

基于 YOLO11s 改进的轻量级钢材表面缺陷检测模型^{*}史林江¹ 黄海松^{1,2}

(1. 贵州大学机械工程学院 贵阳 550025; 2. 贵州大学现代制造技术教育部重点实验室 贵阳 550025)

摘 要: 针对现有钢材表面缺陷检测算法在资源消耗、检测精度上难以平衡的问题,提出一种基于 YOLO11s 改进的轻量级钢材缺陷检测算法(EEC-YOLO)。首先采用 ADown 下采样模块,缓解细粒度信息丢失的同时实现模型轻量化;其次,设计了一种新颖的跨通道交互的高效率注意力(EPCA),并嵌入 YOLO11s 主干网络中,从频域维度强化多尺度缺陷特征提取,减少特征信息缺失;最后,设计增强型筛选特征金字塔网络(ES-FPN),通过使用增强局部注意力(ELA)机制与组归一化优化特征选择与融合效果,对 YOLO11s 的特征融合网络进行重构,提升模型对小目标的关注和检测能力。在 NEU-DET 数据集上,较 YOLO11s 的 mAP@0.5 提升 3%,达到 79.8%,参数量降低 45.1%,计算量降低 30.5%;在 GC10-DET 数据集上,mAP@0.5 提升 3.2%,达到 65.6%,参数量降低 45.0%,计算量降低 30.2%。该算法实现了检测精度、计算成本与效率的良好平衡,为边缘终端设备的工业落地提供有力支持。

关键词: 钢材缺陷表面检测;YOLO11s;模型轻量化;注意力机制

中图分类号: TP391.9;TN911 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improved lightweight steel surface defect detection algorithm
based on YOLO11sShi Linjiang¹ Huang Haisong^{1,2}

(1. School of Mechanical Engineering, Guizhou University, Guiyang 550025, China; 2. Key Laboratory of Advanced Manufacturing Technology of the Ministry of Education, Guizhou University, Guiyang 550025, China)

Abstract: Aiming at the problem that the existing steel surface defect detection algorithms are difficult to balance resource consumption and detection accuracy, an improved lightweight steel surface defect detection algorithm based on YOLO11s (EEC-YOLO) was proposed. Firstly, the ADown downsampling module was used to alleviate the loss of fine-grained information and realize the model lightweight. Secondly, a novel enhanced pooling channel attention (EPCA) attention mechanism is proposed and embedded in the YOLO11s backbone network to strengthen multi-scale defect feature extraction from the frequency domain dimension and reduce the lack of feature information. Finally, an enhanced screening feature pyramid network (ES-FPN) was designed, and the feature fusion network of YOLO11s was reconstructed by using the enhanced local attention (ELA) mechanism and group normalization to optimize the feature selection and fusion effect, so as to improve the attention and detection ability of the model for small targets. On NEU-DET dataset, compared with YOLO11s, its mAP@0.5 is improved by 3% to 79.8%, the number of parameters is reduced by 45.1%, and the amount of calculation is reduced by 30.5%. On the GC10-DET dataset, mAP@0.5 is increased by 3.2% to 65.6%, the number of parameters is reduced by 45.0%, and the amount of calculation is reduced by 30.2%. The proposed algorithm achieves a good balance between detection accuracy, computational cost and efficiency, and provides strong support for the industrial landing of edge terminal devices.

Keywords: steel defect surface detection;YOLO11s;model lightweight;attention mechanism

0 引 言

作为重要的工业材料之一,钢材在建筑、交通、工业制

造等领域中得到广泛应用^[1]。但是,在实际生产过程中,受加工设备和工艺的影响,产品表面会产生裂纹、气孔和夹杂物等缺陷^[2],这些缺陷,无论是直接或是间接,都会对带钢

收稿日期:2025-11-07

* 基金项目:国家自然科学基金项目(52165063,52575566)、贵州省省级科技计划项目(黔科合成果-LH[2024]重大 017,黔科合成果 DXGA[2025]一般 002,黔科合支撑 DXGA[2025]一般 008,黔科合支撑[2025]一般 018,黔科合支撑[2024]一般 093,黔科合平台人才-CXTD[2023] 007,黔科合支撑[2023]一般 348,黔科合支撑[2023]一般 309,黔科合平台人才-GCC[2022]006-1)、贵州省教育厅揭榜挂帅项目(黔教技[2025] 018 号)资助

的质量和性能产生重大影响。因此,如何实现精确、高效的钢材表面缺陷检测,以确保最终产品的质量和性能具有重要意义。

目前,钢材表面缺陷检测,主要可分为传统方法和基于深度学习方法。传统的检测方法包括目视检查、磁粉检查、涡流检查和超声波检测^[3]。然而,这些检测技术复杂、成本高昂、对检验员要求高,容易导致误检、漏检,且难以进行大规模检测^[4]。随着深度学习技术的迅猛发展,基于图像的物体检测方法已经在工业领域中得到了广泛应用^[5]。基于深度学的表面缺陷检测方法,根据是否有区域提案可以分为两大类:一阶段和两阶段的检测算法^[6]。典型两阶段算法有R-CNN^[7]、Fast R-CNN^[8]、Faster R-CNN^[9]和Mask R-CNN^[10]。两阶段目标检测算法会首先生成一系列包含潜在物体的候选区域,然后在这些候选区域内进一步生成对象的精确位置信息和分类信息。因此具有较高的检测精度,但检测速度较慢、模型体积较大,不利于边缘终端设备部署。相较之下,一阶段方法包括SSD^[11]、YOLO系列^[12-15]、RetinaNet^[16]等算法,直接生成概率和位置坐标,简化了过程,提高了检测速度^[17]。其中,值得注意的是,在钢材表面缺陷检测中,YOLO模型以其出色的实时性和高精度,一定程度上满足了工业对速度和性能的双重需求^[18]。然而,在钢材表面缺陷检测任务中,主要的挑战包括缺陷形态的复杂多样、小尺度缺陷的难以准确识别以及终端设备计算能力的有限性。这些因素使得现有的检测方法面临精度与计算成本之间的巨大矛盾。因此,研究更加轻量化且具有较高准确度的检测技术,成为当前工业界亟待解决的问题^[19]。

为解决这些问题,众多研究者提出一系列钢材表面缺陷检测模型。曹义亲等^[20]基于YOLOv5算法,构造SPP_Res特征金字塔结构,同时加入多头注意力机制,有效提升检测精度,但该算法对部分小尺度目标(如裂缝类)检测效果较差。Wu等^[21]提出了一种基于YOLOv5s的SDD-YOLO模型,用于钢材缺陷检测。该模型设计了Convolutional-ghostnet混合模块和多卷积特征融合模块,可以降低计算复杂度,提高特征提取效率。Liu等^[22]提出了ST-YOLO模型用于钢材缺陷检测,采用分流融合网络和自整定最优传输标签分配算法,实现了分类与定位任务的高效特征融合。Kou等^[23]基于YOLO-V3提出了一种无锚点的端到端缺陷检测模型:首先,通过自适应特征尺度选择机制取代传统锚点结构,显著降低计算开销;其次,融入定制化密集卷积块,增强特征提取、复用与表征能力。Zhao等^[24]基于YOLOv5提出了用于钢材表面缺陷检测的RDD-YOLO模型。该模型通过引入Res2Net扩展多尺度感受野,在Neck端设计双特征金字塔(double feature pyramid network,DFPN)深度融合高低层信息,最后,在Head端解耦分类与回归任务。实验结果显示,较原YOLOv5性能得到了显著提升。Zhang等^[25]在YOLOv5s

骨干中加入拉普拉斯锐化以提取清晰多尺度特征,在Neck端引入搭载C3模块的残差加权双向特征金字塔(residual-weighted bidirectional feature pyramid network embedded with C3 module,C3-BiFPN)以增强各尺寸缺陷的表示,以及在Head端通过K-means聚类生成4组先验框,分别预测不同大小的目标。所提出的框架能够有效检测热轧钢的表面缺陷,具有实时表面缺陷检测的潜力。Li等^[26]结合YOLOv5的颈部结构,使用了多尺度特征提取(multi-scale feature extraction,MSFE)模块和高效特征融合(efficient feature fusion,EFF)模块来提高检测精度。Li等^[27]在YOLOX算法中引入自适应空间特征融合(adaptive spatial feature fusion,ASFF)模块,有效融合多尺度特征,从而提升了检测精度,但同时增加了模型体积。尽管上述方法在钢材缺陷检测中取得一定进展,然而,这些方法在处理小尺度缺陷和模型轻量化上仍存在一定的挑战。

本研究提出一种改进的YOLO11s轻量化钢材表面缺陷检测算法(EEC-YOLO),该算法有效地平衡了检测精度和计算成本。该算法不仅在传统钢材缺陷检测任务中取得了较高的精度,同时具备较低的计算复杂度,适合在工业边缘设备中部署。引入ADown下采样模块替代传统卷积模块,有效缓解细粒度信息丢失问题,同时提升模型效率。设计跨通道交互的高效通道注意力(enhanced pooling channel attention,EPCA)机制,并嵌入YOLO11s主干网络,增强了多尺度缺陷特征的提取能力。设计增强型筛选特征金字塔网络(enhanced screening feature pyramid network,ES-FPN),优化了YOLO11s的特征融合能力,提升了对小目标的检测精度。在NEU-DET和GC10-DET数据集上的实验结果表明,EEC-YOLO相比YOLO11s提高了检测精度,并显著降低了计算复杂度和参数量。

1 YOLO11模型介绍

YOLO11是YOLO系列的第11代模型,在YOLOv8的基础上进行了深度优化。该模型在保持高检测精度的同时,通过结构精简和训练策略优化,实现了计算效率与性能的良好平衡。YOLO11s网络主要由主干、颈部和头部3部分组成,结构如图1所示。其中,主干网络负责特征提取,输入图像经过多层卷积逐步下采样以获得多级语义信息。YOLO11s采用了改进的C3k2模块替代C2f模块,兼具C2f的高效性与C3k的灵活性,从而在加快计算速度的同时保持高检测性能。此外,主干中引入C2PSA模块与SPPF模块结合使用,利用空间注意力机制强化特征表达,使模型能更聚焦于关键区域,提高对目标的识别能力。颈部结构采用特征金字塔网络(feature pyramid network,FPN)与路径聚合网络(path aggregation network,PAN)相结合的多尺度特征融合方式,通过上采样与特征拼接实现不同层级特征的整合,以增强模型对多尺度目标的检测能力。头部结构则对融合后的特征进行检测输出,YOLO11s

在检测头中引入了两个深度可分离卷积 (depthwise separable convolution, DWConv), 通过在每个通道上独立卷积的方式减少通道间冗余计算, 进一步提升推理速度与检测效率。整体而言, YOLO11s 模型在结构设计上兼顾了轻量化与高性能, 为后续改进模型 EEC-YOLO 的设计提供了高效可靠的基础。




图 1 YOLO11s 网络结构

Fig. 1 YOLO11s network structure

2 改进 YOLO11s 模型

本研究提出了一种轻量化的 EEC-YOLO 检测模型, 用于提升钢材表面缺陷检测的精度、降低计算成本并提高效率, 尤其适用于资源受限且对实时性要求高的场景。首先, 设计了一种 EPCA 注意力模块并嵌入在骨干网络的底端, 从频域维度减少特征信息缺失, 增强对复杂缺陷的识别精度。这一策略显著提高了骨干网络的有效提取缺陷特征的能力。其次, 采用 ADown 轻量化卷积模块替换原模型中的使用的下采样方法, 以减少因下采样导致的信息丢失问题以及轻量化实现。最后, 设计了轻量化网络 ES-FPN 优化 YOLOs 特征融合层。ES-FPN 基于高层筛选特征金字塔网络 (high-level screened feature pyramid network, HS-FPN), 引入增强局部注意力机制, 进行颈部特征融合, 应对钢材缺陷检测中的多尺度挑战。其结构如图 2 所示。

2.1 EPCA 注意力机制模块

在深度卷积神经网络中, 通道注意力 (channel attention, CA) 机制通过学习各通道的重要性, 帮助网络在训练过程中聚焦于关键信息, 从而提升模型在视觉任务中的性能。传统的 SENet (squeeze-and-excitation network) 采用了全连接层来进行通道间的依赖捕捉, 但这种方法需要对特征图进行显式的降维再升维, 增加了计算复杂度且容易导致模型的过拟合。因此, 随着对计算效率的需求增加, 高效通道注意力 (efficient channel attention, ECA) 机




图 2 EEC-YOLO 网络结构

Fig. 2 EEC-YOLO network structure

制中使用了基于一维卷积的通道间依赖捕捉方法。ECA 无需进行显式的降维, 避免了传统方法的计算开销, 同时也能够有效地捕捉通道间的依赖关系。ECA 首先通过全局平均池化 (global average pooling, GAP) 对每个通道的空间特征进行聚合, 生成 1 个标量表示全局语义。随后, ECA 通过一维卷积在通道维度上滑动, 学习相邻通道之间的加权关系, 并使用 Sigmoid 激活函数将加权结果映射到 (0, 1) 区间, 与输入特征逐通道相乘, 从而实现特征的加权分配。然而, 单一的 GAP 忽略了通道间局部最显著激活点的细节信息, 这在处理一些细粒度特征时可能导致性能的下降, 尤其是对于钢材表面缺陷的细节提取, 平均池化方法往往无法捕捉到不同尺度的局部激活信息。

为了解决这一问题, 提出了 EPCA 模块, 如图 3 所示。通过以下两方面的改进显著提升了注意力机制的性能。




图 3 EPCA 模块结构

Fig. 3 EPCA module structure

1) 分级通道建模: 为了使注意力机制能够在更细粒度的通道子空间内进行学习, EPCA 首先将通道维度划分为若干组。每组通道分别进行池化和一维卷积操作, 最后将各组的输出重新拼接回原始的通道维度。这种分组建模方式使得每一组通道能够独立学习特定的注意力模式, 从而在局部特

征和全局特征之间建立起“局部-整体”的建模层次。

2)多源池化特征融合:传统的ECA机制依赖于GAP来提取全局特征,但这种方式无法有效捕捉到局部显著的激活点,尤其是在具有复杂表面缺陷的钢材图像中,某些细节特征可能被全局池化所忽略。为此,EPCA在GAP的基础上引入了全局最大池化(global max pooling, GMP)。通过对全局平均池化和全局最大池化结果的加权融合,EPCA能够同时保留通道的整体语义信息和局部最强激活信息。

为了更好地理解EPCA模块的理论优势,将其与现有的ECA和卷积块注意模块(convolutional block attention module, CBAM)进行对比分析,重点探讨其在频域处理和多池化融合方面的创新。在ECA中,采用一维卷积学习通道间的加权关系,避免了传统SENet中计算复杂度较高的全连接层结构。然而,ECA仍然依赖于GAP来提取通道的全局语义信息,虽然能够有效捕捉全局信息,但其忽视了通道中最显著的激活点,导致在细粒度特征捕捉上存在不足,尤其在钢材表面缺陷检测中,缺陷形态的多样性和小尺度缺陷的特征要求模型能够准确捕捉细节信息,而传统的GAP方法未能完全解决这一问题。与ECA相比,CBAM引入了双重注意力机制,同时考虑通道和空间的注意力,增强了模型的表达能力,但其对频域处理的探讨较为有限,未能深入研究不同池化方式对特征提取的影响。EPCA模块通过融合GAP和GMP的多池化机制,能够在捕捉全局平均信息的同时,通过最大池化保留局部显著特征,显著增强了对细粒度特征的捕捉能力。这使得EPCA在频域处理上表现出比ECA和CBAM更为优越的性能,尤其在钢材表面缺陷检测中,对于细小缺陷或复杂形态缺陷的处理更加精准。另一方面,ECA仅使用GAP聚合全局信息,尽管能够有效捕捉全局语义,但对于局部显著特征的敏感性较差,尤其在多尺度特征处理上存在局限;而CBAM通过处理通道和空间的双重注意力信息增强了特征表达,但在多尺度特征的处理上仍有所欠缺。相比之下,EPCA通过引入GMP,实现了多池化的融合,不仅能够捕捉到通道的全局语义信息,还能保留局部最强激活信息,从而提高了对多尺度特征的敏感性,特别是在钢材表面缺陷检测中,能够更好地处理复杂形态或微小缺陷,提高检测精度和模型的鲁棒性。综上所述,EPCA在频域处理和多池化融合方面的创新,使其在钢材表面缺陷检测任务中,尤其是在细粒度特征和多尺度特征的捕捉能力方面,具有显著优势。

因此,为了减少与目标特征无关的干扰,提高钢材缺陷检测精度,在YOLO11s模型的主干网络底部引入了EPCA模块。该模块在保持较低参数数量和计算量的同时,显著提升了网络的视觉识别性能。

2.2 ADown模块

下采样在YOLO模型中至关重要,因为它能够在减小特征图尺寸的同时保留关键信息,降低计算负荷和参数数

量,从而加速网络的训练和推理过程。在YOLO11s网络中,卷积(Convolution, Conv)被用于下采样,虽然它有效地减小了特征图的大小,但也导致了细粒度信息的丢失。由于钢材缺陷的特征较为微弱且缺乏冗余信息,细粒度信息的丢失会显著影响模型的检测性能。为了克服这一问题,引入了来自YOLOv9项目的ADown下采样模块,替代YOLO11s主干中的Conv操作。ADown模块通过更高效的设计,能够更好地保留细粒度特征信息,提升模型在钢材缺陷检测中的表现。ADown模块的结构如图4所示。




图4 ADown模块结构

Fig. 4 ADown module structure

2.3 ES-FPN模块

在YOLO11的多尺度特征融合模块中,PANet通过引入自顶向下和自底向上的双向信息流,提升了不同尺度特征的整合效果。然而,PANet在处理大分辨率特征图时,可能会因为细节信息的丢失而导致性能下降,且常规的上下采样操作可能削弱部分原始信息。为了解决这一问题,本研究在HS-FPN^[28]框架下对YOLO11的特征融合模块进行了改进。首先,HS-FPN通过CA机制对不同尺度的特征图进行加权,并对特征进行维度对齐。接着,采用选择性特征融合策略,将高层语义信息与低层细节信息有效融合,从而增强模型对微小目标和复杂结构的检测能力。然而,如图5(a)所示,CA模块使用 1×1 卷积存在空间信息提取不足和长期依赖捕获不充分的问题。为此,本研究提出了ES-FPN,使用增强局部注意力(efficient local attention, ELA)机制^[29]替代CA,如图5(b)所示,ELA通过一维卷积在水平和垂直方向上提取位置信息,卷积核尺寸从传统的1扩展到5或7,显著增强了对长距离依赖的捕获能力。同时,为了避免批量归一化带来的性能波动,ELA采用了组归一化,进一步提升了模型的泛化能力。

在多尺度特征对齐之后,ES-FPN通过选择性融合策略,将高层语义信息与低层细节信息协同集成,最大程度保留原始信息。这种协同融合使模型在检测钢材微小缺陷时更加精准。如图5(c)、(d)所示,ES-FPN的结构由两个主要组件组成。




图 5 ES-FPN 模块结构

Fig. 5 ES-FPN module structure

1) 特征选择模块: ELA 模块在此过程中起着重要作用, ELA 首先对输入的特征图 $f_{in} \in \mathbf{R}^{C \times H \times W}$ 进行处理, 其中 C 表示通道数, H 表示特征图的高度, W 表示特征图的宽度。对于给定输入 x , ELA 在两个空间范围内对每个通道进行平均池化: 沿水平方向的 $(H, 1)$ 和沿垂直方向的 $(1, W)$ 。因此, 第 C 个通道在高度 h 处和宽度 w 处的输出可以表示为:

$$Z_C^w(w) = \frac{1}{W} \sum_{0 \leq j < W} x_c(j, w) \quad (1)$$

ELA 通过 1D 卷积增强水平和垂直方向的位置信息, 并使用组归一化 (group normalization, GN) 处理这些增强的信息, 从而得到在水平和垂直方向上位置注意力表示, 如式 (3) 和 (4) 所示。

$$y_h = \sigma(\text{GN}(F_h(Z_h))) \quad (2)$$

$$y_w = \sigma(\text{GN}(F_w(Z_w))) \quad (3)$$

其中, σ 是非线性激活函数, F_h 和 F_w 表示内核大小为

5 或 7 的 1D 卷积。

最后, 可以得到 ELA 模块的输出, 记为 Y :

$$Y = x_c \times y^h \times y^w \quad (4)$$

最后, 通过将位置注意力与相应比例的特征图相乘, 可以生成过滤后的特征图。然后, 应用 1×1 卷积, 将每个尺度特征图的通道数减少到 256 个, 确保不同尺度之间的维度一致性。

2) 特征融合模块: 在 YOLO11s 的特征融合模块中, 骨干网络输出的多尺度特征图呈现出语义信息丰富但目标定位较为粗糙的高层特征, 而低层特征则提供了精确的目标位置但缺乏深层语义。传统的做法是通过上采样将低层特征与高层特征逐像素相加, 以增强每一尺度的语义表达, 但这种方式并未对不同特征进行有效筛选, 导致信息融合不够精细。为克服这一局限, 引入了选择性特征融合 (selective feature fusion, SFF) 模块, 通过对多层特征的通道或空间权重进行学习, 实现有针对性的特征筛选与融合, 从而在保证定位精度的同时进一步丰富语义信息。给定输入高层特征 $f_{high} \in \mathbf{R}^{C \times H \times W}$ 和低层特征 $f_{low} \in \mathbf{R}^{C \times H_1 \times W_1}$, 首先通过步长为 2、核大小为 3×3 的转置卷积对高级特征进行扩展, 得到特征大小为 $\hat{f}_{high} \in \mathbf{R}^{C \times 2H \times 2W}$ 。然后, 通过 ELA 模块将高级特征转换为相应的注意力权重, 以过滤低级特征, 获得一致维度的特征。最后, 将滤波后的低级特征与高级特征融合, 增强模型的特征表示, 得到: $f_{out} \in \mathbf{R}^{C \times H_1 \times W_1}$ 。

3 实验设计与结果分析

3.1 数据集

在本实验中, 使用 NEU-DET^[30]、GC10-DET^[31] 数据集评估 EEC-YOLO 的有效性。实验按照 8:1:1 的比例随机划分训练集、验证集和测试集。

NEU-DET 数据集包括 6 类典型的热轧带钢表面缺陷, 即裂纹 (crazing, Cr)、夹杂 (inclusion, In)、斑块 (patches, Pa)、麻点 (pitted surface, Ps)、压入氧化铁皮 (rolled-in scale, Rs) 和划痕 (scratches, Sc), 图像的原始分辨率为 200×200 pixels, 每类缺陷的图片都有 300 张, 共 1 800 张。其中 4 189 个缺陷可供评估。在这些缺陷中, 有 447 个小缺陷, 其尺寸 $\leq 32 \times 32$ pixels, 符合 MS-COCO 度量评估标准^[32]。

GC10-DET 数据集包括 10 种缺陷, 包括冲孔 (punching, Pu)、焊缝 (welding line, Wl)、月牙形间隙 (crescent gap, Cg)、水斑 (water spot, Ws)、油斑 (oil spot, Os)、丝斑 (silk spot, Ss)、夹杂物 (inclusion, In)、轧坑 (rolled pit, Rp)、折痕 (crease, Cr) 和腰部折痕 (waist folding, Wf)。GC10-DET 中有 2 294 张图像, 每张图像的大小为 $2\,048 \times 1\,000$ pixels。

3.2 实验设置

本实验软硬件主要配置如表 1 所示。实验设置基本采

用 YOLO11 官方在大型目标检测数据集 COCO 上所得到的推荐参数。在训练阶段,设置随机梯度下降 (stochastic gradient descent,SGD) 优化器对网络参数进行迭代更新,初始学习率设为 0.01,设定早停机制 patience 为 50,动量 momentum 设为 0.937,权值衰减因子 weight_decay 设置为 0.0005。输入图像尺寸为 640×640 pixels,batch size 大小为 16,epoch 为 200 轮。在最后 10 轮关闭 Mosaci 数据增强。

表 1 软硬件环境配置

Table 1 Hardware and software environment configuration	
环境名称	版本/大小
操作系统	Windows 11
处理器	12th Gen Intel(R) Core(TM) i7 12700F
内存	16 G
显卡	NVIDIA GeForce RTX3060(12 GB)
编程语言	Python 3.8
深度学习框架	Pytorch 1.11、CUDA 11.3
编译软件	Visual Studio Code

3.3 评价指标

本实验采用平均精度均值 (mean average precision, mAP)、精确度 (precision, P)、召回率 (recall, R)、参数量 (parameters, Params)、计算量 (FLOPs)5 个指标对网络性能进行评估。上述指标的定义式分别如式(5)~(8)所示。

$$P = \frac{TP}{TP + FP}$$
(5)

$$R = \frac{TP}{TP + FN}$$
(6)

$$AP = \int_0^1 P dR$$
(7)

$$mAP = \frac{\sum_{i=1}^N AP_i}{N}$$
(8)

其中,N 表示待检测目标的类别数;真阳性 (true positive, TP)是正确检测到的缺陷样本的数量;假阳性 (false positive, FP)是检测到的非缺陷样本数;假阴性 (false negative, FN)是错误检测到的缺陷样本的数量。

3.4 注意力机制对比实验

为了验证在主干特征提取 C2PSA 网络层之后引入 EPCA 注意力机制带来的性能提升,本实验在 NEU-DET 数据集上,将基线模型分别引入当前主流的注意力机制后的效果作对比,以证明改进方法的有效性,结果如表 2 所示,其中最优值加粗显示。

根据对比实验结果,引入 EPCA 模块后,YOLO11s 模型在检测精度上表现出显著提升。基线模型 YOLO11s 的 mAP 为 76.8%,而 EPCA 的 mAP 达到了 78.4%,提升了 1.6 %,显示出 EPCA 在提升检测精度方面的显著优势。

表 2 注意力机制对比实验结果
Table 2 Experimental data comparison on attentional mechanisms

模型	mAP50/ %	Params/ (×10 ⁶)	GFLOPs	P/ %	R/ %
YOLO11s	76.8	9.415	21.3	72.6	72.0
+SA	77.4	9.415	21.3	71.5	73.2
+CA	77.5	9.441	21.3	74.3	71.2
+ECA	77.9	9.415	21.3	72.9	73.3
+CBAM	77.2	9.678	21.3	70.6	71.4
+ELA	77.6	9.419	21.3	71.2	72.7
+EPCA	78.4	9.415	21.3	73.4	73.0

相比其他主流注意力机制,如 SA(77.4%)、CA(77.5%)和 ECA(77.9%),EPCA 的提升幅度更为明显,表明其能更有效地增强模型对缺陷目标的关注。在参数量方面,所有引入注意力机制的模型均保持在 9.415×10⁶ 左右,表明 EPCA 未显著增加模型复杂度,保持了 YOLO11s 的轻量性。相比 CBAM(9.678×10⁶),EPCA 的参数量更低,确保了更高效性。各模型计算量均为 21.3 GFLOPs,进一步验证了 EPCA 对计算量的影响极小。在 P 和 R 方面,EPCA 分别达到了 73.4%和 73%,较 YOLO11s 提升了 0.8%和 1%。

综上,实验结果表明,EPCA 能有效增强 YOLO11s 模型在钢材缺陷检测中的性能,提升了模型对复杂背景下缺陷目标的关注,同时保持较低的计算量和参数量,具有较强的实际应用价值。

3.5 消融实验对比

本实验以 YOLOv11s 为基线模型,对其围绕 3 个方面进行改进,设计了轻量高效的 EEC-YOLO 模型。为验证每项改进的有效性,本研究分别在 NEU-DET、GC10-DET 数据集上进行 5 组消融实验。其中 M1 表示将原颈部网络替换成 ES-FPN 网络、M2 表示将原主干网络中的 Conv 下采样模块替换成 ADown 模块、M3 表示将原主干网络底部增加 EPCA 注意力机制模块。实验结果如表 3、4 所示,其中最优值加粗显示。

表 3 消融实验结果(NEU-DET)
Table 3 Results of the ablation experiment(NEU-DET)

模型	mAP/ %	Params/ (×10 ⁶)	GFLOPs	P/ %	R/ %
YOLO11s	76.8	9.415	21.3	72.6	72.0
+M1	77.8	6.566	18.9	76.0	72.1
+M2	77.4	8.031	17.4	74.2	72.1
+M3	78.4	9.415	21.3	73.4	73.1
+M1+ M2	78.5	5.179	15.0	76.2	72.1
+M1+M2+M3	79.8	5.168	14.8	78.6	72.9

表 4 消融实验结果(GC10-DET)

Table 4 Results of the ablation experiment(GC10-DET)

模型	mAP/ %	Params/ ($\times 10^6$)	GFLOPs	P/ %	R/ %
YOLO11s	62.4	9.429	21.5	65.9	59.8
+M1	64.4	6.577	19.0	69.1	58.3
+M2	62.7	8.032	17.4	60.9	64.1
+M3	64.3	9.429	21.5	68.7	60.1
+M1+M2	64.7	5.180	15.0	63.0	64.8
+M1+M2+M3	65.6	5.180	15.0	67.5	62.8

在 NEU-DET 数据集上,基线模型 YOLO11s 的 mAP 为 76.8%。引入 ES-FPN(M1)后,mAP 提升至 77.8%,表明 ES-FPN 在多尺度特征融合方面的有效性。替换为 ADown 模块(M2)后,mAP 为 77.4%,尽管提升幅度较小,但该模块有效减小了计算量。引入 EPCA 模块(M3)后,mAP 显著提升至 78.4%,证明 EPCA 在聚焦缺陷目标和减少背景干扰方面的优势。将三者组合后(YOLO11s+M1+M2+M3),mAP 达到 79.8%,为本次实验中的最佳结果,验证了三者协同作用的显著提升,同时保持较低的计算复杂度。在 GC10-DET 数据集上,YOLO11s 的 mAP 为 62.4%,引入 ES-FPN 后,mAP 提升至 64.4%,进一步体现了 ES-FPN 的优势。ADown 模块(M2)对 mAP 的提升较小,达到 62.7%,但其在计算量方面的减少十分显著。引入 EPCA 模块(M3)后,mAP 为 64.3%,增强了模型对缺陷的敏感性。组合 ES-FPN 和 ADown 后,mAP 达到 64.7%,进一步提高了检测精度;3 项改进(YOLO11s+M1+M2+M3)后的 mAP 为 65.6%,为 GC10-DET 数据集上的最佳结果。

图 6、7 为模型改进前后分别在 NEU-DET、GC10-DET 数据集上各类缺陷检测精度对比,可以看出,EEC-YOLO 相较于 YOLO11s 在两个数据集的各类缺陷上均表现出更大的雷达覆盖范围,说明模型在大多数类别上的检测精度均有所提升,且提升比较均衡。在 NEU-DET 数据集上,EEC-YOLO 在划痕、压入氧化铁皮和麻点等细粒度或纹理复杂的缺陷上提升更为明显;而在 GC10-DET 数据集中,对于基线精度较低或易混淆的类别(如轧坑、折痕等)提升幅度更大。说明 EEC-YOLO 的改进增强了模型对复杂缺陷的检测能力,使整体检测性能更加稳定、鲁棒性更强。

3.6 与其他算法对比实验

为验证本研究算法的优越性,相同实验条件下,在 NEU-DET、GC10-DET 数据集上,将改进后的算法与其他主流目标检测算法进行对比,包括 Faster R-CNN(ResNet-50)、SSD(VGG16)、YOLOv5s、YOLOv6s、YOLOv8s、YOLOv9s、YOLOv10s、YOLO11s、YOLO12s 算法。另外,




图 6 NEU-DET 各缺陷类别检测 AP 对比

Fig. 6 Comparison of AP for each defect category detection by NEU-DET




图 7 GC10-DET 各缺陷类别检测 AP 对比

Fig. 7 Comparison of AP for each defect category detection by GC10-DET

为进一步论证本研究改进后的 EEC-YOLO 的性能优势,增加文献[33-36]针对 NEU-DET 数据集的先进轻量模型对比实验。结果如表 5、6 所示,其中最优值加粗显示。

在 NEU-DET 数据集上,EEC-YOLO 的 mAP 达到了 79.8%,相比基线 YOLO11s 的 76.8%提升了 3%,优于其他主流目标检测算法,如 Faster R-CNN(74.4%)、YOLOv5s(74.1%)和 YOLOv6s(75.0%)。尤其是与传统的 SSD(67.8%)相比,EEC-YOLO 在精度上有了大幅提升,证明了其在钢材缺陷检测中的优越性能。同时,EEC-YOLO 的参数量仅为 5.168×10^6 ,计算量为 14.8 GFLOPs,明显低于其他算法(如 Faster R-CNN 的 136.79×10^6 参数和 369.8 GFLOPs),在保持较高检测精度的同时,极大地降低了计算成本。同时,与文献[33-36]提出的先进轻量化模

表 5 模型对比实验结果(NEU-DET)

Table 5 Models comparison experiment results(NEU-DET)

模型	mAP/ %	Params/ ($\times 10^6$)	GFLOPs	P/ %	R/ %
SSD	67.8	24.28	61.32	68.7	62.3
Faster-RCNN	74.4	136.79	369.8	75.4	72.2
YOLOV5s	74.1	9.12	24.0	68.3	70.5
YOLOV6s	75.0	16.30	44.1	73.1	69.7
YOLOv8s	75.6	11.14	28.4	73.4	70.2
YOLOV9S	74.6	7.18	27.0	76.9	68.6
YOLOv10s	73.5	8.05	24.7	74.7	69.3
YOLO11s	76.8	9.42	21.3	72.6	72.0
YOLO12s	75.3	9.08	18.7	76.5	66.5
文献[34]	78.5	5.88	10.9	—	—
文献[33]	73.1	20.5	—	—	—
文献[35]	77.2	7.04	—	73.9	74.1
文献[36]	79.7	7.0	15.6	77.1	74.6
EEC-YOLO	79.8	5.17	14.8	78.6	72.9

表 6 模型对比实验结果(GC10-DET)

Table 6 Models comparison experiment results(GC10-DET)

模型	mAP/ %	Params/ ($\times 10^6$)	GFLOPs	P/ %	R/ %
SSD	56.9	26.29	62.7	65.4	35.6
Faster-RCNN	64.8	137.10	402.2	65.3	63.5
YOLOV5s	61.9	9.12	24.0	71.3	56.4
YOLOV6s	62.2	15.98	42.8	64.0	62.4
YOLOv8s	61.8	11.14	28.6	60.6	62.5
YOLOV9S	61.7	7.18	27.0	65.8	60.8
YOLOv10s	60.6	8.06	24.7	57.3	60.2
YOLO11s	62.4	9.43	21.5	65.9	59.8
YOLO12s	63.2	9.08	19.3	64.5	65.2
EEC-YOLO	65.6	5.18	15.0	67.5	62.8

型进行对比,本研究提出的 EEC-YOLO 模型在保持更低计算成本的同时取得了更高的检测精度。具体而言,EEC-YOLO 在 NEU-DET 上的 mAP 达到 79.8%,略高于文献[36]模型的 79.7%,并明显优于文献[34](78.5%)及文

献[35](77.2%)。在模型复杂度方面,EEC-YOLO 的参数量仅为 5.17×10^6 ,小于大部分轻量化对比模型(如文献[34]的 5.88×10^6 、文献[36]的 7.0×10^6),计算量为 14.8 GFLOPs,也与同类轻量模型保持相当甚至更低的计算开销。尤其是相比文献[33]的 20.5×10^6 参数量,EEC-YOLO 在模型尺寸上具备显著优势。

在 GC10-DET 数据集上,EEC-YOLO 的 mAP 为 65.6%,同样超过了对比算法,如 YOLOv5s(61.9%)、YOLOv6s(62.2%)和 YOLOv8s(61.8%)。尽管 YOLO12s 的 mAP 相对较高(63.2%),但 EEC-YOLO 在计算效率上表现更为出色,参数量和计算量均明显低于 YOLO12s (9.08×10^6 和 19.3 GFLOPs)。这一结果表明,EEC-YOLO 不仅在精度上表现突出,而且在计算复杂度方面具有更好的平衡,对实时性和资源受限环境有较高要求的工业缺陷检测任务。

3.7 可视化对比实验


为了直观展示不同方法的检测效果,本研究将 EEC-YOLO 算法与 YOLO11s 模型在 NEU-DET 和 GC10-DET 数据集上的缺陷检测结果进行了可视化对比,如图 8 所示。

从图 8 可以看出,YOLO11s 模型存在漏检和误检现象,难以满足高质量钢材的生产需求。相比之下,EEC-YOLO 能够更加准确地检测有效缺陷区域,显著减少漏检和误检,尤其在检测裂缝、麻点和划痕等难以识别的缺陷时表现出色。如图 8(a)所示,在 NEU-DET 数据集上,EEC-YOLO 在裂纹、夹杂物、麻点和氧化皮等类别上取得了明显提升;而在 GC10-DET 数据集上,如图 8(b)所示,对于水斑、轧坑、折痕和腰部折痕 4 类缺陷,EEC-YOLO 的表现尤为突出。此外,EEC-YOLO 检测到的缺陷置信度明显高于 YOLO11s,尽管仍存在部分漏检,但总体检测效果优于基线模型。可视化结果表明,EEC-YOLO 具备更强的浅层特征提取能力,能够有效检测小目标,避免漏检和误检,并在检测性能上表现出显著优势。

此外,本研究还对 NEU-DET 和 GC10-DET 数据集的 6 类缺陷生成了可视化热力图,以便更直观地展示检测效果,如图 9 所示。从图 9(a)、(b)可以看出,热力图的可视化结果与图 8 的检测效果一致。对于难以检测的缺陷类别(如 NEU-DET 数据集中的裂纹、夹杂物、麻点和划痕,GC10-DET 数据集中的水斑、轧坑和折痕等),EEC-YOLO 相较于 YOLO11s 在缺陷区域的热力效果更为突出,漏检率和误检率更低,表明 EEC-YOLO 在小目标检测方面具有较强的性能和较高的鲁棒性。


3.8 泛化性实验

为了进一步评估本研究提出模型的泛化能力,在 PKU-Market-PCB 数据集^[37]上对 EEC-YOLO 进行了测试,将基线模型和本研究算法进行实验对比。该数据集总共包含 693 张带有相应注释文件的 PCB 缺陷图像。包括 115 张漏焊(missing_hole, Mh)、115 张缺口(mouse_bite,



(a) NEU-DET可视化检测结果

(a) NEU-DET visualization detection results



(b) GC10-DET可视化检测结果

(b) GC10-DET visualization detection results

图 8 检测可视化结果对比

Fig. 8 Comparison of detection visualization results

Mb)、116 张开路 (Open_circuit, Oc)、116 张短路 (short, Sh)、115 张毛刺 (spur, Sp) 和 116 张多余铜 (spurious_copper, Sc) 缺陷。在实验中,数据集划分、实验参数设置和

评价指标与第 3.1~3.3 节保持一致,其实验结果如表 7 所示,其中加粗表示最优值。

根据表 7 可知,EEC-YOLO 算法在 PCB 数据集上





图 9 热力图对比结果

Fig. 9 Heat map comparison results

mAP 值达到 95.8%，相较于基线模型提升 2.1%，表明本研究算法具备更强的小目标检测能力，同时参数数量和计算量也具有显著优势。同时，本研究算法在 PCB 板数据集上

的可视化结果如图 10 所示。从图 10 可以看出，本研究算法能够准确地检测出各种缺陷目标。实验结果表明本研究算法具备较强的泛化性能。

表 7 PCB 数据集实验结果对比

Table 7 Comparison of experimental results of the PCB dataset

模型	mAP/%	Params/($\times 10^6$)	GFLOPs	P/%	R/%
YOLO11s	93.7	9.42	21.3	95.4	91.8
EEC-YOLO	95.8	5.17	14.8	96.5	92.3




图 10 PCB 数据集检测可视化结果

Fig. 10 Heat map comparison results

4 结 论

本研究针对现有钢材表面缺陷检测模型参数量大、多尺度缺陷识别难,检测精度与模型轻量化难以平衡的问题,本研究提出 EEC-YOLO 轻量级算法。该算法通过 ADown 下采样模块实现轻量化压缩,EPCA 注意力机制强化特征提取、ES-FPN 网络优化特征融合,在 NEU-DET 和 GC10-DET 数据集上均实现精度提升与资源消耗降低,有效平衡了检测精度、与轻量化需求,具备良好泛化能力。未来将进一步优化模型工业现场稳定性与部署成本,推动其在工业钢材缺陷检测中的规模化应用。

参考文献

[1] LI M, WEI L SH, ZHENG B W. Steel surface defect detection based on improved YOLOv7[C]//2024 4th International Conference on Computer, Control and Robotics (ICCCR), 2024.

[2] DANG Z CH, WANG X SH. FD-YOLO11: A feature-enhanced deep learning model for steel surface defect detection [J]. IEEE Access, 2025, 13: 63981-63993.

[3] HUANG X H, ZHU J H, HUO Y. SSA-YOLO: An improved YOLO for hot-rolled strip steel surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-17.

[4] ZHANG W, LIU J Y, YAN ZH Q, et al. FC-YOLO: An aircraft skin defect detection algorithm based on multi-scale collaborative feature fusion [J]. Measurement Science and Technology, 2024, 35(11): 115405.

[5] SINGH S A, DESAI K A. Automated surface defect detection framework using machine vision and

convolutional neural networks[J]. Journal of Intelligent Manufacturing, 2023, 34(4): 1995-2011.

[6] 吴葛,朱宇凡,叶天成. 改进 YOLOv10 的钢材表面缺陷检测方法[J]. 电子测量技术, 2025, 48(4): 158-168.

WU G, ZHU Y F, YE T CH. Steel surface defect detection method based on improved YOLOv10[J]. Electronic Measurement Technology, 2025, 48(4): 158-168.

[7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014.

[8] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV), 2015.

[9] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[10] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017.

[11] QIAN H M, WANG H L, FENG S, et al. FESSD: SSD target detection based on feature fusion and feature enhancement[J]. Journal of Real-Time Image Processing, 2023, 20(1): 2.

[12] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and

- Pattern Recognition (CVPR), 2016.
- [13] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [14] LI C Y, LI L L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. ArXiv preprint arXiv: 2209.02976, 2022.
- [15] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023.
- [16] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017.
- [17] 赵佰亭, 张敏, 贾晓芬. YOLOv8n-CSG: 轻量化钢材表面缺陷检测算法[J]. 电子测量与仪器学报, 2025, 39(8): 115-125.
- ZHAO B T, ZHANG M, JIA X F. YOLOv8n-CSG: A lightweight steel surface defect detection algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 115-125.
- [18] XIA Y K, LU Y, JIANG X H, et al. Enhanced multiscale attentional feature fusion model for defect detection on steel surfaces[J]. Pattern Recognition Letters, 2025, 188: 15-21.
- [19] 赵海丽, 狄子隆, 景文博, 等. 融合动态卷积与可变形注意力的钢材缺陷检测[J]. 仪器仪表学报, 2025, 46(12): 75-86.
- ZHAO H L, DI Z L, JING W B, et al. Steel defect detection fusing dynamic convolution and deformable attention[J]. Chinese Journal of Scientific Instrument, 2025, 46(12): 75-86.
- [20] 曹义亲, 伍铭林, 徐露. 基于改进YOLOv5算法的钢材表面缺陷检测[J]. 图学学报, 2023, 44(2): 335-345.
- CAO Y Q, WU M L, XU L. Steel surface defect detection based on improved YOLOv5 algorithm[J]. Journal of Graphic Science, 2023, 44(2): 335-345.
- [21] WU Y Y, CHEN R H, LI Z, et al. SDD-YOLO: A lightweight, high-generalization methodology for real-time detection of strip surface defects[J]. Metals, 2024, 14(6): 650.
- [22] LIU S B, JIA M P. An adaptive shunt model for steel defect detection based on YOLOX[C]//2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2023.
- [23] KOU X P, LIU S J, CHENG K Q, et al. Development of a YOLO-V3-based model for detecting defects on steel strip surface [J]. Measurement, 2021, 182: 109454.
- [24] ZHAO C, SHU X, YAN X, et al. RDD-YOLO: A modified YOLO for detection of steel surface defects[J]. Measurement, 2023, 214: 112776.
- [25] ZHANG Y Z, WANG W J, LI Z M, et al. Development of a cross-scale weighted feature fusion network for hot-rolled steel surface defect detection [J]. Engineering Applications of Artificial Intelligence, 2023, 117: 105628.
- [26] LI Z G, WEI X M, HASSABALLAH M, et al. A deep learning model for steel surface defect detection [J]. Complex & Intelligent Systems, 2024, 10(1): 885-897.
- [27] LI C F, XU A, ZHANG Q B, et al. Steel surface defect detection method based on improved YOLOX[J]. IEEE Access, 2024, 12: 37643-37652.
- [28] CHEN Y F, ZHANG C Y, CHEN B, et al. Accurate leukocyte detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood diseases[J]. Computers in Biology and Medicine, 2024, 170: 107917.
- [29] XU W, WAN Y. ELA: Efficient local attention for deep convolutional neural networks [J]. ArXiv preprint arXiv:2403.01123, 2024.
- [30] HE Y, SONG K C, MENG Q G, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493-1504.
- [31] LYU X M, DUAN F J, JIANG J J, et al. Deep metallic surface defect detection: The new benchmark and detection network[J]. Sensors, 2020, 20(6): 1562.
- [32] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: Common objects in context[C]//Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 740-755.
- [33] 耿涛, 刘宇峰, 金海波. 改进YOLOv7的轻量化钢材表面缺陷检测算法[J]. 计算机工程与设计, 2025, 46(7): 1998-2003.
- GENG T, LIU Y F, JIN H B. Lightweight steel surface defect detection algorithm based on improved YOLOv7 [J]. Computer Engineering and Design, 2025, 46(7): 1998-2003.
- [34] 张政超. 改进YOLOv5的轻量级带钢表面缺陷检测[J]. 计算机系统应用, 2023, 32(6): 278-285.
- ZHANG ZH CH. Lightweight surface defect detection for strip steel based on improved YOLOv5 [J].

Computer Systems Application, 2023, 32(6): 278-285.

[35] 周彦, 孟江南, 王冬丽, 等. 基于多尺度轻量化注意力的钢材缺陷检测[J]. 控制与决策, 2024, 39(3): 901-909.

ZHOU Y, MENG J N, WANG D L, et al. Steel defect detection based on multi-scale lightweight attention[J]. Control and Decision, 2024, 39(3): 901-909.

[36] 梁礼明, 龙鹏威, 卢宝贺, 等. EHH-YOLOv8s: 一种轻量级的带钢表面缺陷检测算法[J/OL]. 北京航空航天大学学报, 1-15[2025-11-07]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0426>.

LIANG L M, LONG P W, LU B H, et al. EHH-YOLOv8s: A lightweight strip steel surface defect detection algorithm [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-15 [2025-11-07]. <https://doi.org/10.13700/j.bh.1001-5965.2024.0426>.

[37] HUANG W B, WEI P. A PCB dataset for defects detection and classification[J]. ArXiv preprint arXiv: 1901.08204, 2019.

作者简介

史林江, 硕士研究生, 主要研究方向为机器视觉、目标检测。
E-mail:gs.shilj23@gzu.edu.cn

黄海松(通信作者), 博士, 教授, 博士生导师, 主要研究方向为智能制造、制造大数据等。
E-mail:hshuang@gzu.edu.cn