

DOI:10.19651/j.cnki.emt.2415902

基于改进 YOLOv5 的铝锭合金表面 缺陷检测技术研究*

胡波¹ 王佳欣² 杨青² 陈婷² 杨明²

(1.贵州省计量测试院 贵阳 550003; 2.贵州大学电气工程学院 贵阳 550025)

摘要: 针对铝锭合金表面缺陷在形态上不规则、检测效果欠佳的问题,提出了一种基于改进 YOLOv5 的铝锭合金表面缺陷检测方法。首先,利用 Res2Net 特征提取网络块替换基线模型中的 CSPDarknet53 模块,以实现多尺度缺陷的有效检测。其次,在 YOLOv5 的主干网络引入 CBAM 卷积注意力模块,以增强对缺陷特征的代表能力。最后,使用基于过参数化的重参数化卷积块替代主干和颈部网络的 3×3 卷积块,以降低模型的推理延时。与传统的目标检测方法进行对比实验,结果表明改进后的方法对缺陷检测的 mAP 达到 75.8%,在检测精度和推理速度上均有显著提升,可很好地满足实际工业生产的任务和需求。

关键词: 深度学习;YOLOv5;铝锭合金;缺陷检测

中图分类号: TP391; TG146; TN805 **文献标识码:** A **国家标准学科分类代码:** 520

Improved YOLOv5-based surface defect detection technology for aluminum ingot alloys

Hu Bo¹ Wang Jiaxin² Yang Qing² Chen Ting² Yang Ming²

(1. Institute of Metrology and Testing, Guiyang 550003, China;

2. College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

Abstract: Aiming at the problems of irregular morphology and suboptimal detection performance of surface defect on aluminum ingot alloys, an improved YOLOv5-based defect detection method is proposed. Firstly, The Res2Net feature extraction network block is employed to replace the CSPDarknet53 module of the baseline model, which can effectively detect the multi-scale defect. Secondly, the CBAM convolutional attention module is introduced into the backbone network of YOLOv5 to enhance the representational ability of defect features. Finally, the over-parameterized reparameterization convolutional blocks are used to substitute for the 3×3 convolutional blocks in the backbone and neck networks so as to reduce the model's inference latency. Experimental results compared with the traditional target detection methods demonstrate the improved method achieves a mAP of 75.8% for defect detection, which is a significant improvement both in detection accuracy and inference speed, and can well satisfy the tasks and demands of practical industrial production.

Keywords: deep learning; YOLOv5; aluminum ingot alloys; defect detection

0 引言

铝锭合金因具备轻量、高强度和耐腐蚀等特性,被广泛应用于航空航天、电力包装和制造业等领域。然而在实际工业生产中,铝锭合金表面极易在高温冷却或浮渣打捞过程中受损,导致出现夹渣、飞边和毛刺。这些缺陷直接影响

铝锭合金的强度、耐磨性和美观度,缩短其使用寿命,进而给企业造成巨大的经济损失^[1]。因此,对铝锭合金表面质量进行有效检测至关重要。

近些年,深度学习^[2]作为一种高效的机器学习方法,其应用在目标检测任务中取得了显著的成效。赵林熔等^[3]结合坐标注意力机制和双向特征金字塔网络(bidirectional

收稿日期:2024-04-22

*基金项目:国家自然科学基金(52265066, 62203132)、贵州省教育厅青年科技人才成长项目(黔教合 KY 字[2022]138号)、贵州大学博士基金(GDRJ[2020]30)项目资助

feature pyramid network, BiFPN), 解决钢材表面缺陷检测精度差、效率低的问题。朱安康等^[4]通过采用快速区域卷积神经网络 (faster region-based convolutional neural network, Faster RCNN) 和可变形卷积网络 (deformable convolution network, DCN) 检测铝材表面缺陷。Cheng 等^[5]提出一种基于视网膜网络 (retina neural network, RetinaNet) 的差分通道注意和自适应空间特征融合的钢表面缺陷检测方法。谷静等^[6]利用密集连接卷积网络 (densely connected convolutional networks, DenseNet) 和数据动态增强方法, 对 X 射线焊缝缺陷的检测精度达到 98.969%。Ma 等^[7]基于 YOLOv4 设计了具有双通道注意力机制的轻量级检测器, 用于铝带表面的缺陷检测。李大华等^[8]针对印刷电路板表面缺陷微小、易混淆的特点, 引入滑动窗口变换网络 (shifted window transformer, Swin-Transformer) 网络并增加小目标检测层, 达到提高检测精度的目的。Zhu 等^[9]提出基于 YOLOv5 的特征强化连接方法, 可应用于金属表面的微小缺陷检测。Zhang 等^[10]提出适用于风力涡轮叶片缺陷图像检测的小目标检测模型 (small object detection-yolo, SOD-YOLO)。Yang 等^[11]通过将空间和通道注意力机制 (spatial and channel squeeze and excitation, SCSE) 和小目标检测层融入 YOLOv5 网络, 提高对小目标的检测能力。张恒等^[12]针对芯片目标缺陷漏检、误检等问题提出一种基于改进 YOLOv5 的新方法, 与改进前的方法相比, 对小目标检测精度相较提升 1.6%。张福豹等^[13]提出一种结合弱光增强和 YOLOv3 算法的铝链缺陷检测方法, 以提高在复杂环境下铝链缺陷检测的准确率。实验结果表明, 该方法在弱光环境中能够显著提高铝链图像的亮度和细节检测精度, 相比原始 YOLOv3 算法提高了 14%。以上研究将深度学习应用于不同的目标检测领域, 取得了良好的检测效果, 但在铝锭工件表面缺陷检测中仍面临一些挑战。铝锭合金表面缺陷图像存在形态不规则、各类缺陷集中、类别相似等问题, 导致 YOLOv5 无法取得良好的检测效果。

为解决上述问题, 本研究提出一种基于改进 YOLOv5 的铝锭合金表面缺陷检测的方法。该方法在主干网络中引入 Res2Net 模块, 并在颈部网络中结合卷积块注意力模块 (convolutional block attention module, CBAM) 机制, 以增强特征提取的有效性。此外, 使用基于过参数化的重参数化模块, 减少推理延时并提升检测精度。本研究旨在为工业生产中的铝锭合金表面缺陷检测提供一种高效、可靠的方法, 推动智能制造的发展。

1 铝锭合金表面缺陷图像数据集制作及预处理

由于铝锭合金表面缺陷没有相应的开源数据集, 利用国内某铝锭合金工厂实地采集共 976 张图片, 涵盖夹渣、飞边和毛刺 3 种缺陷类别, 如图 1 所示。为避免模型训练时出现过拟合, 采用翻转、随机旋转、裁剪缩放和亮度变换等

数据增强方法以随机组合的方式对原始数据集进行扩充, 得到共计 2 573 张图像, 并将训练集和验证集按 8:2 的比例划分, 如图 2 所示。

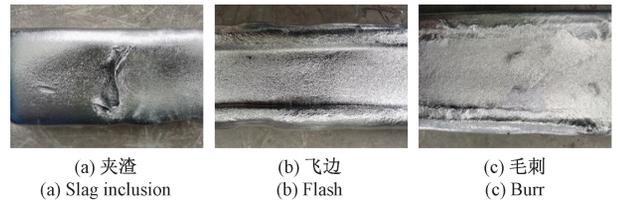


图 1 铝锭合金表面缺陷图

Fig. 1 Aluminum ingot alloy defects diagram

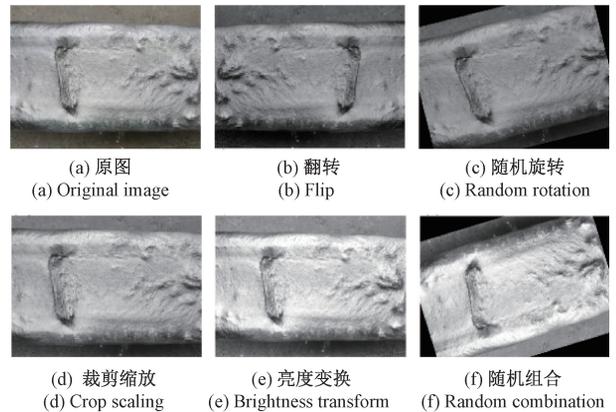


图 2 铝锭合金缺陷图像的数据增强效果

Fig. 2 Data enhancement effect of aluminum ingot alloy defect images

2 基于深度学习的铝锭合金缺陷检测方法

2.1 YOLOv5 网络

YOLOv5 网络是一种推理速度快、检测精度高的单阶段目标检测方法, 主要分为 YOLOv5s、YOLOv5n、YOLOv5m、YOLOv5l 和 YOLOv5x 五种类型。为了满足高效率、易实现的工业需求, 本文选择轻量级的 YOLOv5s-6.0 版本作为基线模型, 其网络结构如图 3 所示。

YOLOv5 的网络架构分为 3 大部分: 主干、颈部和头部。相较于 YOLOv5-5.0, 6.0 版本在主干部分进行两项关键改进: 一是采用 6×6 卷积核、stride 和 padding 分别为 2 的方式处理输入图像, 替代之前的 Focus 模块, 将输入图像尺寸从 (640, 640, 3) 直接转换为 (320, 320, 64), 这一改进在保持功能角色不变的同时, 提升效率有利于模型导出; 二是对空间金字塔池化 (spatial pyramid pooling, SPP) 的改进, 采用串行模式下的空间金字塔快速池化 (spatial pyramid pooling fast, SPPF) 块取代并行模式下的 SPP 块, 既保持相同的效果, 又显著减少重复计算。其次, 颈部用于生成来自骨干网络的不同分辨率特征图, 包括特征金字塔网络 (feature pyramid network, FPN) 和路径聚合网络 (path aggregation network, PANet)。FPN 通过自顶向下

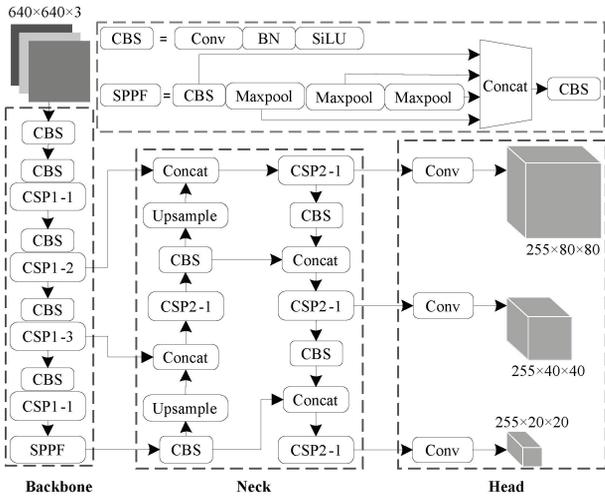


图 3 YOLOv5s-6.0 网络结构

Fig. 3 YOLOv5s-6.0 network structure

的方式传递语义信息,而 PANet 则以自底向上的方式传递位置信息,从而使网络能够获取更加丰富的特征信息。最后,头部作为模型的预测网络,分别针对不同尺度的 80×80、40×40 和 20×20 进行预测,通过卷积运算输出 3 组特征向量:类别预测框、坐标位置和置信度得分。

2.2 改进的 YOLOv5 网络

1) Res2Net 特征提取网络

CSPDarknet53 是用于特征提取的深度学习神经网络,但卷积层操作比较浅,难以提取更抽象和复杂的语义信息。而 Res2Net^[14]是一种新型的残差网络结构,具有更高的表现力和特征提取能力,其网络结构如图 4 所示。因此,本文将主干和颈部网络中的复合卷积层(compound convolutional layer, C3)模块替换为 Res2Net 模块。

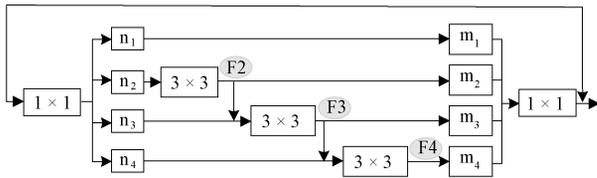


图 4 Res2Net 模块的网络结构

Fig. 4 Network structure of Res2Net module

首先,Res2Net 模块通过 1×1 卷积调整输入特征图的通道数,分为 s 组(记作 $n_i, i \in 1, 2, \dots, s$)。其次,除 n_1 外,其余特征图分别与相应的 3×3 卷积块进行卷积操作(记作 F_i)。随后,除 n_1, n_2 之外,特征图 n_i 与前一组 F_{i-1} 的输出相加并进行 F_i 处理。最后,将这 s 组特征图的输出 m_i 拼接集成,并通过 1×1 卷积操作促进通道间的信息交互。本研究将 s 设置为 4,具体公式如下:

$$m_i = \begin{cases} n_i, & i = 1 \\ F_i(n_i), & i = 2 \\ F_i(n_i + m_{i-1}), & 2 < i \leq s \end{cases} \quad (1)$$

与原方法中的跨级连接(cross stage partial, CSP)模块相比,Res2Net 进行 3×3 卷积的多次叠加和分组设计,不仅可以更好地利用参数,提高特征提取的质量和数量,而且可以学习更多不同尺度的特征,从而获得更丰富的特征表达,实现多尺度特征融合和更丰富的特征提取。对于本实验中铝锭工件表面缺陷集中、密集的特点,使用 Res2Net 模块可以帮助改进后的网络获得更强大的特征提取能力。

2) CBAM 注意力模块

通过在主干网络中引入 CBAM 注意力机制,进一步增强网络对图像不同部分的感知能力,使网络更专注于重要的目标区域。CBAM 注意力机制基于两个关键组件:通道注意力和空间注意力。输入特征依次通过以上两个模块,以此获得更好的有效特征响应。网络结构如图 5 所示。

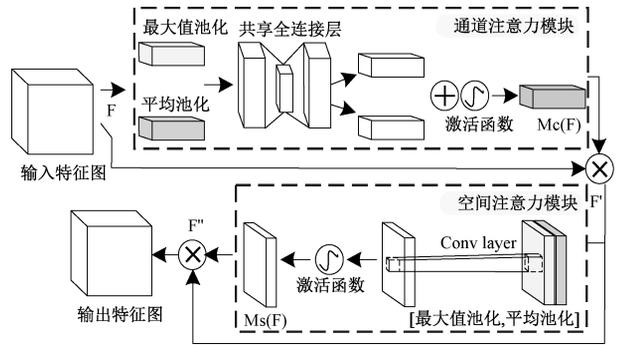


图 5 CBAM 模块结构

Fig. 5 CBAM module structure

通道注意力模块的作用是使网络能够更加关注重要的通道,提高对特征的区分度。权重系数公式为:

$$M_c(F) = \sigma(MLP(Avg\ pool(F)) + MLP(Max\ pool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (2)$$

式中:输入特征 $F \in R^{C \times H \times W}$, σ 是 sigmoid 激活函数。

空间注意力模块的作用是使网络能够更好地捕获特征图中不同位置的信息,提高对目标的定位精度。权重系数公式为:

$$M_s(F) = \sigma(f^{7 \times 7}([Avg\ pool(F); Max\ pool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (3)$$

其中,7×7 代表卷积核的大小。

3) 基于过参数化的重参数化技术

随着深度学习架构由单一分支向多分支结构的演进,目标检测领域的精度实现显著的飞跃。然而,这一进步也伴随着推理速度的减缓和显存利用效率的下降,导致计算资源的大幅浪费,这对于计算能力有限的设备来说可能构成重大障碍。为解决这个问题,本研究引入可重参数化卷积神经网络(re-parameterization visual geometry group, RepVGG)^[15]结构中的结构重参数化技术,旨在开发一种既高效又轻量的网络架构来优化目标检测任务。

结构重参数化技术的关键要点是设计一种仅存在线性

运算的多分支模块。为加快训练收敛速度,RepVGG 网络在每个分支上都添加批归一化层 (batch normalization, BN), 目的在于加速训练的收敛速度, 同时避免梯度分散和梯度爆炸的问题。然而, 该操作会导致模型在推理阶段占用大量的内存, 造成推理延时。因此, 利用结构重参数化技术将 BN 层与卷积层 (convolutional layer, Conv) 相结合构成较为简单的推理结构。RepVGG 实现参数重构的过程如图 6 所示。

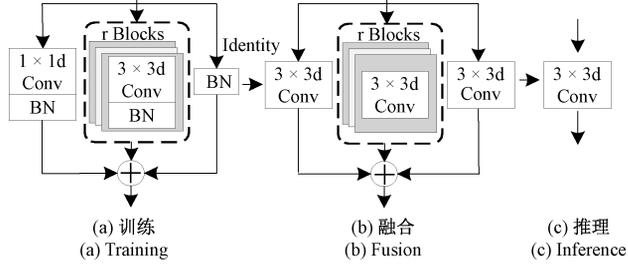


图 6 RepVGG 参数重构的过程

Fig. 6 The process of RepVGG parameter reconstruction

由图 6 可知, 在模型的训练阶段, RepVGG 块通过并行和堆叠方式引入 1×1 卷积层和归一化层, 从而构建出多分支的模型结构。接着, 结合整流线性单元激活函数 (rectified linear unit, ReLU), 完成模型的多分支训练网络的建立。最后, 在推理阶段, 为降低模型的复杂度并提升推理速度, 采用结构重新参数化的策略, 将多分支模型转换为单一分支推理网络。

在参数重构过程中, Conv 层和 BN 层分别表示为:

$$Conv(x) = \mathbf{W}(x) + \mathbf{b} \quad (4)$$

$$BN(x) = \frac{x - \mu_i}{\sigma_i} \times \gamma_i + \beta_i \quad (5)$$

式中: μ_i 为累计平均值, σ_i 为累计方差, γ_i 为比例因子, β_i 为偏置因子, 权重矩阵 $\mathbf{W} \in \mathbf{R}^{C_{out} \times C_{in} \times K \times K}$, 偏差 $\mathbf{b} \in \mathbf{R}^D$ 。

通过将 Conv 层和 BN 层进行融合并折叠后, 偏差 \mathbf{b} 趋近于 0。模型的 1×1 和 identity 卷积分支均转变成 3×3 卷积分支并进行求和处理, 得到推理过程中新的卷积层、卷积层权重和偏差可分别描述为:

$$Conv(BN(x)) = \frac{\gamma_i}{\sigma_i} \times (\mathbf{W}(x) - \mu_i) + \beta_i \quad (6)$$

$$\mathbf{W} = \sum_i^N \mathbf{W}'_i \quad (7)$$

$$\mathbf{b} = \sum_i^N \mathbf{b}'_i \quad (8)$$

其中, 权重矩阵 \mathbf{W}'_i 和偏差矩阵 \mathbf{b}'_i 可分别表示为:

$$\mathbf{W}'_i = \frac{\gamma_i}{\sigma_i} \times \mathbf{W}(x) \quad (9)$$

$$\mathbf{b}'_i = \beta_i - \frac{\gamma_i \times \mu_i}{\sigma_i} \quad (10)$$

在此基础上, 引入过参数化分支增加模型训练的复杂度, 在不增加推理延时的前提下, 进一步提高检测精度。本

研究将过参数化因子 r 设置为 2。

4) 改进后的网络结构

本研究通过采用 Res2Net 来代替原始的 YOLOv5 模型中主干和颈部网络的 C3 模块, 旨在增强特征提取的能力。同时, 在 YOLOv5 的主干网络引入 CBAM 卷积注意力模块, 以增强对缺陷特征的代表能力。此外, 使用基于过参数化的重参数化卷积块替代主干和颈部网络的 3×3 卷积块, 以降低模型的推理延时。改进后的网络结构如图 7 所示。

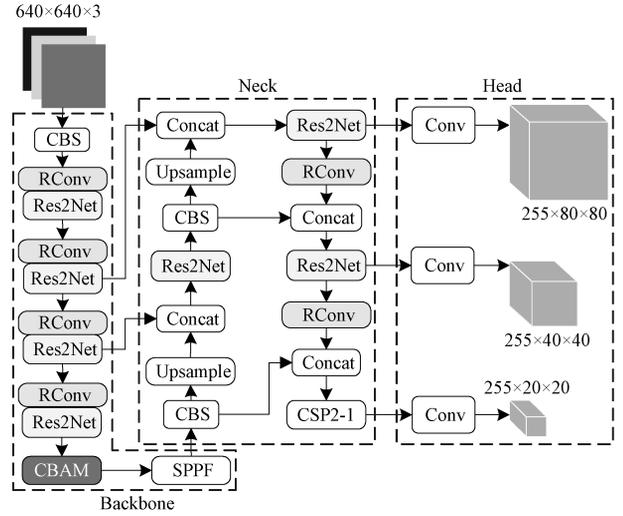


图 7 改进后的网络结构

Fig. 7 Improved network structure

3 实验验证与结果分析

3.1 实验环境与评价指标

为验证改进的 YOLOv5 模型性能, 搭建了基于 Ubuntu 22.04 LTS Linux 操作系统、GPU 为 NVIDIA RTX3090Ti 的实验平台。模型训练的超参数设置包括: 动量设为 0.937, 权重衰减设为 0.0005, 初始学习率设为 0.01, 循环学习率设为 0.1, batch size 设为 84, epoch 设为 300。

为评估改进模型对铝锭合金表面缺陷检测的有效性, 采用以下评价指标: 推理时间、精确率 (P)、召回率 (R)、平均精确率 (AP) 和平均精确率均值 (mAP)。各项评价指标的计算公式分别如下式表示:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

$$AP = \int_0^1 P(R) dr \quad (13)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (14)$$

式中: n 是样本类别数量, TP 表示模型正确检测到的正样本, FP 表示模型错误地将负样本预测为正样本, FN 表示

模型错误地将正样本预测为负样本。

3.2 实验结果分析

1) 目标检测模型性能比较

与原YOLOv5网络相比,改进的YOLOv5方法对数据集集中三类缺陷的检测精度均有提升,对缺陷种类的识别与定位更加精准,对比效果如图8所示。

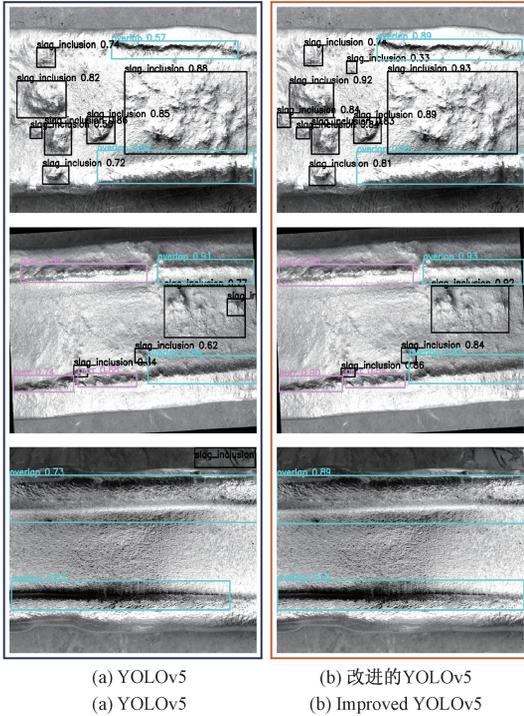


图8 YOLOv5与改进的YOLOv5检测效果对比
Fig. 8 Comparison of YOLOv5 and improved YOLOv5 detection effects

为验证本文方法的优越性,在铝镁合金表面缺陷数据集上,与其他目标检测模型进行了对比,实验结果如表1所示。从表1可知,所提方法的mAP指标均优于其他目标检测模型。尤其针对铝镁合金中毛刺此类缺陷的检测,相较于YOLOv4、YOLOv5、YOLOv7、YOLOv8、RetinaNet和Faster RCNN模型有很大的提升,AP分别提高39.2%、13%、10.2%、18.7%、42.8%和47.1%。实验结果表明,所提方法能更有效地检测铝镁合金的各类表面缺陷。

为验证本文方法在工业应用场景中的适用性,在不改变其他参数的前提下,与YOLO系列其他目标检测方法在模型的推理时间方面进行了对比,结果如表2所示。

由表2的结果表明,改进的YOLOv5方法在mAP处于最优的情况下,推理时间分别比YOLOv5、YOLOv6、YOLOv7和YOLOv8方法缩短了0.1ms、0.74ms、1.9ms和0.5ms,可满足工业生产环境的任务需求。

2) 不同改进模块的有效性

实验A为YOLOv5模型,实验B在实验A的基础上添加了Res2Net模块,实验C在实验B的基础上添加了

表1 不同检测模型的性能比较

Table 1 Performance comparison of different detection models

检测模型	AP/%			mAP/%
	夹渣	毛刺	飞边	
YOLOv4	67.8	23.3	54.7	48.6
YOLOv5	81.1	49.5	79.9	70.2
YOLOv7	87.3	52.3	80.9	73.5
YOLOv8	79.4	43.8	74.1	65.7
RetinaNet	63.9	19.7	42.5	42.0
Faster RCNN	45.4	15.4	56.8	39.2
Improved Method	83.6	62.5	81.3	75.8

表2 不同模型的推理时间对比

Table 2 Comparison of inference time for different models

检测模型	mAP/%	对单张图片的推理时间/ms
YOLOv5	70.2	1.00
YOLOv6	68.4	1.64
YOLOv7	73.5	2.80
YOLOv8	65.7	1.40
Improved Method	75.8	0.90

CBAM注意力机制,实验D在实验C的基础上添加了基于过参数化的重参数化卷积块,结果如表3所示。实验数据显示,实验B的mAP比原网络提升了0.8%,实验C的mAP较上一阶段提升了1.8%,虽然实验D的模型GFLOPs有一定的增加,但推理时间较上一阶段降低了0.6ms,且检测效果最好。实验结果表明,所提方法能够达到更加准确和高效的性能。

表3 不同改进模块对模型性能的影响

Table 3 Effect of different improvement modules on model performance

A	B	C	D	GFLOPs	mAP/%	推理时间/ms
✓				14.2	70.2	1.0
✓	✓			14.5	71.0	1.4
✓	✓	✓		15.6	72.8	1.5
✓	✓	✓	✓	22.8	75.8	0.9

为更好地说明CBAM注意力机制对模型性能的影响,本研究将CBAM分别添加在模型的主干和颈部网络,并进行了实验,对比结果如表4所示。

由表4实验数据可知,CBAM注意力机制可以对缺陷特征进行有效性响应,模型的检测精度显著提升。相比于

表 4 CBAM 注意力机制对模型的性能比较

Table 4 Comparison of CBAM attention mechanism performance on models

CBAM 的位置	P/%	R/%	mAP/%
Improved Method-Neck	73.6	71.4	72.4
Improved Method-Head	76.6	71.9	72.8

颈部网络,在主干网络中添加 CBAM 模块检测性能最好,其中 P、R 和 mAP 分别增加了 3%、0.5% 和 0.4%。

4 结 论

本研究提出了一种用于铝镁合金表面缺陷检测的改进 YOLOv5 方法,能够同时提高模型的精度和效率。采用 Res2Net 模块和注意力机制 CBAM 增强对多尺度缺陷特征的有效检测能力,同时引入基于过参数化的重参数化卷积块降低模型的推理延时。对比实验表明,改进后的方法在最短的推理时间内提高了对铝镁合金表面缺陷的整体检测效果,为缺陷检测领域提供更为优越的解决方案。在未来的研究中,将会进一步探索轻量级的网络模型,使其在实际工业生产中具有更广泛的适用性。

参考文献

- [1] GUO Z, WANG C, YANG G, et al. MSFT-YOLO: Improved YOLOv5 based on trans-former for detecting defects of steel surface[J]. *Sensors*, 2022, 22(9): 3467.
- [2] 刘桂雄, 廖普, 杨宁祥. 基于深度学习主动视觉压力容器焊缝质量参数检测方法[J]. *仪器仪表学报*, 2023, 44(5): 1-9.
LIU G X, LIAO P, YANG N X. Active vision method for pressure vessel weld quality parameter detection based on deep learning [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(5): 1-9.
- [3] 赵林熔, 甄国涌, 储成群, 等. 基于 CBE-YOLOv5 的钢材表面缺陷检测方法[J]. *电子测量技术*, 2023, 46(15): 73-80.
ZHAO L R, ZHEN G Y, CHU CH Q, et al. Steel surface defect detection method based on CBE-YOLOv5 [J]. *Electronic Measurement Technology*, 2023, 46(15): 73-80.
- [4] 朱安康, 王烧芬, 张振宇. 基于深度学习的铝材表面缺陷检测系统设计[J]. *传感器与微系统*, 2022, 41(8): 96-99, 103.
ZHU AN K, WANG R F, ZHANG ZH Y. Design of aluminum surface defect detection system based on deep learning[J]. *Sensors and Microsystems*, 2022, 41(8): 96-99, 103.
- [5] CHENG X, YU J. RetinaNet with difference channel attention and adaptively spatial feature fusion for steel surface defect detection [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.
- [6] 谷静, 王琦雯, 张敏, 等. 基于 DenseNet 网络的焊缝缺陷检测识别[J]. *传感器与微系统*, 2020, 39(9):

129-131.

GU J, WANG Q W, ZHANG M, et al. Weld defect detection and recognition based on densenet network[J]. *Sensors and Microsystems*, 2020, 39(9): 129-131.

- [7] MA Z, LI Y, HUANG M, et al. A lightweight detector based on attention mechanism for aluminum strip surface defect detection [J]. *Computers in Industry*, 2022, 136: 103585.
- [8] 李大华, 徐傲, 王笋, 等. 基于改进 YOLOv5 的印刷电路板缺陷检测[J]. *电子测量技术*, 2023, 46(23): 112-119.
LI D H, XU AO, WANG S, et al. Printed circuit board defect detection based on improved YOLOv5 [J]. *Electronic Measurement Technology*, 2023, 46(23): 112-119.
- [9] ZHU X, LIU J, ZHOU X, et al. Enhanced feature fusion structure of YOLOv5 for detecting small defects on metal surfaces[J]. *International Journal of Machine Learning and Cybernetics*, 2023, 14(6): 2041-2051.
- [10] ZHANG R, WEN C. SOD-YOLO: A small target defect detection algorithm for wind turbine blades based on improved YOLOv5 [J]. *Advanced Theory and Simulations*, 2022, 5(7): 2100631.
- [11] YANG R, LI W, SHANG X, et al. KPE-YOLOv5: An improved small target detection algorithm based on YOLOv5[J]. *Electronics*, 2023, 12(4): 817.
- [12] 张恒, 程成, 袁彪, 等. YOLOv5-EA-FPNs 的芯片缺陷检测方法研究[J]. *电子测量与仪器学报*, 2023, 37(5): 36-45.
ZHANG H, CHENG CH, YUAN B, et al. Research on chip defect detection method of YOLOv5-EA-FPNs[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(5): 36-45.
- [13] 张福豹, 吴婷, 赵春峰, 等. 基于弱光增强与 YOLO 算法的锯链缺陷检测方法[J]. *电子测量技术*, 2024, 47(6): 100-108.
ZHANG F B, WU T, ZHAO CH F, et al. Saw chain defect detection system based on low-light enhancement and YOLO algorithm [J]. *Electronic Measurement Technology*, 2024, 47(6): 100-108.
- [14] ZHAO C, SHU X, YAN X, et al. RDD-YOLO: A modified YOLO for detection of steel surface defects[J]. *Measurement*, 2023, 214: 112776.
- [15] DING X, ZHANG X, MA N, et al. RepVGG: Making VGG-style convnets great again[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR)*. Nashville: IEEE Computer Society, 2021: 13733-13742.

作者简介

胡波,高级工程师,主要研究方向为计量测试、数字信号处理与图像分析、光电检测等。

E-mail: hubo@gzjics.com

杨明(通信作者),特聘教授,主要研究方向为机器视觉检测、激光测量、振动计量、运动控制与测试等。

E-mail: myang23@gzu.edu.cn