^{-w_w})^\theta + (1 - e^{-w_h})^\theta \quad (9)$$

$$\Omega = \sum_{t=w,h} (1 - e^{-w_t})^\theta \quad (10)$$

$$w_w = \frac{|w - w^{\text{gt}}|}{\max(w, w^{\text{gt}})} \quad (11)$$

$$w_h = \frac{|h - h^{\text{gt}}|}{\max(h, h^{\text{gt}})} \quad (12)$$

式中:  $w$  为预测框的宽;  $h$  为预测框的高;  $w^{\text{gt}}$  为真实框的宽;  $h^{\text{gt}}$  为真实框的高;  $\theta$  控制对形状损失的关注程度。

OS-IoU 损失函数中 IoU 损失  $\Psi$  如图 4(c) 所示, 公式为

$$\Psi = \frac{|A \cap B|}{|A \cup B|} \quad (13)$$

式中:  $A$  为物体真实边框;  $B$  为预测边框。

OS-IoU 损失函数的定义为

$$L_{\text{OS-IoU}} = 1 - \Psi + \frac{2(\Delta + \Omega)}{3} \quad (14)$$

LHODM 网络损失函数由矩形框损失函数  $L_r$ 、目标置信度损失函数  $L_o$ 、目标分类概率损失函数  $L_c$  组成。网络中矩形框损失函数采用 OS-IoU, 目标置信度损失、目标分类概率损失采用二分类交叉熵损失 (binary cross entropy loss, BCE)<sup>[16]</sup>, 损失函数  $L$  公式为

$$L_B = -\frac{1}{j} \sum_j [k \ln c + (1 - k) \ln(1 - c)] \quad (15)$$

$$L = n \times L_r + m \times L_o + r \times L_c \quad (16)$$

$$n + m + r = 1 \quad (17)$$

式中:  $L_B$  为二分类交叉熵损失;  $k$  为目标信息;  $c$  为预测输出信息;  $j$  为样本总量;  $n$ ,  $m$ ,  $r$  分别为  $L_r$ ,  $L_o$ ,  $L_c$  3 大损失加权和, 且权重和为 1。

## 2 试验准备

### 2.1 数据集

在实际工业中, X 射线焊缝常见缺陷分为内部缺陷和外部缺陷。常见缺陷有夹渣 (s)、咬边 (u)、裂纹 (c)、气孔 (p)、未焊透 (lop)、未熔合 (lof)。文中采用的数据集是由中国石油天然气管道科学研究院和 GDXray 公共数据库提供的缺陷底片样本共同组成<sup>[17]</sup>, 由于焊缝图像尺寸不协调, 长宽比过大, 遂使用先验知识对现有数据集图像进行裁剪, 共获得尺寸大小为  $160 \times 160$  像素的缺陷图像 2 647 张, 其中涉及缺陷分别为裂纹缺陷图像 486 张、未熔合缺陷图像 498 张、未焊透缺陷图像 482 张、气孔缺陷图像 502 张、夹渣缺陷图像 499 张、咬边缺陷图像 180 张。为方便后续模型训练, 提前将图像划分为训练集、验证集和测试集, 划分比例为 7:2:1, 最终得到训练集图像 1851 张、验证集图像 527 张、测试集图像 269 张。

### 2.2 试验环境

试验基于 Windows64 位操作系统, 硬件配置为: 中央处理器 (CPU) 为 AMD Ryzen 7 5800H with Radeon Graphics, 显卡使用 NVIDIA GeForce RTX 3060 Laptop GPU, 在 Pytorch 框架下进行。初始学习率设置为 0.001, 迭代 300 次, Batch-size 大小为 64。

### 2.3 性能指标

为客观、有效地对模型性能及改进模型效果进行评价, 文中使用评价指标为准确率  $P$ 、召回率  $R$ 、均值平均精度  $P_{A0.5}$ 、参数量  $P_M$  和每秒传输帧数  $F_{PS}$ 。其中准确率  $P$  表示预测为真的样本中正样本数所占整个样本比例, 召回率  $R$  表示在所有真实情况为正的样本中预测为真的样本数所占比例。平均精度  $P_A$  是不同召回率下准确率的平均值, 均值平均精度  $\bar{P}_A$  表示不同类别的  $P_A$  值的平均值。  $P_{A0.5}$  表示 IOU 设置为 0.5 时, 计算每个类别的  $P_A$  均值。具体公式为

$$P = \frac{P_T}{P_T + P_F} \quad (18)$$

$$R = \frac{P_T}{P_T + N_F} \quad (19)$$

$$\bar{P}_A = \frac{1}{q} \sum_{i=1}^q P_{Ai} \quad (20)$$

式中:  $P_T$  表示预测为真的正样本;  $N_F$  表示预测为假的负样本;  $P_F$  表示预测为假的正样本;  $q$  表示类别数;  $P_{Ai}$  表示第  $i$  个类别的  $P_A$  值<sup>[18]</sup>.

### 3 试验结果与分析

#### 3.1 模型训练结果

图 5 为 LHODM 模型训练曲线, 其中包括  $F_1$ -C、 $P$ -C、 $R$ -C、 $P$ -R 曲线.  $F_1$ -C 曲线是精确率和召回率的调和平均值, 一般来说, 置信度阈值较低时, 较多置信度低的样本会被认为真, 召回率高, 精确率低; 相反置信度阈值较高时, 置信度高的样本才能被认为是真, 检测结果就会越准确;  $P$ -C 曲线, 当置信度越大时, 类别检测越准确;  $R$ -C 曲线, 当置信度越小时, 类别检测越全面;  $P$ -R 曲线体现精确率和召回率的关系, 通常希望在准确率很高的前提下, 尽可能地找到全部缺陷类别, 因此曲线面积越接近 1, 模型效果越好. 整体来看, 模型训练结果良好, 在保证一定准确率的前提下, 可实现对缺陷类别的全面识别. 由模型训练结果来看, 训练 300 轮次后, 各项曲线基本收敛,  $\bar{P}_A$  值已收敛, 达到稳定状态, 通常认为可以结束训练并获取模型权重.

#### 3.2 对比试验结果

为证明文中模型性能平衡且检测表现优异, 选择主流一阶段、二阶段目标检测网络和 LHODM 进行对比, 对比模型分别为 YOLOv5s, CentripetalNet, Faster-RCNN, Cascade-RCNN, YOLOv3, LHODM 模型检测结果<sup>[19-22]</sup>. 图 6 为在 GDXray 数据集与中国石油天然气管道科学研究院提供的 X 射线焊缝数据集随机选择的 4 张图象上的模型检测结果, 方框表示缺陷存在位置并标明缺陷类别与置信度. 由检测结果可知, CentripetalNet, Faster-RCNN, YOLOv3, Cascade-RCNN 4 种模型均出现不同程度的漏检现象且缺陷置信度较低, 在实际工业中, 4 种模型均无法达到工业需求.

LHODM 模型具有较大检测优势, 与 YOLOv5s 模型相比, LHODM 同样可识别漏检缺陷, 可检测部分遮挡缺陷或成像不明显缺陷, 虽然缺陷置信度有微弱下降, 但对实际检测结果没有影响. 在牺牲




图 5 训练结果收敛曲线

Fig. 5 Convergence curve of model results. (a)  $F_1$ -C curve; (b)  $P$ -C curve; (c)  $R$ -C curve; (d)  $P$ -R curve

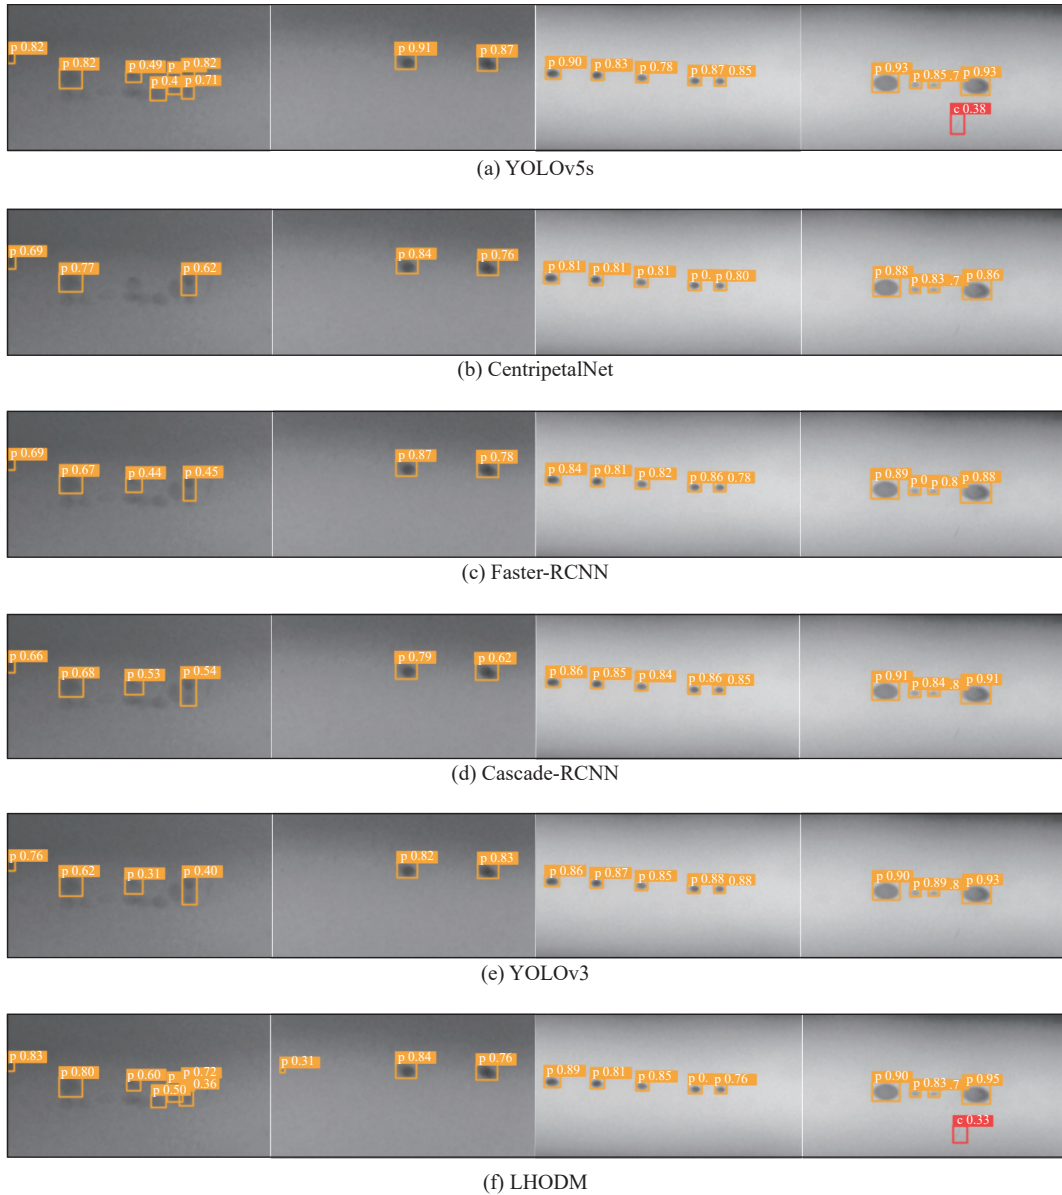


图 6 模型检测结果对比

Fig. 6 Comparison of model detection results. (a) YOLOv5s; (b) CentripetalNet; (c) Faster-RCNN; (d) Cascade-RCNN; (e) YOLOv3; (f) LHODM

极少精度损失的前提下,获得明显速度提升、参数量减少回报,降低成本,对 X 射线焊缝检测工作来说,是综合性能提升的表现。

在实际检测结果对比试验中, LHODM 具有良好的检测效果. 为更全面评价模型,设计了  $\bar{P}_A$  值、参数量、测试时间、 $F_{PS}$  性能指标测试试验,试验结果如表 1 所示。

试验结果表明, LHODM 以降低 0.42%  $\bar{P}_A$  值为代价,检测速度提升了 20.86 帧/s,参数量下降了 3.04 M,测试时间缩短了 7.71 ms,综合性能显著提升. LHODM 降低了对内存和硬件需求,实用性更佳。

### 3.3 消融试验结果

为验证文中各方法的有效性设计了相关消融

试验,由于参考了 YOLOv5s 网络架构,故在 YOLOv5s 网络架构中进行本文提出设计的验

表 1 模型性能对比  
Table 1 Model performance comparison

模型	均值平均精度 $P_{A0.5}$	参数量 $P_M/M$	测试时间 $t/ms$	每秒传输帧数 $F_{PS}/$ (帧·s <sup>-1</sup> )
YOLOv5s	92.04	7.03	23.47	42.61
YOLOv3	91.33	61.54	190.48	5.25
Faster-RCNN	89.67	41.14	158.73	6.30
Cascade-RCNN	90.46	68.94	126.90	7.88
CentripetalNet	88.19	205.68	127.06	7.87
LHODM	91.62	3.99	15.76	63.47

证工作, 试验结果如表 2 所示. 其中包括替换 YOLOv5s 卷积方式为 ULConv 卷积, 试验结果表明, 网络参数量由 7.03 M 降低至 3.69 M, 检测速度由 42.61 帧/s 提高至 65.33 帧/s, 模型计算复杂度和空间复杂度降低, 网络明显轻量化, 但同时  $\bar{P}_A$  值由 92.04% 降低至 88.46%, 可见模型轻量化设计带来一定程度的精度损失. 为弥补由模型轻量化造成的精度损失问题, 本文采取两种措施, 分别是使用轻量级上采样算子 CARAFE 和设计轻量级高效专注模块 ELCC, 将两个模块应用到

YOLOv5s 进行消融试验, 结果表明, CARAFE 算子使得模型参数量增长了 0.16 M,  $\bar{P}_A$  值提升了 0.29%; ELCC 模块使参数量增长了 0.17 M,  $\bar{P}_A$  值提升 0.36%. 由此可知, CARAFE 算子与 ELCC 模块在带来参数量小幅增长的同时, 可带来更大精度回报. 同时结合焊缝缺陷特点, 考虑模型受到真实框和预测框之间的方向影响, 设计 OS-IoU 损失函数替换 YOLOv5s 的 CIoU 损失函数, 试验结果表明, 在模型参数量不变的前提下  $\bar{P}_A$  值由 92.04% 提升至 92.19%.

表 2 LHODM 模块消融结果  
Table 2 Module ablation results of LHODM

模型	准确率 $P(\%)$	召回率 $R(\%)$	均值平均精度 $P_{A0.5}$	参数量 $P_M/M$	测试时间 $t/ms$	每秒传输帧数 $F_{PS}/(\text{帧}\cdot\text{s}^{-1})$
YOLOv5s	90.17	87.36	92.04	7.03	23.47	42.61
YOLOv5s + ULConv	85.52	83.15	88.46	3.69	15.31	65.33
YOLOv5s + CARAFE	91.39	88.44	92.33	7.20	25.58	39.09
YOLOv5s + L-ELCC	89.77	88.01	92.41	7.21	25.54	39.16
YOLOv5s + OS-IoU	89.21	87.58	92.19	7.03	23.47	42.61
YOLOv5s + ULConv + CARAFE	85.76	83.20	88.73	3.86	17.94	55.74
YOLOv5s + ULConv + CARAFE + ELCC	86.32	84.67	89.70	3.99	15.76	63.47
LHODM	89.98	87.79	91.62	3.99	15.76	63.47

综上所述, 使用 ULConv 卷积组成的主干网络可实现模型轻量化, CARAFE 与 ELCC 可弥补精度损失, OS-IoU 可提升模型精度. 为进一步验证 4 种方法结合使用效果, 在 YOLOv5s 框架上先后叠加使用上采样算子 CARAFE, ULConv, ELCC 和 OS-IoU 损失函数, 试验结果表明, LHODM 综合性能显著提升, 拥有轻量化网络和不错的精度表现.

## 4 结论

(1) 参考深度学习 YOLOv5s 模型原始框架的基础上, 重新设计主干网络, 提出轻量级卷积 ULConv, 使用 Depthwise 操作生成更多有效冗余特征, 丰富的特征信息通常可以保证网络对输入的全面理解.

(2) 设计 ELCC 高效轻量化专注模块, 使用条纹池化捕获孤立区域的长距离关系, 在空间维度上保持较窄的内核形状, 便于捕捉局部上下文信息, 防止无关区域干扰标签预测.

(3) 结合轻量级上采样算子 CARAFE, 在响应

模型轻量化前提下, 加强整体通道特征, 使网络更加关注待检测目标, 在模型特征重组时具有更大感受野, 更有效利用环境周围信息. 最后, 设计符合焊缝缺陷特点的 OS-IoU 损失函数, 考虑期望回归向量之间的夹角, 重新定义惩罚项及相关性, 构建 LHODM 网络.

## 参考文献

- [1] 樊丁, 胡桢得, 黄健康, 等. 基于改进卷积神经网络的管焊缝 X 射线图像缺陷识别方法 [J]. 焊接学报, 2020, 41(1): 7-11.  
Fan Ding, Hu Ande, Hang Jiankang, *et al.* X-ray image defect recognition method of pipe weld based on improved convolutional neural network [J]. Transactions of the China Welding Institution, 2020, 41(1): 7-11.
- [2] Huang X, Wang P, Zhang S, *et al.* Structural health monitoring and material safety with multispectral technique: A review [J]. Journal of Safety Science and Resilience, 2022, 3(1): 48-60.
- [3] 徐建军, 石巍. 金属管道对接焊缝超声检测缺陷类型识别研究 [J]. 世界有色金属, 2022(5): 226-228.  
Xu jianjun, Shi Wei. Research on identification of defect types in



- ultrasonic testing of metal pipeline butt welds[J]. *World Nonferrous Metals*, 2022(5): 226 – 228.
- [4] Xu X, Zhang X, Zhang T. Lite-yolov5: A lightweight deep learning detector for on-board ship detection in large-scene sentinel-1 sar images[J]. *Remote Sensing*, 2022, 14(4): 10 – 18.
- [5] Liang H, Seo S. Lightweight deep learning for road environment recognition[J]. *Applied Sciences*, 2022, 12(6): 31 – 68.
- [6] Razfar N, True J, Bassiouny R, *et al.* Weed detection in soybean crops using custom lightweight deep learning models[J]. *Journal of Agriculture and Food Research*, 2022, 8: 100308.
- [7] Liu M, Chen Y, Xie J, *et al.* LF-YOLO: A lighter and faster yolo for weld defect detection of X-ray image[J]. *IEEE Sensors Journal*, 2023, 23(7): 7430 – 7439.
- [8] Zhu Y, Yang R, He Y, *et al.* A Lightweight multiscale attention semantic segmentation algorithm for detecting laser welding defects on safety vent of power battery[J]. *IEEE Access*, 2021, 9: 39245.
- [9] Yang Y, Yang R, Pan L, *et al.* A lightweight deep learning algorithm for inspection of laser welding defects on safety vent of power battery[J]. *Computers in Industry*, 2020, 123: 1 – 8.
- [10] Guo K, He C, Yang M, *et al.* A pavement distresses identification method optimized for YOLOv5s[J]. *Scientific Reports*, 2022, 12(1): 35 – 42.
- [11] Cao J, Li Y, Sun M, *et al.* Do-conv: Depthwise over-parameterized convolutional layer[J]. *IEEE*, 2006, 20: 3726 – 3736.
- [12] Mazzini D. Guided upsampling network for real-time semantic segmentation[J]. *Springer Berlin Heidelberg*, 2018(6): 19 – 26.
- [13] Frajka T, Zeger K. Downsampling dependent upsampling of images[J]. *Signal Processing: Image Communication*, 2004, 19(3): 257 – 265.
- [14] Kundu S, Mostafa H, Sridhar S N, *et al.* Attention-based Image Upsampling[D]. New York: Cornell University, 2020.
- [15] Wang Jiaqi, Chen Kai, Xu Rui, *et al.* Carafe: Content-aware reassembly of features[C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*, Arxiv. 2019: 3007 – 3016.
- [16] Zhou M, Li B, Wang Jue. Optimization of hyperparameters in object detection models based on fractal loss function[J]. *Fractal and Fractional*, 2022, 6(12): 120706.
- [17] Mery D, Riffio V, Zscherpel U, *et al.* GDXray: The database of X-ray images for nondestructive testing[J]. *Journal of Nondestructive Evaluation*, 2015, 34(4): 1 – 12.
- [18] Chen L, Tian X, Chai G, *et al.* A new CBAM-P-Net model for few-shot forest species classification using airborne hyperspectral images[J]. *Remote Sensing*, 2021, 13(7): 1269.
- [19] Dong Z, Li G, Liao Y, *et al.* Centripetalnet: Pursuing high-quality keypoint pairs for object detection[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Arxiv. 2020: 10519 – 10528.
- [20] Ren S, He K, Girshick R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *Institute of Electrical and Electronics Engineers*, 2017, 39(6): 1137 – 1149.
- [21] Cai Z, Vasconcelos N. Cascade: Delving into high quality object detection[C]//*Proceedings of the IEEE Conference on Computer vision and Pattern Recognition*, Arxiv. 2018: 6154 – 6162.
- [22] Redmon J, Farhadi A. Yolov3: An incremental improvement[J]. *Astrophysicd Journal*, 2018(7): 1804.

第一作者:王睿, 讲师; 主要从事焊接过程控制和焊缝缺陷检测等研究; Email: wangrui@hebut.edu.cn.

(编辑: 王盈盈)