

DOI:10.19651/j.cnki.emt.2416899

基于编码器和多尺度特征融合的轮胎缺陷检测*

王广周 崔雪红 王旭 龚玉洁 丁志星

(青岛科技大学信息科学技术学院 青岛 266061)

摘要: 轮胎内部缺陷检测能够及时发现轮胎生产中存在的潜在问题,可为工艺调整及行驶安全提供有力保障。而轮胎 X 光图像中的缺陷目标具有多尺度、极端长宽比、形状各异且不规则、小目标多以及正负样本不均衡等特点,致使缺陷检测精度低。针对以上情况,提出一种基于高效编码器与多尺度特征融合的轮胎缺陷检测方法。首先结合可变形注意力机制和通道注意力机制设计一个高效的编码器,以增强特征提取和表示能力,然后构建多尺度特征提取和融合模块,融合浅层与深层特征信息,来保留重要上下文信息并增强特征表示的多样性,最后在模型训练中自适应边界框回归方法,动态分配难易样本权重,减少无效样本,实现模型快速收敛、提高模型泛化能力。实验结果表明,改进后模型在轮胎缺陷数据集上的平均精度(mAP)达到 95.5%,较基线网络提高 3.6 个百分点,为轮胎缺陷检测的实际落地应用奠定了一定的基础。

关键词: 目标检测;特征融合;边界框回归;轮胎生产缺陷;注意力机制

中图分类号: TP391;TN-919.8 **文献标识码:** A **国家标准学科分类代码:** 520.6

Tire defect detection based on encoder and multi-scale feature fusion

Wang Guangzhou Cui Xuehong Wang Xu Gong Yujie Ding Zhixing

(College of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Tire internal defect detection can effectively identify potential issues during the manufacturing process, providing strong support for process adjustments and ensuring driving safety. Defect targets in tire X-ray images are characterized by multi-scale features, extreme aspect ratios, diverse and irregular shapes, a large number of small targets, and an imbalance between positive and negative samples, which results in low detection accuracy. To address these challenges, we propose a tire defect detection method based on an efficient encoder and multi-scale feature fusion. First, an efficient encoder is designed by combining deformable attention mechanisms and channel attention mechanisms to enhance feature extraction and representation capabilities. Then, a multi-scale feature extraction and fusion module is constructed to integrate shallow and deep feature information, preserving critical contextual information and improving feature representation diversity. Finally, an adaptive bounding box regression method is employed during model training to dynamically allocate weights to samples based on difficulty, reducing the impact of invalid samples and achieving faster model convergence while enhancing generalization. Experimental results demonstrate that the proposed model achieves a mean average precision (mAP) of 95.5% on the tire defect dataset, a 3.6 percentage point improvement over the baseline network, thus laying a solid foundation for the practical application of tire defect detection.

Keywords: object detection; feature fusion; bounding box regression; tire production defect; attention mechanism

0 引言

轮胎生产质量直接影响生产成本和汽车行使安全^[1-2]。因此,及时检测轮胎缺陷并严格把控出厂轮胎质量是轮胎生产过程中的关键环节。在国外,轮胎检测任务已经有了比较完善的设备和软件,但由于整套设备价格高昂,无法直

接适用于国内的轮胎检测流程等特点,国内很多轮胎厂依然在用人工的方式进行全检或者抽检。但人工检测容易受主观因素影响从而准确度不高且效率低下,加之劳动力减少等弊端,提出一种轮胎缺陷自动化智能检测方法是至关重要的。

传统计算机轮胎缺陷检测方法常使用统计方法,Sun

收稿日期:2024-09-15

* 基金项目:国家自然科学基金(61472196,61672305)项目资助

等^[3]提出轮胎缺陷会改变帘线的平行布局,在统计完正常图像中的平行帘线数量后,使用人为设计的双阈值作为判断缺陷是否存在标准。Zhao 等^[4]提出使用滑动窗口对轮胎 X 射线图像进行局部逆差矩计算,生成的特征分布作为轮胎图像纹理的有效描述符,接着计算特征分布与每个滑动窗口图片之间的相似度以此检测缺陷特征。基于统计的方法在检测单一类别缺陷具有较好的性能,但由于轮胎具有各种各样的型号、类型,针对每一个特殊型号的轮胎都可能需要特定的检测参数。当需要调整传统算法的参数时,开发人员就要求具备充足的经验和专业知识。

近些年来深度学习被广泛应用于工业生产^[5-6],对于轮胎缺陷检测方法,Chen 等^[7]提出使用残差网络(residual network, ResNet)作为 Faster R-CNN(faster region-based convolutional neural network, Faster R-CNN)的特征提取网络,ResNet 第 4 层输出特征作为区域建议网络(region proposal network, RPN)的输入特征,ResNet 第 5 层输出特征作为分类器的输入特征,并且根据缺陷样式修改锚框大小和宽高比,提升检测效果,但该策略对于困难样本处理效果不好,在采样过程中使用了大量锚框,大多数样本都是无效或者低质量。史建杰等^[8]提出使用 YOLOX(you only look once x, YOLOX)模型检测轮胎图像 0°带束层接头缺陷,首先使用投影直方图定位、切割轮胎带束层区域,然后将处理后的带束层区域图片使用 YOLOX 模型进行检测,提高了检测精度,此方法仅检测带束层区域缺陷,并且需要较长预处理时间分割轮胎图片,且需要配合其他检测算法共同检测轮胎缺陷。郭培林等^[9]提出在 Faster R-CNN 网络中融入特征金字塔网络(feature pyramid network, FPN),并对候选框进行排名,以增加模型检测精度,但最终的 mAP(mean average precision, mAP)指标达到 60.8%,不适合应用于实际场景。Zheng 等^[10]提出使用稀疏编码替代卷积来进行特征提取,实现无监督训练,该方法在杂质、气泡明显缺陷中取得良好的效果,但在其他缺陷种类检测中容易出现漏检、误检现象。

对于深度学习轮胎缺陷语义分割方法,X 光轮胎图像具有高分辨率特点,分割算法能实现像素级精准分割,但需要大量计算资源,耗费大量时间,不利于部署和实时应用。Wang 等^[11]提出使用 VGG(visual geometry group network, VGG)网络提取特征,同时加入一个纹理感知网络以补充在提取特征过程中丢失的细节信息,实现了像素级检测与分割的功能。然而,该方法无法对缺陷进行分类。朱焕宇等^[12]设计一个新型特征金字塔,使用自注意力和交叉注意力机制增强模型感受野和增强目标特征在网络中的权重,提高网络泛化能力。Zheng 等^[13]提出类 UNet 结构替代原始 UNet 的编码、解码器结构,同时使用坐标注意力机制增强网络分割能力,但此网络在胎冠处,容易出现误检、漏检现象。分割方法耗时费钱,不利于在线检测。此外,对于大规模数据集,标记成本也很高。

为此,本文针对轮胎缺陷难检测、易误和漏检等难点,提出编码器和多尺度特征融合的轮胎缺陷检测方法,以提升复杂背景中的轮胎缺陷检测效果。首先设计双重注意力编码器增强特征的提取和表示能力,然后构建多尺度特征提取和融合模块,融合浅层与深层特征信息,来保留重要上下文信息并增强特征表示的多样性,最后在模型训练中自适应边界框回归方法,动态分配难易样本权重,减少无效样本,实现模型快速收敛、提高模型泛化能力。实验结果表明,改进后模型在精度上达到了 93.2%,召回率达到 93.6%,与 YOLOv9(you only look once version 9, YOLOv9)、RT-DETR(real-time detection transformer, RT-DETR)等模型相比,在 X 光轮胎缺陷检测中具有更好的检测效果。

1 轮胎缺陷检测模型

本文网络结构由特征提取网络、颈部特征融合网络以及解码器检测头组成,具体细节流程如图 1 所示。由 X 光机采集到的轮胎图像输入网络,利用 Resnet101 作为骨干网络,提取图像的深层次特征,尤其是 C5 层的特征。此外,为了捕捉更多信息,网络通过混合编码器进行特征提取,结合可变形注意力机制^[14]增强特征捕获的灵活性,并通过通道注意力^[15]对每个通道的特征进行加权处理,进一步提升特征质量。接着,将 C2 特征引入特征融合模块。其中,C2 特征通过空间深度转换卷积(spatial depthwise convolution, SPD-Conv)^[16]下采样至 C3 特征相同的大小,在 F3 模块中,F2、C3、F4 三种特征进行多尺度特征拼接,拼接后的特征将由局部分支、大分支和全局分支并行处理,以捕捉多尺度感受野,高效建模全局与局部的依赖关系,最终得到完整的特征图。最后,解码器检测头对这些特征图进行目标定位和分类。此外,在训练过程中,本文使用了难易样本均衡损失函数,按照难易样本占比动态调整线性映射区域重构原有交并比(intersection over union, IoU)损失。

1.1 高效混合编码器

在特征提取过程中,随着网络深度的增加,深层特征图中包含丰富的语义信息。传统特征融合方法主要依赖 1×1 卷积进行通道压缩和融合,虽然计算效率高,但它只能执行局部线性变换,难以充分捕捉复杂的特征交互。因此,在多尺度目标场景下,这种方法可能导致关键空间信息和上下文关系的丢失。针对这一不足,本文引入了一个混合编码器模块,专门处理 C5 层的深层特征,模块结构如图 2 所示。

该模块采用了可变形注意力机制,动态调整特征图的感受野,以增强特征提取能力。具体过程为:首先,对输入特征图进行下采样,生成参考点;随后,通过线性映射生成查询特征 q ,并利用偏移生成网络调整参考点的位置,生成变形后的采样点。在这些变形点上,通过双线性插值获取

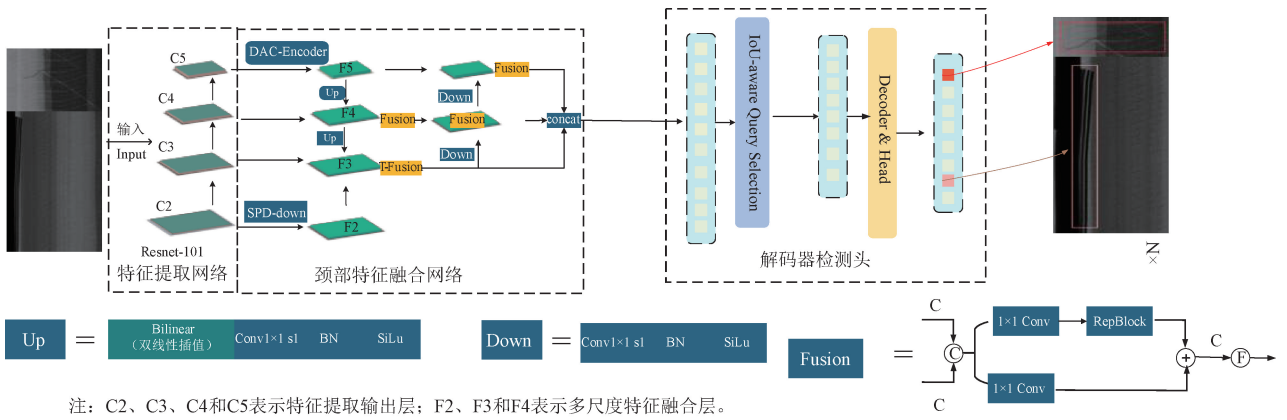


图 1 本文研究方法的技术路线
Fig. 1 Technical roadmap of the research method in this article

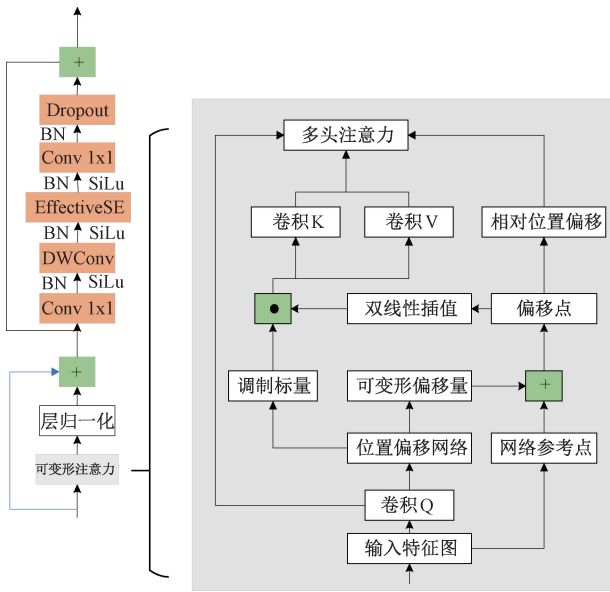


图 2 混合编码器
Fig. 2 Hybrid encoder

新的特征表示 x' , 并对其进行线性映射生成变形后的键 k 和值 v 。最后, 查询特征 q 与变形后的键 k 通过点积计算得到注意力分数, 结合相对位置偏差计算自注意力输出特征 z 。

与此同时, 该模块还将输出特征 z 送入通道注意力模块中, 以进一步提升通道间的信息交互。首先, 采用 1×1 卷积层对其升维, 增强特征的表达能力。随后, 利用深度可分离卷积减少计算量。通过引入仅包含一个全连接层的高效注意力机制 (effective squeeze-and-excitation, EffectiveSE), 避免通道间信息的丢失, 并强化了网络对关键特征的捕捉能力。最后, 再通过 1×1 卷积层进行降维处理。残差连接在不同层级之间有效传递几何信息, 防止梯度在深层网络中消失, 提升模型在升维与降维过程中的学习能力。

1.2 增强多尺度特征融合

传统的颈部特征融合通常采用金字塔网络结构

(PANet)进行, 将特征提取网络输出的后 3 个特征层通过横向连接与层次融合的方式, 获取大量的目标信息, 从而提升模型对多尺度目标的检测能力。然而, 由于轮胎缺陷中存在大量的小目标, 主干网络在频繁特征提取时容易丢失小目标的上下文信息。针对这一不足, 传统的改进方法通常是将浅层特征图加入到金字塔网络中, 但这会导致浅层特征图直接与解码器检测头相连, 显著增加计算量并降低推理速度。为了解决这一问题, 提升模型对小目标的检测能力, 同时优化特征融合效果, 本研究通过引入浅层特征图并增强多尺度目标特征传递, 设计了一种新的特征融合策略。即通过 SPD 模块对浅层特征图进行下采样, 再融合到现有 PANet 结构中, 同时设计了新的多尺度融合模块 Tri-Fusion, 通过 3 个分支提取不同感受野的浅层位置信息和深层语义信息, 以增强模型对多尺度特征的学习能力。此设计强化了主干网络与颈部网络之间的信息交互, 避免了深层网络中的特征信息丢失, 实现了更为完整的多尺度信息传递。

SPD 下采样模块由特征图切分、特征图重组和非跳跃卷积层组成。其在降低特征图空间维度的同时保留了通道维度信息, 以此避免信息丢失。具体而言, 特征图根据缩放因子按坐标位置进行切分, 然后将子特征图在通道维度上重新组合, 空间分辨率虽然降低, 但所有原始像素信息仍保存在通道维度上。随后, 通过非跳跃卷积层对处理后的特征进行计算, 最终得到输出特征, 模块结构如图 3 所示。




图 3 SPD 模块结构
Fig. 3 SPD module structure

Tri-Fusion 多尺度融合模块接收来自 3 个不同尺度的特征, 但单一感受野难以同时捕获所有尺度上的缺陷特

征。所以,该模块通过跨层连接允许低层特征直接传递到高层,提升了信息流动性的同时又减少了冗余计算。模块结构如图 4 所示。




图 4 Tri-Fusion 模块结构

Fig. 4 Tri-Fusion module structure

输入特征按通道划分为两部分,一部分通过标准卷积处理,并使用全核(Omni-Kernel)模块^[17]提取特征,另一部分则作为残差连接。Omni-Kernel 模块拥有局部分支、大分支和全局分支 3 种不同的分支来增强多尺度特征的表达。局部分支通过逐点卷积来专注于小尺度的特征;大分支采用大卷积核和条带状卷积核检测较大或不规则形状的目标;全局分支通过双域通道关注机制和频率门控机制实现全局感受野的建模,捕捉整个图像的长距离依赖关系和全局信息,弥补局部分支仅关注局部特征的不足。

1.3 增强多尺度特征融合

在传统的目标检测方法中,负样本的数量远多于正样本而导致的样本不平衡是常见的问题,即由于训练过程中低质量负样本的占比过大,模型容易过度关注这些无用样本,导致对正样本的学习不足。此外,IoU 损失函数作为目标检测中的常用度量标准,在处理 IoU 值较小或为零的样本时,梯度会消失,使得模型难以学习到有效的位置信息,尤其是当预测框与真实框几乎不重叠时,训练效果较差。为了克服这些问题,本文提出了一种自适应边界框回归损失,该损失函数能够根据模型的训练状态动态调整对不同样本的关注度,确保模型能够在不平衡的数据分布下依然有效学习目标位置信息,并改善 IoU 梯度消失的问题,从而提升模型的回归性能。

自适应边界框回归损失的函数如下:1)计算当前 Δz_{pq} 值的平均值,并通过该平均值动态调整参数 d 和 u 。2)使用调整的参数 d 和 u 对原始 IoU 进行线性映射,得到 $IoU^{focaler}$ 。3)将真实框与预测框的重叠损失、中心距离损失和宽高损失考虑进损失函数中,通过 Focal-EIoU^[18] 对 $IoU^{focaler}$ 进行计算, Focal-EIoU 如图 5 所示,其最终的损失函数表达式如下:

$$\begin{cases} d = \overline{IoU} - 0.45 \in [0, 0.05] \\ u = \overline{IoU} + 0.45 \in [0.95, 1] \end{cases} \quad (1)$$

$$IoU^{focaler} = \begin{cases} 0, & IoU < d \\ \frac{IoU - d}{u - d}, & d \leq IoU \leq u \\ 1, & IoU > u \end{cases} \quad (2)$$

$$L_{EIoU} = 1 - L_{IoU} + \frac{\rho^2(b, b^{gt})}{(h^c)^2 + (\omega^c)^2} + \frac{\rho^2(\omega, \omega^{gt})}{(h^c)^2} + \frac{\rho^2(h, h^{gt})}{(\omega^c)^2} \quad (3)$$

$$L_{Focal-EIoU} = IoU^\gamma L_{EIoU} \quad (4)$$

$$L_{FF-EIoU} = IoU^\gamma (L_{EIoU} + IoU - IoU^{Focaler}) \quad (5)$$

式中: b 为框的中心点, ω 为框的高度, h 为框的宽度; IoU 为 IoU 的平均值,在模型的训练过程中,动态调整参数 ‘ d ’ 和 ‘ u ’,这个函数能够让 $L_{FF-EIoU}$ 损失函数在不同的训练阶段和数据集上自适应地调整其对样本难易程度的关注度。这种动态调整机制有助于提升模型在复杂场景下的鲁棒性,并使模型更好地平衡简单样本和困难样本的影响,从而提高整体检测性能。自适应边界框回归函数重点关注高质量优质 IoU 锚框,将它们线性映射到 $[0, 1]$ 区间,进行更细致的优化;对于极端情况,如果 IoU 值小于 d ,则映射结果为 0,表示模型不再对这些 IoU 值产生关注,如果 IoU 值大于 u ,则映射结果为 1,表示模型认为这些 IoU 值已经足够好,不需要进一步优化。 ρ 表示中心点坐标的欧氏距离, γ 为控制异常值抑制程度的超参数。




图 5 Focal-EIoU 示意图

Fig. 5 Focal-EIoU schematic diagram

2 实验结果与分析

2.1 实验数据集

现阶段没有公开的轮胎缺陷数据集,且在轮胎生产过程中,产生轮胎缺陷的比例相对较低,因此轮胎缺陷图片较难收集。本文使用某集团轮胎生产车间提供的图像数据,轮胎图像分为钢丝圈、胎侧、胎肩和胎面四部分。钢丝圈由一层层钢丝组合起来,在图像上呈现黑色,如图 6 中钢丝圈所示;胎侧由平行的帘线组成,如图 6 中胎侧所示;胎肩位置处于胎侧和胎冠区域中间,承担着连接和过渡的功能,如图 6 中胎肩所示;胎面区域由多层帘线以不同角度方向相互交叉,形成复杂背景纹理,如图 6 中胎面所示。该数据集包括 1 100 张图片,收集了跳线(jumper)、异物(impurity)和刺出(prick)3 种出现几率较高的缺陷,如图 7 所示。按照 7:1:2 比例将数据集划分为训练集、验证集和测试集。为提高网络泛化能力,分别对轮胎缺陷图像数据集做直方图均衡化、增加亮度、高斯噪声、图像拉伸、合并图像、BigGAN 网络合成图像数据增强处理,挑选并标

注了7 210张轮胎缺陷图像,训练集5 039张、验证集1 443张和测试集726张图片。





图6 轮胎图像结构

Fig. 6 Tire image structure



(a) 跳线缺陷 (a) Jumper defect (b) 刺出缺陷 (b) Prick defect (c) 异物缺陷 (c) Impurity defect

图7 数据增强后的轮胎缺陷示例

Fig. 7 Example of tire defects after data augmentation

2.2 实验设置

本文实验环境:操作系统为 Ubuntu20.04 版本的 Linux 系统, GPU 为 NVIDIA_RTX_A5000, 显存容量为 24 GB。深度学习框架为 PyTorch1.13.1, 编程语言为 Python3.8, 软件环境为 Anaconda 和 CUDA11.7。训练设置中参数如下:训练轮数为 300 轮,网络此时已达到收敛状态;批量大小为 8;输入图片尺寸为 640×640 像素;随机种子设置为 1,固定网络中随机数,避免消融实验受到误差影响;优化器为 SGD,初始学习率设置为 0.001, lrf 设置为 1.0。

2.3 评价指标

为评价模型性能,本文采用了 PASCAL VOC 数据集的主要评价指标,包括准确率(Precision, P)、多个类别的平均准确率(mAP@0.5)、不同 IoU 下的多个类别的平均准确率(mAP@0.5:0.95)、召回率(Recall, R)、F1 分数以

及模型的推理速度(FPS)。上述评价指标的计算公式如式(6)所示。

$$\left\{ \begin{aligned} Precision &= \frac{TP}{TP + FP} \times 100\% \\ Recall &= \frac{TP}{TP + FN} \times 100\% \\ AP &= \int_0^1 P(R) dR \times 100\% \\ mAP &= \frac{1}{n} \sum_0^1 AP \times 100\% \\ FPS &= \frac{1}{t} \\ F1 - score &= \frac{1}{\frac{1}{2} \left(\frac{1}{Precision} + \frac{1}{Recall} \right)} \end{aligned} \right. \quad (6)$$

式中: TP (true positive)、FP (false positives)、FN (false negatives)是混淆矩阵的评价指标。TP 表示模型将实际正例预测为正例的数量, FP 表示将实际负例预测为正例的数量, FN 表示将实际正例预测为负例的数目, AP (average precision)是精确度(Precision)与召回率(Recall)之间的权衡,通常用于评估在不同置信度阈值下模型的性能, t 表示每张图像的处理时间。

2.4 消融实验

为了验证提出的各个改进模块是否有效,本文进行消融实验对比,如表 1 所示。将高效编码器与基准模型进行融合,结果由实验 2 可知,召回率(R)和平均精度(mAP)分别提高了 1.1%和 0.9%,这主要是由于 DA-Encoder 模块可以更好的提取深度特征,融合多尺度的目标信息,提高模型的检测精度。实验 3 在实验 2 的基础上融合 Tri-Fusion 模块,可以看出融合后算法的精度有些下降,但召回率(R)和 mAP 分别提升 0.8%和 1.4%,说明 Tri-Fusion 模块能够充分融合浅层表征信息与深层语义信息,使得模型可以有效识别各种缺陷。相比实验 3,实验 4 使用自适应边界框回归函数, P、R 与 mAP 分别提升了 0.4%、2.3%和 1.3%,这种改进通过区间映射重构 IoU 损失,实现了对不同难度样本的动态关注,从而提高了模型的整体性能。

表 1 消融实验

Table 1 Ablation experiment

实验	Encoder	Tri-Fusion	Loss	P/%	R/%	mAP/%	FPS/fps	F1/%	参数量/M	计算量/GFLOPs
1				91.1	89.4	91.9	38.9	89.4	67.3	232.3
2	✓			91.2	90.5	92.8	46.1	90.8	76.5	257.8
3	✓	✓		92.8	91.3	94.2	43.4	92.0	83.8	349.0
4	✓	✓	✓	93.2	93.6	95.5	43.4	93.4	83.8	349.0

优化前后的 P-R 曲线如图 8 所示,其中图 8(a)为 RT-DETR 算法的曲线图,图 8(b)为本文改进算法的曲线图。图中横坐标为召回率,纵坐标为精度、曲线与横纵坐标轴

所围面积为不同缺陷类别的平均精度。由对比结果可知,改进后的网络整体的检测精度得到了提升,刺出(prick)、跳线(jumper)与异物(impurity)缺陷检出率分别提高了

2.5%、1.1%及7%，异物缺陷的检测性能提升最大，主要是模型融合部分加入浅层信息，提升了小目标检测的性能。

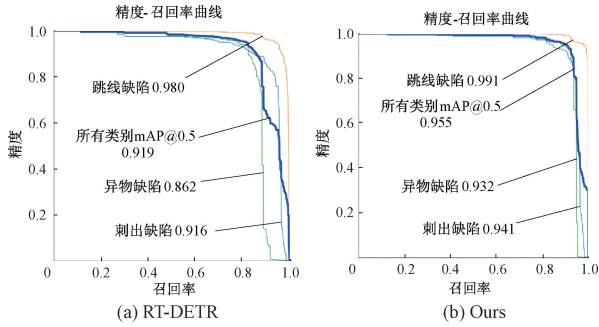


图 8 精度-召回率对比曲线

Fig. 8 P-R comparison curve

2.5 对比实验

通过上述方法对 RT-DETR 进行一系列改进取得检测性能的提升,为了进一步验证改进算法的性能优劣,在相同的数据集上,与 Faster-RCNN、TOOD 等目标检测算法进行对比,各实验参数保持一致,比较不同模型在测试集上的 mAP50、mAP50~95 以及单幅图片检测时间。由表 2 可知,与两阶段目标检测算法 Faster-RCNN、Cascade-RCNN 相比,改进算法的平均精度显著提高,其值为 95.5, 优于 Faster-RCNN 的 64.7 和 Cascade-RCNN 的 66.9;同时也优于 YOLO 系列的 YOLOv8 和 YOLOv9,在 mAP0.5 中分别提升了 4.5% 和 4.3%,并且改进模型 FPS 为 43.4,符合工业实时检测需求。

2.6 系统设计

检测系统主要体现在软件设计方面,包含一个检测服

表 2 对比试验

Table 2 Comparative experiment

模型	P/%	R/%	mAP50/%	mAP50~95/%	FPS/fps	F1/%	参数量/M	计算量/GFLOPs
Faster-RCNN	67.1	65.7	64.7	39.9	28.2	66.3	60.1	330.1
Cascade-RCNN	70.4	66.0	66.9	44.7	25.4	68.1	88.4	420.3
tood	78.5	76.3	78.6	40.9	23.3	77.3	41.3	200.7
dq-detr	85.8	82.6	86.1	46.4	13.3	84.1	40.4	190.5
YOLOv8x	90.1	91.1	91.0	46.9	64	90.6	68.2	257.8
YOLOv9e	90.3	89.3	91.2	47.0	60	89.8	57.3	189.0
RT-DETR	91.1	89.4	91.9	49.6	38.9	90.2	67.3	232.3
本文	93.2	93.6	95.5	58.4	43.4	93.4	83.8	349.0

务器模块,用于接收传入的图像数据并执行神经网络检测,并对检测结果中的建议框进行统计分析,以判断当前轮胎是否合格,检测结果随后被保存至数据库。基于此方案,构建了如图 9 所示的子午线轮胎缺陷检测系统。首先,采集设备和 MES 工控系统获取待检测轮胎条形码信息,然后,轮胎在 X 光铅房中成像,所得图像数据通过数据传输机传递,并通过 TCP 网络发送至检测服务器。在检测服务器中,使用本文提出的轮胎缺陷检测算法进行检测处理,最终将数据及检测结果存储到轮胎数据库中。

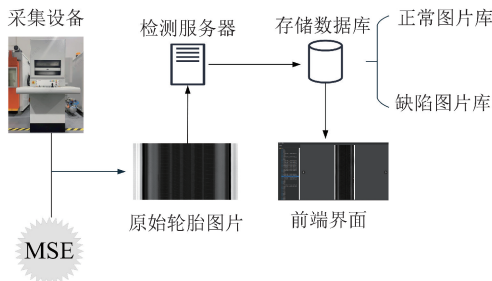


图 9 系统结构图

Fig. 9 System structure diagram

2.7 轮胎缺陷检测可视化

为了更直观地评价本文算法的检测性能,使用基线网络与改进网络在测试集进行了预测,结果如图 10 所示。对比结果分为 3 组。刺出缺陷通常出现在胎面和胎肩两个区域,其中胎肩区域的刺出缺陷与背景差异明显,而胎面区域由于背景复杂,刺出缺陷的对比度较低,容易被忽略。第 3 组刺出缺陷图片结果显示,原始模型在对比度低的缺陷处取得较差的置信度分数,而改进模型可以得出较高的分数。在异物缺陷对比中,基线网络容易出现误检错误,例如在第 3 组异物缺陷,基线网络检测出的异物置信度为 0.31,而实际上并无缺陷;而改进网络能够更准确地检测出实际缺陷,避免了无效区域的误检,这得益于改进网络在特征提取及多尺度特征融合等方面的增强,能够更加精准地识别异物缺陷,减少误报的发生。在跳线缺陷的对比中,改进模型也表现出了更高的置信度分数。综上所述,本文提出的模型在轮胎缺陷检测中表现出更强的性能,能够更准确地定位和识别缺陷,提升检测的准确率。




图 10 检测结果对比图

Fig. 10 Comparison of detection results

3 结 论

为了解决轮胎检测性能差、漏检误检问题的不足,本文以 RT-DETR 作为基线网络,通过构建新的高效编码器模块、使用多尺度特征融合 Tri-Fusion 模块、替换自适应边界框回归损失函数,提出了一种改进的轮胎缺陷检测方法。消融实验结果表明,本文提出的轮胎缺陷检测模型可以高效利用深层特征和小目标特征层特征,减少漏检和误检的发生,显著提高轮胎内部缺陷的检测精度。对比实验结果表明,本文提出的改进算法优于其他主流网络模型,在保持高精度的同时,还具备实时检测的能力,对轮胎缺陷检测工作具有重大的现实意义。未来研究方向包括:通过网络剪枝技术减少模型参数,在保持精度的同时提高检测速度;探索更高效的特征提取和融合方法,进一步提升模型在复杂背景下的检测性能。

参考文献

- [1] 康诚,严欣,高友发,等. 汽车轮胎爆胎测试试验及其相关安全控制技术研究综述[J]. 时代汽车, 2021(8): 172-173.
KANG CH, YAN X, GAO Y F, et al. Summary of research on automobile tire burst test and related safety control technology[J]. Auto Time, 2021(8): 172-173.
- [2] 李建青,姜朝,李佑泉,等. 浅谈轮胎行业的安全风险点及应对措施[J]. 橡塑技术与装备, 2023, 49(8): 55-59.
LI J Q, JIANG CH, LI Y Q, et al. Talking about the safety risk points and countermeasures of tire industry[J]. China Rubber/Plastics Technology and Equipment, 2023, 49(8): 55-59.
- [3] SUN H X, GU N J, LIN C W. Tire impurity defect detection based on grayscale correction and threading method[C]. 2021 IEEE 6th International Conference on Computer and Communication Systems (ICCCS).

IEEE, 2021: 229-233.

- [4] ZHAO G, QIN S Y. High-precision detection of defects of tire texture through X-ray imaging based on local inverse difference moment features[J]. Sensors, 2018, 18(8): 2524-2548.
- [5] 刘韵婷,刘鑫,高宇. 基于 FAMGAN 的轮胎 X 光图像缺陷检测[J]. 电子测量与仪器学报, 2023, 37(12): 58-66.
LIU Y T, LIU X, GAO Y. Defect detection of tire X-ray images based on FAMGAN [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 58-66.
- [6] 刘韵婷,李绅科,郭辉,等. 基于神经批采样的轮胎 X 光图像异常检测研究[J]. 电子测量技术, 2023, 46(5): 157-163.
LIU Y T, LI SH K, GUO H, et al. Research on tire X-ray image anomaly detection based on neural batch sampling[J]. Electronic Measurement Technology, 2023, 46(5): 157-163.
- [7] CHEN J Y, LI Y W, ZHAO J X. X-ray of tire defects detection via modified faster R-CNN [C]. 2019 2nd International Conference on Safety Produce Informatization(IICSPD). IEEE, 2019: 257-260.
- [8] 史建杰,李金屏,赵建玉. 基于 YOLOX 模型的轮胎 X 射线图像中 0°带束层接头检测[J]. 济南大学学报(自然科学版), 2023, 37(3): 280-287.
SHI J J, LI J P, ZHAO J Y. 0° belt joint detection in tire X-ray images based on YOLOX model[J]. Journal of University of Jinan (Science and Technology), 2023, 37(3): 280-287.
- [9] 郭培林,陈金水,卢建刚,等. 轮胎 X 光图像瑕疵检测 Faster R-CNN 算法改进研究[J]. 自动化博览, 2020, 37(8): 94-98.
GUO P L, CHEN J SH, LU J G, et al. Research on

- the improvement Faster R-CNN algorithm for tire X-ray image defect detection[J]. Automation Panorama, 2020, 37(8):94-98.
- [10] ZHENG Z Z, SHEN J Y, SHAO Y Y, et al. Tire defect classification using a deep convolutional sparse-coding network [J]. Measurement Science and Technology, 2021, 32(5), DOI: 10.1088/1361-6501/ABDDF3.
- [11] WANG R, GUO Q, LU S M, et al. Tire defect detection using fully convolutional network[J]. IEEE Access, 2019, 30(7):43502-43510.
- [12] 朱焕宇, 王明泉, 贾虎, 等. 基于多维度动态衰减 Transformer 的轮胎检测算法应用[J]. 电子测量技术, 2024, 47(7):88-94.
- ZHU H Y, WANG M Q, JIA H, et al. Application of tire detection algorithm based on multi-dimensional dynamic attenuation Transformer [J]. Electronic Measurement Technology, 2024, 47(7): 88-94.
- [13] ZHENG Z Z, YANG H B, ZHOU L, et al. HLU 2-Net: A residual U-structure embedded U-Net with hybrid loss for tire defect inspection [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [14] XIA Z F, PAN X R, SONG S J, et al. Vision transformer with deformable attention [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 4794-4803.
- [15] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [16] SUNKARA R, LUO T. No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects [C]. Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443-459.
- [17] CUI Y N, REN W Q, KNOLL A. Omni-Kernel network for image restoration[C]. AAAI Conference on Artificial Intelligence, 2024, 38(2): 1426-1434.
- [18] ZHANG H, ZHANG S J. Focaler-IoU: More focused intersection over union loss[J]. ArXiv preprint arXiv: 2401.10525, 2024.

作者简介

王广周, 硕士研究生, 主要研究方向为目标检测。

E-mail: wangguangzhou21999@163.com

崔雪红(通信作者), 副教授, 博士, 主要研究方向为人工智能、计算机视觉。

E-mail: cuixuehongzhe@163.com

王旭, 硕士研究生, 主要研究方向为目标检测。

E-mail: 17860273050@163.com

龚玉洁, 硕士研究生, 主要研究方向为目标检测。

E-mail: gongyujie0303@163.com

丁志星, 硕士研究生, 主要研究方向为目标检测。

E-mail: 1410452670@qq.com