

DOI: 10.13382/j.jemi.B2307060

ECC-YOLO: 一种改进的钢材表面缺陷检测方法*

赵佰亭¹ 张晨¹ 贾晓芬^{1,2}

(1. 安徽理工大学电气与信息工程学院 淮南 232001; 2. 安徽理工大学省部共建深部煤矿采动响应与灾害防控国家重点实验室 淮南 232001)

摘要:针对当前钢材表面缺陷检测效率低、检测精度差的问题,提出了一个模型,命名为 ECC-YOLO,基于 YOLOv7 的钢材表面缺陷检测。首先,为了提高主干网络特征图信息表征能力,引入了特征增强模块 ConvNeXt,通过融合深度可分离卷积、大核卷积,增强模型对细小裂缝的特征提取能力,其次设计了 C2fFB 模块,在增强目标特征信息的提取能力同时,显著降低了模型的计算量和参数复杂性。最后借助 ECA 注意力机制设计出 MPCE 模块,削弱复杂背景信息对钢表面缺陷检测的干扰,提升检测效率。最后,广泛的实验结果表明,ECC-YOLO 在 NEU-DET 数据集上,该模型的 mAP 达到 77.2%,相较于 YOLOv7, ECC-YOLO 的检测精度提高了 10.1%,模型参数量减 9.3%,该模型在钢表面缺陷检测中具有较好的综合性能。

关键词: 目标检测; 缺陷检测; YOLOv7; ConvNeXt; 注意力机制

中图分类号: TP206 **文献标识码:** A **国家标准学科分类代码:** 520.2060

ECC-YOLO: An improved method for detecting surface defects in steel

Zhao Baiting¹ Zhang Chen¹ Jia Xiaofen^{1,2}

(1. China Institute of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China; 2. State Key Laboratory of Mining Response and Disaster Prevention and Control in Deep Coal Mines, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: Aiming at the current problems of low efficiency and poor detection accuracy of steel surface defects, a model, named ECC-YOLO, is proposed for steel surface defects detection based on YOLOv7. Firstly, in order to improve the capability of feature map information characterization of the backbone network, a feature enhancement module ConvNeXt is introduced, which enhances the feature extraction capability of the model for fine cracks by fusing the depth separable convolution and the large kernel convolution, secondly, a C2fFB module is designed, which enhances the capability of extracting the feature information of the target and at the same time, reduces the computational volume and parameter complexity of the model significantly. Finally, the MPCE module is designed with the help of the ECA attention mechanism to weaken the interference of the complex background information on the steel surface defect detection and improve the detection efficiency. Finally, extensive experimental results show that the mAP of the model of ECC-YOLO reaches 77.2% on the NEU-DET dataset, and compared with YOLOv7, the detection accuracy of ECC-YOLO is improved by 10.1%, and the number of model parameters is reduced by 9.3%, which gives the model a better comprehensive performance in steel surface defect detection.

Keywords: target detection; defect detection; YOLOv7; ConvNeXt; attention mechanism

0 引言

钢材作为一种制造业的原材料之一,已经在航空航

天、高速铁路和车辆制造等领域广泛应用。但是在钢材生产和使用过程中,容易受到温度、碰撞等多种因素的影响,致使其表面的出现各种各样的缺陷,如裂纹、划痕、斑块、点蚀面等^[1]。这些典型的表面缺陷降低了钢材的强

度、韧性、耐腐蚀性和使用年限,甚至可能直接导致安全事故的发生。因此,实现钢材表面缺陷高精度检测具有重要意义。

传统的钢材表面缺陷检测方法包括了多种技术手段,其中最常见的人工检测方法和无损检测方法。人工检测方法通过人工的视觉来进行检测,虽然直观,但由于人为主观性的影响,其检测结果往往存在较大的误差。而且,人工检测需要耗费大量的人力资源和时间成本,检测效率低下。此外,人工检测还容易出现假检和漏检的情况,从而影响产品质量和生产效率^[2]。另一方面,无损检测方法则通过利用物理、化学或电磁等原理,对钢材表面缺陷进行快速而准确的检测。涡流检测法是其中的一种常用方法,它利用交流电在导体表面产生的涡流来检测缺陷,但是当涡流场发生变化时,检测速度可能会受到影响,尤其是在复杂生产环境中^[3];红外检测法则是通过红外检测设备捕捉物体表面温度的差异来识别潜在的缺陷,然而,由于物体表面温度受多种因素影响,该方法往往无法准确测定缺陷类型,而且设备安装成本较高,不利于大规模应用^[4];激光扫描检测法是利用激光作为光源,实现对缺陷的识别和分类,但对环境条件(如烟尘、振动等)的要求较严格,可能需要特定的环境控制措施以保证检测精度。因此,虽然无损检测方法具有较高的检测精度和效率,但在实际应用中仍存在一定的局限性。

近些年来,深度学习技术在图像处理和目标检测领域取得了飞速的发展,其中卷积网络(convolutional neural networks, CNN)作为一种强大的图像处理工具,逐渐成为目标检测任务的主流方法。根据目标检测的方法的设计思想和框架,主要分为两大类:一阶段算法以 SSD^[5]、RetinaNet^[6]、YOLO^[7-8] 系列为主,二阶段算法以 Mask R-CNN^[9]、Faster R-CNN^[10-11] 为主。两阶段目标检测算法首先在候选框中确定物体位置,然后会进一步对这些候选框分类和定位,最终得到缺陷检测的信息。Zhao 等^[12]提出一种改进 Faster R-CNN 方法,使用可变性卷积对 ResNet-50 网络进行重构,并使用特征金字塔网络 FPN 对特征图进行多尺度运算。改进的模型网络虽然性能优异,但检测速度仍然较慢;Hou 等^[13]使用 Cascade Mask RCNN 与迁移学习相结合来识别电缆表面缺陷;Wei 等^[14]基于 Faster R-CNN 网络提出一种棒材表面检测网络,引入加权感兴趣区域池化,同时使用严格非最大抑制算法,来提升对钢材表面缺陷小目标的检测。上述方法虽然取得了一定效果,但是其模型结构复杂,通常参数量较大,计算成本较高,无法满足工业中的实际应用需求。

单阶段检测方法算法可以直接一步对物体检测和定位,只需一次前向传播就可以得出检测结果,与二阶段检测算法相比提高了检测速度。Kou^[15]等设计一种 YOLOV3 算法,它选择无锚特征选择机制和引入密集卷

积块检测钢带的表面缺陷在 NEU-DET 数据集上达到了 72% 的 mAP。虽然利用无锚特性优化了检测性能,但存在模型复杂度和计算成本较高的不足。该模型是 Li 等^[16]在识别钢材表面缺陷时,在 YOLOV4 主干网络中引入 CBAM 注意力模块并结合接受场块(RFB),提高了网络检测缺陷的能力。该模型该方法仍然存在一定程度的误检,部分类别不能正确识别。马燕婷等^[17]通过引入 Transformer 自注意力机制在 YOLOv5 主干网络中,并结合 BiFPN 结构,提高了网络的提高了网络的检测速度和精度。在 YOLOv5 模型中, Xia 等^[18]设计出一种大核卷积模块 RepLK-C3 并引入到主干网络和颈部网络中,同时在设计出不同接受域的大核空间金字塔池(RepLKSP)模块,测试结果表明,平均检测准确率达到了 76.8%。虽然利用大核卷积提升了检测性能,但存在一些需要改进的地方,如在提取细小缺陷特征提取能力方面。以上几种单阶段检测方法可以与其他模块结合起来进行快速检测,但是在某些特定应用场景下,如钢材缺陷检测,其精度依然无法满足实际需求。

综上,为了实现钢材表面细小缺陷的准确、快速检测,设计了基于特征提取模块和高效通道注意力模块的目标特征提取方法,并进一步提出了钢材表面缺陷的检测网络 ECC-YOLO。ECC-YOLO 网络在强化模型特征表征能力的同时,又显著降低了参数量,实现了模型准确性与轻量化的平衡。

1 钢材表面缺陷检测模型 ECC-YOLO

钢材表面缺陷检测作为关键的质量控制环节,在生产和使用过程中,由于工艺的不完善或操作失误等原因会出现轧制氧化皮、斑块、开裂、点蚀表面、内含物和划痕等缺陷。为了避免安全事故,及早发现潜在风险,应该在表面缺陷刚出现时迅速而准确地进行检测。而在复杂背景条件下的自动识别钢材表面缺陷特征,以及轻量化智能检测网络的部署一直都是需要解决的难题。YOLOv7 是一种单阶段的检测算法,它对比其他的 YOLO 算法平衡了精度和速度。所以,本文选择以 YOLOv7 网络作为基础,设计一种改进的轻量化 YOLO 钢材表面缺陷检测的网络 ECC-YOLO,它的网络结构图如图 1 所示。

它是由 3 部分组成:主干特征提取网络、强化特征提取网络和预测网络。为针对 YOLOv7 网络对钢材表面缺陷的特征提取能力不足、网络模型复杂度高且运算速度慢等问题,对网络进行了 3 点改进:

1) 通过在主干特征提取网络中引入

ConvNext 模块,用其替换主干网络中 ELAN 模块,为了增强网络对钢材表面细小缺陷的特征提取能力。

2) 设计一种新的 C2fFB 模块,为了减少参数量,提升




图 1 ECC-YOLO 网络结构
Fig. 1 ECC-YOLO network structure

网络模型在钢材缺陷检测中的检测速度和精度的同时,也降低了计算成本。

3) 设计 MPCE 模块,形成注意力池化模块,为了削弱复杂背景信息对钢材表面缺陷检测的干扰,使网络更加关注细小缺陷目标信息。

1.1 ConvNext 模块

在对钢材表面进行缺陷检测时,由于其缺陷微小,YOLOv7 原始模型的主干网络中的 ELAN 结构对其特征能力提取不足,从而导致了细小缺陷检测精度偏低。为了充分提取钢材表面上的小目标特征,尝试在主干中引入特征能力更强的 ConvNeXt 结构模块。

ConvNeXt 网络是 Liu 等^[19]在通过借鉴了以往人的设计的 Transformer 经验上,改进了基于现有的 ResNet 网

络设计,使之具有“倒瓶颈”模块结构、深度分离卷积、大核卷积的特点。根据模型的计算复杂度的不同,ConvNeXt 有 4 个不同版本的 T/S/B/L。本文综合考虑使用钢材表面缺陷的类别与数据集的大小,选取了 ConvNeXt-B 版本,同时为了保持整体网络结构的稳定,提高对钢材表面缺陷特征的处理能力,将 ConvNeXt-B 模块替换成主干网络中的首个和最后一个 ELAN 模块。

在宏观设计上,ConvNeXt 网络和 ResNet 网络模块都是采用四阶分布设计的,只是在每个阶段的 Block 的模块数量不同,ResNet 网采取的比例是[3 : 4 : 6 : 3],而 ConvNeXt 采用的是更加合理的[3 : 3 : 9 : 3]设计比例,提高了计算速度并优化了网络结构。如图 2 是 ConvNeXt-B 模块结构,其中 h、w、dim 分别表示特征图的高、宽和层数。




图 2 ConvNeXt-B 模块结构图
Fig. 2 ConvNeXt-B module structure diagram

图 3 ConvNeXt Block 模块是 ConvNeXt-B 网路中的主要构成模块之一。ConvNeXt Block 模块相对于 ELAN 模块的结构的不同,它采用倒瓶颈的设计和 7×7 大卷积核相结合的方式。ConvNeXt Block 模块采用倒瓶颈的结构能有效的提取主干网络中图片高纬度的特征信息,避免了降采样过程中小目标钢材缺陷特征信息的丢失,提高了对钢材细小缺陷检测精度。

ConvNeXt Block 模块使用 7×7 大卷积核进行先对钢

材表面细小缺陷进行特征提取,并使用 LN 代替 BN 来解决网络层数增加导致中间特征图的偏移及梯度爆炸等负面影响以稳定模型,再使用 1×1 卷积核对钢材表面缺陷进行特征增强,能够有助于最大化通道维度信息的利用。

同时使用 GELU 激活函数替代 RELU 函数,增加其更好的非线性特性,有效的提升神经网络学习的速度和精度。此外,由于借鉴了 Swim Transformer^[20]的结构,减少了激活函数的使用,ConvNeXt 结构不仅强化了网络提




图3 ConvNeXt Block 模块结构

Fig. 3 ConvNeXt Block module structure diagram

取钢材表面小目标缺陷信息的能力,还使网络降低了浮点运算次数。

综上,在主干网络上引用 ConvNeXt 模块,不仅强化了主干网络对于钢材细小缺陷的特征提取能力,降低了特征信息的丢失程度,旨在提升特征提取能力的同时保持良好的速度,有助于模型的实际应用部署。

1.2 C2fFB 模块

ELAN 模块在 YOLOv7 中起着十分重要的作用。然而,由于 ELAN 模块包含大量的卷积模块和残差连接,使得网络模型的参数量变大、复杂程度加深,难以在较小的算力情况下来更大限度地提取有效特征信息。受到 C2f 模块结构的启发,C2f 模块具有可以将不同尺度的特征图进行融合,提高准确性的同时,带来更少的参数和计算量的优势。因此为解决上述问题,本文设计出一种轻量化的模块 C2fFB 模块来替换 Head 部分中的 ELAN 模块。C2f、C2fFB 模块,如图 4、5 所示。图中 h, w, k 分别代表特征图的高、宽以及卷积核尺寸, C_p 表示常规卷积通道数。




图4 C2f 模块结构

Fig. 4 C2f Module structure diagram

C2fFB 模块主要有 CBS 和 Split 和 FasterNet Block 组成,C2fFB 模块通过 Split 操作将卷积后的特征图张量拆分成多个小张量,实现特征图的并行计算,加快模型的训练速度和效率。其中 CBS 结构,它是由卷积层、批量归一化层和 SiLU 激活函数构成。而 FasterNet Block 是使用 FasterNet^[21] 中的部分卷积思想,从而提出一个 FasterNet Block 结构,它是以 PConv、 1×1 卷积和批量归一化层和 SiLU 激活函数构成,该结构在降低内存访问量的同时优化了冗余计算所带来的参数量问题,极大地提升了捕捉空间特征的能力。在归一层上,网络采取批量归一化(batch normalization, BN)方法,使网络实现更快的推理




图5 C2fFB 模块结构

Fig. 5 C2fFB Module structure diagram

速度。而 PConv 只是在于对一部分输入通道采用一般的卷积操作来获取空间特征,相对于普通卷积优势在于,它避免了对缺失位置的计算,在计算是跳过大量无效的位置,从而减少了内存访问的数量。PConv 的 FLOPs 表达式为:

$$\text{FLOPs} = h \times w \times k^2 \times c_p^2 \quad (1)$$

其中, h, w, k 分别代表特征图的高、宽以及卷积核尺寸, C_p 表示常规卷积通道数。

在实际实现时一般有 $r = \frac{c_p}{c} = \frac{1}{4}$, PConv 的 FLOPs

仅为常规卷积的 1/16。因此,本文使用 C2fFB 模块降低模型参数量,并提升网络模型对钢材表面缺陷检测中的检测速度和特征提取能力。

1.3 MPCE 模块

在对钢材表面缺陷的进行检测时,背景环境复杂,常使用单一的池化 MP 操作来减少特征图的特征,会导致细节信息上的丢失,使得网络难以准确捕捉裂缝等细小目标缺陷,而造成误检和漏检问题。考虑到在图像检测任务中融合注意力机制,能使网络更加关注裂缝缺陷的特征,抑制背景信息的干扰。所以本文构建一种 MPCE 注意力结构模块,MPCE 是在 MPConv 的模块的基础上引入 ECA 注意力机制模块的思想构建而成。ECA 注意力机制模块在不降维的前提下,可以更好地将通道和空间

注意信息相结合,从而在降低模型的复杂度的同时而提升网络的性能,所以将 MPConv 模块中第二条分支的原先的 CBS 模块替换成 ECA 注意力机制模块,MPConv 和 MPCE 模块如图 6、7 所示。




图 6 MPConv 模块结构

Fig. 6 MPConv module structure diagram




图 7 MPCE 模块结构

Fig. 7 MPCE module structure diagram

MPCE 模块是由两个分支构建而成,第一条分支先通过一个 MaxPool(最大池化层),经过下采样后,在通过一个 1×1 的 CBS 模块;第二条分支,先经过 ECA 注意力模块,在通过一个 3×3 的 CBS 模块,最后将第一个分支和第二个分支的结果进行 Concat 操作,然后进行输出,这样网络可以增强模型细小缺陷特征的提取能力。

其中高效通道注意力机制 (efficient channel attention, ECA),当输入单个图像 $X[C, H, W]$,其中 C 表示特征图通道数, H 表示特征图的高度和 W 表示特征图的宽度, ECA 注意机制首先进行 GAP (global average pooling) 来捕获每个通道的全局上下文信息。

$$GAP(X) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{cij}, \forall c \in \{1, \dots, C\} \quad (2)$$




图 8 六种类别的缺陷图像示例

Fig. 8 Example of defect images in six categories

2.2 实验环境与评价指标

设备配置: NVIDIA A100-PCI 的 GPU, AMD EPYC 7713 64-Core Processor@ 2.0 GHz 的 CPU, Linux 系统, 基于 Pytorch 框架, Cuda11.4, Cudnn8.2 加速, Python 版本为 3.8, 实验参数如表 1 所示。

在这种情况下, X_{cij} 表示特征图在通道 c 的第 (i, j) 处的特征值。GAP 输出是一个 C 维的向量, 每个元素反应了输入特征图中对应通道的平均响应。随后, ECA 模块进行卷积核大小为 k 的一维卷积操作, 从中获取局部通道之间的相关性, 再经过 sigmoid 激活函数学习通道注意力。其中一维卷积核的尺寸 k 与输入通道数 C 的公式为:

$$k = \varphi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{odd} \quad (3)$$

这里, γ 作为一个超参数, 作用是调节局部依赖范围印象, 同时控制调节不相同通道之间信息交互的程度。较小的 γ 值产生较大的卷积核大小, 增强局部感受野, 包含更广泛的通道依赖关系。odd 表示向上取最近的奇数。

MPCE 模块通过多尺度特征提取、ECA 注意力机制、信息融合等策略, 具有计算效率高、参数数量少、与现有卷积神经网络无缝兼容等优点, 将 MPCE 模块嵌入到特征增强网络中, 旨在削弱复杂背景信息对钢材缺陷检测的干扰, 增强模型细小缺陷和复杂特征的特征提取能力。

2 实验与结果分析

2.1 数据集

本文实验使用东北大学制作的公开数据集 NEU-DET(钢材表面缺陷)来训练和测试模型。NEU-DET^[22]数据集一共包含六种钢材表面缺陷, 分别是裂纹 (Cr)、夹杂 (In)、斑块 (Pa)、点蚀面 (Ps)、轧制氧化皮 (RS) 和划痕 (Sc), 一共有 1 800 张图片, 每种缺陷图像为 300 张, 其图片分辨率为 640×640 , 按照 8 : 1 : 1 的比例划分训练集、验证集和测试集, 即训练集 1 440 张, 验证集 180 张, 测试集 180 张。数据集部分图片如图 8 所示。

为了评估模型的整体性能, 本实验使用的评估指标是平均精度 (AP)、平均平均精度 (mAP)、参数量 Params (Parameters)。设置 IOU 阈值为 0.5, 当检测框与真实框交并比大于 0.5 时, 判定预测正确。其计算公式如下:

表 1 实验相关参数

Table 1 Relevant parameters of the experiments	
实验参数	参数量
Epoch	200
Batch size	16
Learning rate	0. 01
Optimizer	SGD
Size	640

$$P = \frac{TP}{TP + FP}$$

(4)

$$R = \frac{TP}{TP + FN}$$

(5)

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

(6)

$$mAP = \frac{1}{N} \sum_{i=0}^N AP(i)$$

(7)

其中, P 表示精确度, R 表示召回率, n 表示预测类别数量, TP 、 FP 、 FN 分别表示真正例、假正例,假反例。

2.3 消融实验

为了验证改进方案对钢材表面缺陷检测的有效性,本文在在 NEU-DET 数据集上进行了消融实验。为此开展下列表 2 的 5 个实验,每组实验都是同一个参数和网络环境测试。其中实验 1 为未加任何改进策略的 YOLOv7 网络,实验 2、3、4、5 则分别表示为引入 ConNeXt 模块、引入 C2fFB 模块、引入 MPCE 模块与 ECC-YOLO 网络。

由表 2 可以看出,实验 1 是未加任何改进策略的原始 YOLOv7 网络,其 mAP 值为 70.1%,其参数量为 36.5 M。实验 2 是在原始 YOLOv7 的网络上引入了 ConNeXt 模块,替换后的网络精度提升了 5.6%,在 Cr、In、Ps、Rs、Sc 等类别的检测准确率远远高于原始 YOLOv7 的网络。实验 2 证明它能增强网络对钢材表面缺陷的特征提取能力和网络的推理速度。实验是 3 是在强化特征提取网络将 YOLOv7 的 ELAN 模块替换为 c2fFB 模块,mAP 精度提升了 1.7%,虽然模型的浮点运算量没有降幅不大,但模型参数量明显减少了,减少了 20.71%,证明了 C2fFB 模块在提升精度的同时,也大大降低了模型的复杂度,获得更轻量化的模型。实验 4 是引入 MPCE 模块,此时的模型参数量是 36.5 M,mAP 为 71.4%,相比于原 YOLOv7 网络,mAP 值提升了 1.3%,该效果主要是由于 ECA 注意力机制削弱复杂背景信息对钢材缺陷检测的干扰,对钢材表面缺陷特征具有强化作用。最后在第 5 组实验,是加入了 3 种改进策略,mAP 达到了 77.2%,是其中最好的,比 YOLOv7 网络检测精度提升了 10.1%,模型参数量减少了 9.3%,结果表明改进的 ECC-YOLO 网络可以提高对钢材表面缺陷的种类的预测。对于六种类别缺陷均有不同程度的提升,其中 Rs 缺陷 AP 值从 54%提升到了 74.2%,提高了 20.2%。而检测 Sc 缺陷的 mAP 的值是最高的,其精度达到了 95.3%。表 2 的实验结果表明,3 种改进策略 ECC-YOLO 网络设计合理,对于钢材表面缺陷检测效果最佳,具有较好的检测精度和检测速度。

表 2 消融实验结果
Table 2 Ablation results

实验	mAP	Cr	In	Pa	Ps	Rs	Sc	Parameters/M
1	0. 701	0. 327	0. 797	0. 873	0. 779	0. 540	0. 891	36. 5
2	0. 755	0. 415	0. 808	0. 887	0. 796	0. 682	0. 944	39. 2
3	0. 718	0. 303	0. 801	0. 899	0. 765	0. 602	0. 934	31. 1
4	0. 714	0. 346	0. 811	0. 865	0. 765	0. 557	0. 938	36. 5
ECC-YOLO	0. 772	0. 434	0. 893	0. 843	0. 766	0. 742	0. 953	33. 13

2.4 对比实验

1) 不同注意力机制对比实验
为了验证引入 MPCE 注意力模块对钢材表面缺陷检

测的检测结果,以 YOLOv7 网络模型,将其与 SA、SimAM、ECA 注意机制模型在检测网络的 Head 部分进行对比,并在 NEU-DET 数据集上进行验证,如表 3 所示。

表 3 融合不同注意力模块验证实验
Table 3 Comparative experiment of different attention modules

Methods	mAP	Cr	In	Pa	Ps	Rs	Sc
YOLOv7	0. 701	0. 327	0. 797	0. 873	0. 779	0. 540	0. 891
YOLOv7+SA	0. 709	0. 281	0. 803	0. 875	0. 777	0. 594	0. 926
YOLOv7+SimAM	0. 709	0. 283	0. 793	0. 884	0. 770	0. 615	0. 909
YOLOv7+ECA	0. 714	0. 346	0. 811	0. 865	0. 765	0. 557	0. 938

由表 3 可得,不同的注意力机制对钢材缺陷检测的性能提升效果不同。其中使用 SimAM 模块检测网络对 Pa 和 Rs 的 AP 值分别为 88.4 和 61.5%,而在使用 ECA 模块检测网络时,Cr、In、Sc 的 AP 值为最高,分别为 34.6%、81.1%、93.8%,与原网络相比,AP 值分别提高了 1.9%、1.4%和 4.7%。与其他两种融入注意力机制的网络对比,使用 ECA 注意力机制对钢材缺陷中的 Cr、In、Sc 检测效果最好,并且 mAP 值达到了最高的 71.4%,优于表中的其他算法,证明了 ECA 注意力机制的有效性。

2) 不同网络模型对比实验

为了验证本文提出的 ECC-YOLO 网络算法的鲁棒性,分别将 YOLOv7 算法与 ECC-YOLO 在罐道表面缺陷数据集^[23]上进行对比实验。罐道表面缺陷数据集一共有 3 000 张图片,包含 abrasion (磨损)、crack (裂痕)、dislocation(错位)这 3 种罐道表面缺陷。将此数据集按照 NEU-DET 数据集相同的设置比例进行划分,实验结果如表 4 所示。

表 4 罐道表面缺陷数据集上的鲁棒性实验

Table 4 Robustness experiments on can surface defect dataset

模型	Precision	Parameters/M	mAP
YOLOv7	0.815	36.50	0.824
ECC-YOLO	0.829	33.13	0.846

表 5 不同目标检测网络对比实验

Table 5 Comparative experiment of different target detection networks

模型	mAP	Cr	In	Pa	Ps	Rs	Sc	Parameters/M
Faster-RCNN	0.575	0.221	0.492	0.821	0.820	0.333	0.764	108.9
RetinaNet	0.665	0.246	0.717	0.904	0.712	0.523	0.888	33.9
YOLOv4	0.681	0.271	0.787	0.887	0.707	0.565	0.867	72.8
YOLOv5	0.703	0.338	0.843	0.792	0.754	0.594	0.487	9.1
YOLOv7-tiny	0.662	0.221	0.854	0.727	0.735	0.539	0.898	6.0
YOLOv7	0.701	0.327	0.797	0.873	0.779	0.540	0.891	36.5
Kou's method	0.722	0.389	0.737	0.935	0.748	0.607	0.914	60.7
Zhao's method	0.752	0.501	0.791	0.792	0.874	0.649	0.905	—
ECC-YOLO	0.772	0.434	0.893	0.843	0.766	0.742	0.953	33.13M

为了更全面地展示 ECC-YOLO 网络模型在钢材表面缺陷检测方面的性能,本文通过图 9 进行了详细的对比分析。图 9 包含 3 行图片,分别展示了钢材表面缺陷的原始图片、YOLOv7 网络算法的检测效果图,以及 ECC-YOLO 网络算法的检测效果图。图中,每个框代表检测到的缺陷区域,每个缺陷区域上方标注了缺陷类别和缺陷的置信度,这一细节增加了结果的可解释性和实用价值。从图 9 的对比中可以观察到,使用原始 YOLOv7 网络进行缺陷检测时,对于 Cr 和 RS 类缺陷的识别存在漏检问题,仅成功检测到一个缺陷,并且缺陷的置信度也未明确标注。这一结果揭示了原始 YOLOv7 网络在钢材表

面缺陷检测方面的局限性,尤其是在处理特定类型缺陷时的鲁棒性不足。相较之下,改进后的 ECC-YOLO 网络在检测效果上有了显著提升。不仅成功地识别出了更多的 Cr、RS 类等缺陷,而且对每个检测到的缺陷区域,都准确标注了缺陷类别和置信度,从而对钢材表面缺陷的定位也变得更加精确。这归因于 ECC-YOLO 网络在模型结构和算法上的优化,使其能够更有效地处理钢材表面的复杂纹理和各类缺陷特征。此外,ECC-YOLO 网络显示出对各类钢材表面缺陷的良好检测效果,表明该网络具有较强的泛化能力和鲁棒性。这对于实际应用中提高钢材质量控制的准确性和效率具有重要意义。

由表 4 实验结果可知,在该罐道表面缺陷数据集上,ECC-YOLO 网络相较于基准 YOLOv7 网络 mAP 达到了 84.6%,提升了 2.67%,参数量由参数量由模型参数量由基线的 36.50 M 减少至 33.13 M,减少了 3.37 M,且各项指标都达到了最优结果。由此通过实验结果证明了,ECC-YOLO 网络具有良好的鲁棒性。

为了进一步的验证 ECC-YOLO 网络算法的检测精度和可靠性,本文对目前主流的检测算法 Faster R-CNN、RetinaNet、YOLOv4、YOLOv5 在 NEU-DET 数据集进行对比实验。具体结果表 5 所示。

从表 5 可以看出与其他模型相比,改进后的 ECC-YOLO 网路模型,能有效的提高对各类缺陷的检测精度,除了 Cr、Ps、Pa 类缺陷,其他都达到了最高检测精度。其中与 Faster R-CNN 相比,在 mAP、参数量都得到了极大提升,mAP 精度提高了 19.7%,参数量降低了 69.60%。而与 RetinaNet、YOLOv4、YOLOv5、YOLOv7-tiny、Zhao's method^[12]、Kou's method^[15]相比,本文的 mAP 精度分别提高了 10.7 mAP、9.1 mAP、6.9 mAP、11.0 mAP、2.0 mAP、5.0 mAP。在模型参数量上,达到了 33.13 M。从以上数据可以看出,ECC-YOLO 在降低模型复杂度的同时,能提升模型的对钢材表面细小缺陷的精度,这为工业生产领域的实际应用奠定了坚实的基础。




图9 6类缺陷检测效果对比

Fig.9 Comparison of 6 kinds of defect detection result

综合以上讨论,ECC-YOLO 网络模型在钢材表面缺陷检测方面展现出了优异的性能,不仅解决了原始YOLOv7 网络存在的漏检问题,还通过准确标注缺陷类别和置信度提高了缺陷检测的精度和效率。

3 结论

文中针对钢材表面缺陷检测问题,提出了一种的ECC-YOLO 缺陷检测算法。该算法通过在主干特征提取网络中引入 ConvNext 模块,增强网络对目标特征提取能力,提升网络对细小缺陷的检测精度。引入设计轻量化 C2fB 模块,将模型的参数量从 36.5 M 有效降低到 31.1 M,减少计算冗余、内存访问,从而提高网络的推理速度。设计 MPCE 模块,通过跨通道式的信息交互,使网络充分利用特征信息,有利于小目标缺陷的检测。

在 NEU-DET 数据集上,ECC-YOLO 网络对钢材表面缺陷检测的 mAP 达到了 77.2%,精度提高了 10.1%,模型参数量减少了 9.3%,所提出的方法可以有效地应用于钢材缺陷检测领域。后续将继续提高网络对 Pa、Ps 类缺陷的检测精度,优化网络结构,方便网络直接用于实际部署中。

参考文献

- [1] LV X, DUAN F, JIANG J, et al. Deep metallic surface defect detection: The new benchmark and detection network[J]. Sensors, 2020, 20(6): 1562.
- [2] LI Z, ZHANG J, ZHUANG T, et al. Metal surface defect detection based on MATLAB[C]. 2018 IEEE 3rd

Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), IEEE, 2018: 2365-2371.

- [3] TANG S, GAO X, TIAN K, et al. Non-destructive evaluation of weld defect with coating using electromagnetic induction thermography [J]. Nondestructive Testing and Evaluation, 2023: 1-19.
- [4] ZHOU W, DU Y G, WANG S D, et al. Effects of welding defects on the damage evolution of Q245R steel using acoustic emission and infrared thermography[J]. Nondestructive Testing and Evaluation, 2023, 38(2): 189-210.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [6] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [8] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, arXiv:2004.10934.
- [9] SHI X, ZHOU S, TAI Y, et al. An improved faster R-CNN for steel surface defect detection[C]. 2022 IEEE

- 24th International Workshop on Multimedia Signal Processing (MMSP), IEEE, 2022: 1-5.
- [10] ZHENG J, ZHANG T. Wafer surface defect detection based on background subtraction and faster R-CNN[J]. Micromachines, 2023, 14(5): 905.
- [11] 向宽, 李松松, 栾明慧, 等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法[J]. 仪器仪表学报, 2021, 42(1): 191-198.
- XIANG K, LI S S, LUAN M H, et al. Aluminum surface defect detection method based on improved Faster RCNN [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 191-198.
- [12] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021: 1-13.
- [13] HOU S, DONG B, WANG H, et al. Inspection of surface defects on stay cables using a robot and transfer learning [J]. Automation in Construction, 2020, 119: 103382.
- [14] WEI R, SONG Y, ZHANG Y. Enhanced faster region convolutional neural networks for steel surface defect detection [J]. ISIJ International, 2020, 60(3): 539-545.
- [15] KOU X, LIU S, CHENG K, et al. Development of a YOLO-V3-based model for detecting defects on steel strip surface[J]. Measurement, 2021, 182: 109454.
- [16] LI M, WANG H, WAN Z. Surface defect detection of steel strips based on improved YOLOv4[J]. Computers and Electrical Engineering, 2022, 102: 108208.
- [17] 马燕婷, 赵红东, 阎超, 等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8): 150-157.
- MA Y T, ZHAO H D, YAN CH, et al. Surface defect detection method of strip steel based on improved YOLOv5 network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 150-157.
- [18] XIA K, LV Z, ZHOU C, et al. Mixed receptive fields augmented YOLO with multi-path spatial pyramid pooling for steel surface defect detection[J]. Sensors, 2023, 23(11): 5114.
- [19] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11976-11986.
- [20] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.
- [21] CHEN J, KAO S, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021-12031.
- [22] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(4): 1493-1504.
- [23] 赵佰亭, 吴俊东, 贾晓芬. 融合特征增强的轻量化罐道缺陷检测算法[J]. 电子测量与仪器学报, 2023, 37(6): 159-168.
- ZHAO B T, WU J D, JIA X F. Fusion feature enhanced lightweight tank channel defect detection algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 159-168.

作者简介



赵佰亭, 2002 年于青岛科技大学获得学士学位, 2005 年于青岛科技大学获得硕士学位, 2010 年于哈尔滨工业大学获得博士学位, 现为安徽理工大学教授, 主要研究方向为深度学习、图像处理。
E-mail: btzhao@ aust. edu. cn

Zhao Baiting received his B. Sc. degree from Qingdao University of Science and Technology in 2002, M. Sc. degree from Qingdao University of Science and Technology in 2005 and Ph. D. degree from Harbin Institute of Technology in 2010. Now he is a professor at Anhui University of Science and Technology. His main research interests include deep learning and image processing.



张晨(通信作者), 现为安徽理工大学硕士研究生, 主要研究方向为图像处理、缺陷检测。
E-mail: 912548165@qq.com

Zhang Chen (Corresponding author) is now a M. Sc. candidate at Anhui University of Science and Technology. His main research interests include image processing and defect detection.