

DOI:10.19651/j.cnki.emt.2211012

基于改进 YOLOX 的钢材表面缺陷检测算法^{*}

熊 聪¹ 于安宁¹ 高兴华¹ 原森浩¹ 曾孝平²

(1. 重庆科技学院智能技术与工程学院 重庆 401331; 2. 重庆大学微电子与通信工程学院 重庆 400044)

摘要: 针对工业生产中钢材表面背景复杂导致缺陷检测精度低的问题,本文提出一种基于改进 YOLOX 的钢材表面缺陷检测算法。首先,引入了 Swin Transformer 模块来捕获缺陷钢材表面区域全局上下文信息并提取更多差异化特征;其次,采用加权双向特征金字塔网络(BiFPN),能够方便、快速的进行跨尺度特征融合;最后,对原始目标定位损失函数进行改进,建立了一种融合边界框中心位置的 CIoU 损失函数从而实现目标框高精度定位。实验表明,算法在 NEU-DET 数据集上的 mAP 为 80.7%,检测精度相较于原始 YOLOX-S 网络提高了 6.2%,同时也明显高于一些其他主流算法,具有较高的准确率和实用性。

关键词: 钢材表面;缺陷检测;YOLOX;BiFPN;Swin Transformer

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 510.4050

Steel surface defect detection algorithm based on improved YOLOX

Xiong Cong¹ Yu Anning¹ Gao Xinghua¹ Yuan Senhao¹ Zeng Xiaoping²

(1. School of Intelligent Technology and Engineering, Chongqing University of Science and Technology, Chongqing 401331, China;

2. School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Aiming at the problem of low defect detection accuracy caused by complex steel surface background in industrial production, this paper proposes a steel surface defect detection algorithm based on improved YOLOX. First, the Swin Transformer module is introduced to capture the global context information of the surface area of the defective steel and extract more differentiated features. Secondly, the weighted bidirectional feature pyramid network (BiFPN) is used to facilitate cross-scale feature fusion. Finally, we improved the original target localization loss function and established a CIoU loss function that fuses the center position of the bounding box to achieve high-precision localization of the target frame. Experiments showed that the mAP of our algorithm on the NEU-DET dataset is 80.7%, which is 6.2% higher than the original YOLOX-S network, and it is also significantly higher than some other mainstream algorithms, with high accuracy and practicality.

Keywords: steel surface;defect detection;BiFPN;YOLOX;Swin Transformer

0 引言

近年来随着人工智能技术的不断发展,其越来越广泛的被运用于工业生产中^[1]。例如在钢材制造过程中,材料表面的缺陷会降低材料的强度,从而缩短工件的使用寿命。传统的图像处理技术在对表面缺陷进行分类前需要手动提取特征,常见的特征提取方式包括 LBP、HOG 等。这些方法极大的提高了钢材表面缺陷检测效率,然而在光照不足等复杂背景环境下,传统处理方法的鲁棒性较差。深度学习方法在缺陷检测方面具有许多优势,但基于计算机视觉的钢材表面缺陷检测仍有问题亟待解决,例如采集的缺陷图像质量对检测准确率有较大影响,同时检测算法精度也有待提高。

在当前的目标检测领域,特征提取器主要使用的是卷积神经网络(convolutional neural network, CNN)和 Transformer^[2],其主要完成特征提取任务,输出包含丰富特征信息的特征图,为后续目标检测中的分类和回归任务奠定基础。

基于 CNN 的目标检测可以分为单阶段检测器和双阶段检测器。单阶段检测器的检测速度通常较快,具有代表性的算法有 YOLO 系列^[3-5] 和 SSD^[6]。双阶段检测算法会经过两次筛选后生成最终的候选框,具有代表性的算法有 R-CNN 系列^[7-9]。目前单阶段检测器的推理速度远胜于双阶段检测器,并且检测精度也可以与双阶段检测器相媲美。

收稿日期:2022-08-09

*基金项目:重庆市教委科学技术研究项目(KJQN202001523)、重庆科技学院青年科学基金(CKRC2019042)、重庆科技学院研究生科创项目(YKJCX2120816)资助

由于图片中相邻元素具有较高的关联性,因此 CNN 利用滑动窗口可以很好的整合相邻元素的特征信息,但是 CNN 仅关注于二维局部数据之间的相互关联导致很难利用全局上下文信息。而 Transformer 中的自注意力机制可以很好的关注全局上下文信息并提取出更强有力的特征。

Transformer 目前已经取得了令人震撼的效果但是对于分辨率高的图像自注意力机制会带来庞大的计算量,这对训练设备提出了较高的要求。针对这一问题,Liu 等^[10]提出了 Swin Transformer,通过将自注意力计算限制在窗口内大幅降低了模型复杂度。

目前在工业生产中缺陷检测主要有两种方法:传统方法:Ai 等^[11]利用曲波变换对图像进行分解,在分解后图像中提取傅里叶频谱特征,检测连铸板表面的纵向裂缝缺陷。这种方法检测效率较低并且检测精度不足。Liu 等^[12]通过对比尺度不变特征变换、加速鲁棒特征和局部二进制模式特征提取方法与 BP 神经网络、支持向量机和极限学习机分类方法的各种结合,来证明使用局部二进制模式进行特征提取和极限学习机进行缺陷分类的混合方法效果最优。这种方法步骤繁琐,需要大量的人工先验知识,费时费力。深度学习检测方法:刘涛等^[13]提出了基于 YOLOv4 轻量化的印刷电路板缺陷检测模型。该算法与传统的印刷电路板检测算法相比提高了检测精度和速度。张明路等^[14]采用了深度可分离卷积替换了部分传统卷积,并加入了注意力机制,实现了对电子元器件的实时监测。单明陶等^[15]采用了改进的 Faster R-CNN 算法对刹车零件的缺陷进行检测,取得了较好的检测精度。上述算法针对不同场景进行了优化,但在钢材生产环境中需要满足实时性要求,同时钢

材表面的缺陷存在变化范围大且背景干扰较多,在提高检测效率的同时需要尽量提高模型检测精度。彭伟康等^[16]提出一种基于改进 Faster R-CNN 的水准泡缺陷检测方法,有效提高了模型检测准确度。

针对以上不足,本文提出了一种改进 YOLOX 的钢材表面缺陷检测算法。首先,在单阶段检测器 YOLOX 中引入了 Swin Transformer 结构块,兼顾了 CNN 的局部信息特征提取能力和 Transformer 的全局上下文信息捕获能力,有效的扩大了感受野来检测多尺度的目标。其次,提出了一种高效的加权双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN),用于实现有效的跨尺度特征融合,提高模型对不同尺度特征的提取能力。最后,通过引入 CIoU 位置损失函数,在计算坐标误差时结合重叠面积、中心点距离和纵横比 3 种几何因素,减少了漏检或误检的发生,有效的提高了检测精度。

1 本文模型

上述目标检测算法中,两阶段算法由于从候选区域选取再到对候选区域分类,往往需要花费较多的时间,而在工业生产中往往需要实时性更强的算法,因此本文将采用一阶段算法识别钢材表面缺陷,相比于两阶段算法而言能够在保证预测精度不低的同时,大大减少缺陷检测的时间,提高缺陷检测的效率。得益于 YOLO 算法的提出,其在目标检测任务上获得较高的精度的同时,处理速度也可以满足实时应用的要求,因此,本文针对以 YOLOX^[17]算法进行改进,以解决工业生产中钢材表面缺陷检测精度低的问题。改进后的整体网络结构如图 1 所示。

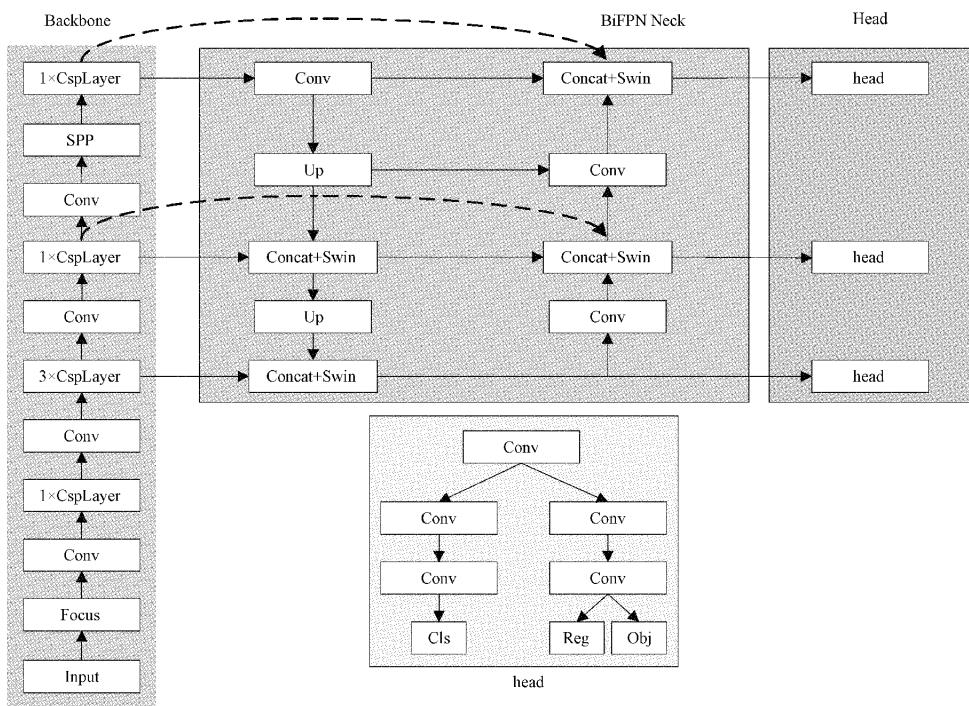


图 1 钢材表面缺陷检测算法结构

1.1 Swin Transformer

针对目标尺度不统一、场景复杂的钢材表面缺陷图像,为了提高缺陷类别辨识度,需要更好的抽象出语义信息。相同类型缺陷附近往往具有类似的特征表达,然而,CNN 中卷积操作的局部性限制了其获取全局上下文信息的能力,它是基于临近像素具有较大相关性的假设而形成的一种归纳偏置,无法更好挖掘特征及周围像素点之间的关键性。相比之下,Transformer 的学习过程基于全局信息的交互,因此在学习方式和特征性质等方面与 CNN 存在一定差异,在 CNN 中加入 Transformer 有助于提升模型对特征的学习和表达能力^[18]。

与 Vision Transformer 不同的是,Swin Transformer 采用基于窗口的自注意力机制,大幅度减少了计算量,结构如图 2 所示。由于 Transformer 缺少一些 CNN 固有的归纳偏置,例如平移不变性和局部性,因此为提升缺陷检测效果,改善特征提取过程中细节信息丢失的问题,我们将 Swin Transformer 引入到 neck 中。这是因为 Transformer 的泛化性能较差,若作为主干特征提取网络在中小规模的数据集上训练时,模型产生的结果并不理想。此外,将 CSPbottleneck 中的卷积模块替换为 Swin Transformer 模块后,模型整体计算量变大,特征也更复杂。

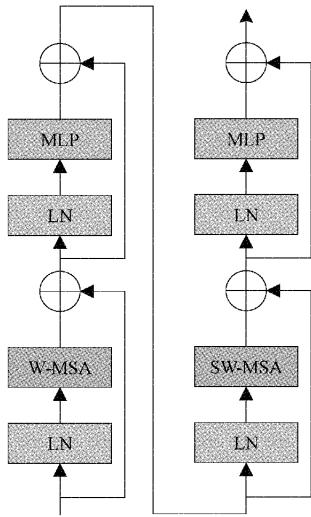


图 2 Swin Transformer 编码器结构

标准的 Vision Transformer 架构是对整张图片采取全局自注意力机制,这会导致模型复杂度随图像分辨率呈爆炸式增长。Swin Transformer 采用注意力机制限制在一个窗口内,一方面借鉴于 CNN 的滑动窗口可以更好的关注相邻元素的特征信息,另一方面能减少计算量。通过如下公式可以反映关于 MSA 模块和 W-MSA 的计算复杂度:

$$\Omega(\text{MSA}) = 4hwC^2 + 2(hw)^2C \quad (1)$$

$$\Omega(\text{W-MSA}) = 4hwC^2 + 2M^2hwC \quad (2)$$

其中, h, w, C, M 分别代表特征图的高度、宽度、深度

和窗口大小。若特征图的 $h, w = 112, C = 128, M = 7$, 那么 W-MSA 的复杂度仅为 MSA 的 $\frac{1}{256}$ 。

如图 2 所示的第 1 个结构块中,W-MSA 只会对窗口内的图像块进行自注意力计算,而窗口间是不会进行信息交互的。因此,在第 2 个结构块中采用了 Shifted Windows Multi-Head Self-Attention(SW-MSA)模块,该方法能让信息在相邻的窗口中进行传递。

1.2 BiFPN

模型的 neck 部分作为加强特征提取网络,可以将主干提取多尺度特征进行融合。高层网络的感受野较大具有较强的语义表征能力,但是经过多次下采样后图像的分辨率较低致使钢材表面缺陷的细节难以保留;而低层网络的感受野小、语义表征能力较弱,但是特征图分辨率较高,钢材表面缺陷的边缘等细节信息保留较完整。因此对不同深度的网络特征层进行融合可以有效的提高模型的检测能力。YOLOX 的 neck 部分延续了 YOLOv4 中的 PANet 结构,该结构通过融合自底向上和自顶向下的特征层有效增强了骨干网络的特征提取能力。在本文中使用了更高效的 BiFPN^[19-20]结构,如图 3(b)所示。

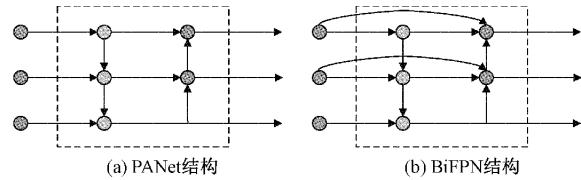


图 3 加强特征提取网络

由于 NEU-DET 数据集中少数缺陷类别尺寸较小,因此提取出的浅层特征更有利识别出这些缺陷。当涉及到辨识度低的缺陷时,更深的特征层可以更好的抽象出缺陷的语义信息。通过多尺度特征融合的方法可以增加模型对缺陷特征的判别能力。但不同尺度特征层对融合的输出特征的贡献并不完全相同,BiFPN 通过引入可学习的权重来确定各特征层的重要性,在本文算法中使用了快速归一化融合方式,其工作原理如式(3)所示。

$$O = \sum_i \frac{w_i}{\epsilon + \sum_j w_j} I_i \quad (3)$$

其中, w_i 表示可学习权重参数并且 $w_i \geq 0$, 学习率 ϵ 为一个小值,以避免数值不稳定,每个归一化权重的值在 $0 \sim 1$ 。

BiFPN 有效的保留了 PANet 双向跨尺度特征融合的优点,又可以自适应确定不同尺度特征层的重要程度。

1.3 CIoU

在目标检测中,通常使用交并比(intersection over union,IoU)来反映预测框与真实框的重合程度,如式(4)所示。但是 IoU 不能很好的反映两个边界框之间的距离,此外当两个边界框不重合时会造成梯度消失的问题。

$$IoU = \frac{|B \cap B^{gt}|}{|B \cup B^{gt}|} \quad (4)$$

式中： B 和 B^{gt} 代表预测框和真实框。在原始 YOLOX 模型中使用了 GIoU 作为边界框损失函数，如式(5)。GIoU 引入了预测框和真实框的最小闭包矩形，有效缓解了预测框和真实框不重叠导致梯度消失的问题。GIoU Loss 的计算方法如式(6)：

$$GIoU = IoU - \frac{|C - (B \cup B^{gt})|}{C} \quad (5)$$

$$Loss_{GIoU} = 1 - IoU + \frac{|C - (B \cup B^{gt})|}{C} \quad (6)$$

其中， C 表示覆盖预测框和真实框的最小外接边界框。但当预测框与真实框存在包含关系时，GIoU 会退化为 IoU。因此，考虑到 GIoU 的缺点，本文采用了一种具有更快收敛速度和更好的边界框回归性能的损失函数 ClIoU^[21]，通过直接回归两个框中心点的欧式距离，从而加速收敛。该损失函数引入了边界框回归中通常被忽略的几何信息，例如重叠区域、纵横比和中心点距离，ClIoU 对边界框添加了纵横比的一致性。ClIoU 的计算公式如下：

$$L_{ClIoU} = 1 - IoU + \frac{\rho^2(B, B^{gt})}{c^2} + \alpha v \quad (7)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (8)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (9)$$

在式(7)中， ρ 代表的是预测框和真实框中心点间的欧式距离， c 代表的是能够同时包含预测框和真实框的最小闭包矩形的对角线距离。 α 是一个惩罚系数， v 为权重系数，用来度量宽高比。在进行边界框回归时，在 ClIoU 的作用下预测框会根据钢材表面缺陷真实框的尺寸以及位置不断调整，以达到最好的收敛边界。

2 实验结果与分析

2.1 数据集

实验数据集采用的是东北大学发布的钢材表面缺陷数据集：NEU-DET^[22]，其中包括了 6 种典型的缺陷：crazing、inclusion、patches、pitted surface、rolled-in scales 和 scratches，每个类别分别包含 300 张灰度图像。各类别缺陷图像样例如图 4 所示。

2.2 评价指标

本文采用以下指标定量评价模型的性能：精度(Precision)、召回率(Recall)、平均均值精度(mean average precision, mAP) 以及每秒检测图像帧数(frames per second, FPS)。精度和召回率计算如下：

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

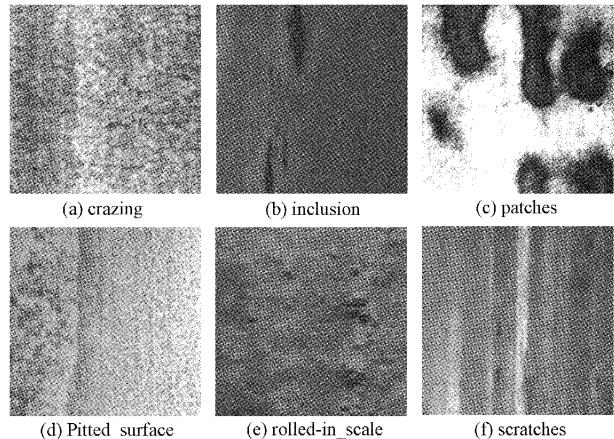


图 4 数据集样例

AP 表示单类别不同召回率下的平均精度，可以通过计算 P-R 曲线积分得到，如式(12)。mAP 是所有类的 AP 取平均，如式(13)。

$$AP = \int_0^1 p(r) dr \quad (12)$$

$$mAP = \frac{1}{N} \sum AP_i \quad (13)$$

2.3 实验细节

本文中的实验配置如表 1 所示。

表 1 实验平台配置

配置	参数
操作系统	Windows 10
GPU	Geforce RTX 6G
CPU	Intel(R) Core(TM) i5-10400
深度学习框架	Pytorch 1.7.0
环境	Python 3.7

在本文中，所有实验均借鉴迁移学习的思想采用基于 COCO 数据集的预训练权重对网络 backbone 部分进行初始化并冻结训练 50 轮，解冻后训练 150 轮。在冻结阶段，backbone 部分的权值不会发生改变，占用的显存相对较少，仅对网络进行微调。解冻后，模型的所有参数都会参与训练。同时选择 SGD 作为优化器，默认权重衰减为 0.0005，动量为 0.937，初始学习率设置为 0.01，最小学习率为 0.01×0.1 ，使用余弦退火算法来更新学习率。

2.4 不同模型结果对比

为了验证模型的有效性，将本文模型和其他主流检测模型通过上述的评价指标进行对比，实验结果如表 2 所示。

如表 2 中的数据所示，作为新一代的 YOLO 目标检测器，YOLOX 的检测速度最快，同时 mAP 也高于其他目标

表 2 在 NEU-DET 数据集上不同算法的结果

模型	AP/%						mAP/%	FPS
	crazing	inclusion	patches	pitted-surface	rolled-in_scale	scratches		
SSD-ResNet	33.0	84.4	92.3	90.2	64.0	76.9	73.5	46.5
CenterNet	27.5	81.6	89.4	90.6	53.3	95.2	72.9	27.2
YOLOv5-S	23.9	80.4	92.9	88.1	66.4	83.7	72.6	48.5
YOLOX-S	35.1	82.1	92.1	91.4	53.6	92.9	74.5	52.4
ours	32.2	80.5	94.7	91.5	87.0	98.1	80.7	22.9

检测算法。而本文提出的基于 YOLOX 的改进算法总体检测精度优于 YOLOX 本身,但是在小目标检测效果稍低于原始算法,这是由于 Transformer 对大目标物体的全局建模能力更强^[23]。SSD-ResNet 在某些类别上的检测效果良好,但是整体 mAP 远远低于本文提出的方法。原因是本文的方法更好地结合了不同尺度和不同层次的特征。对于尺寸较小的缺陷本身在提取特征时就存在一定的难度,同时复杂的背景也对特征提取产生了一定的负面影响。

尽管引进了 Transformer 导致推理速度大幅度下降,但是我们的方法极大的提升了检测精度。

本文模型中各缺陷类别的 P-R 曲线如图 5 所示,横坐标表示精确率也称为误检率,纵坐标表示召回率也称为漏检率,P-R 曲线下方的面积即为该类别的 AP 值。P-R 曲线可以在一定程度上反映模型的泛化性,图 5 为各缺陷类别的 P-R 曲线,可以看出除 crazing 缺陷外,其他几个缺陷类别的 P-R 曲线都比较高。

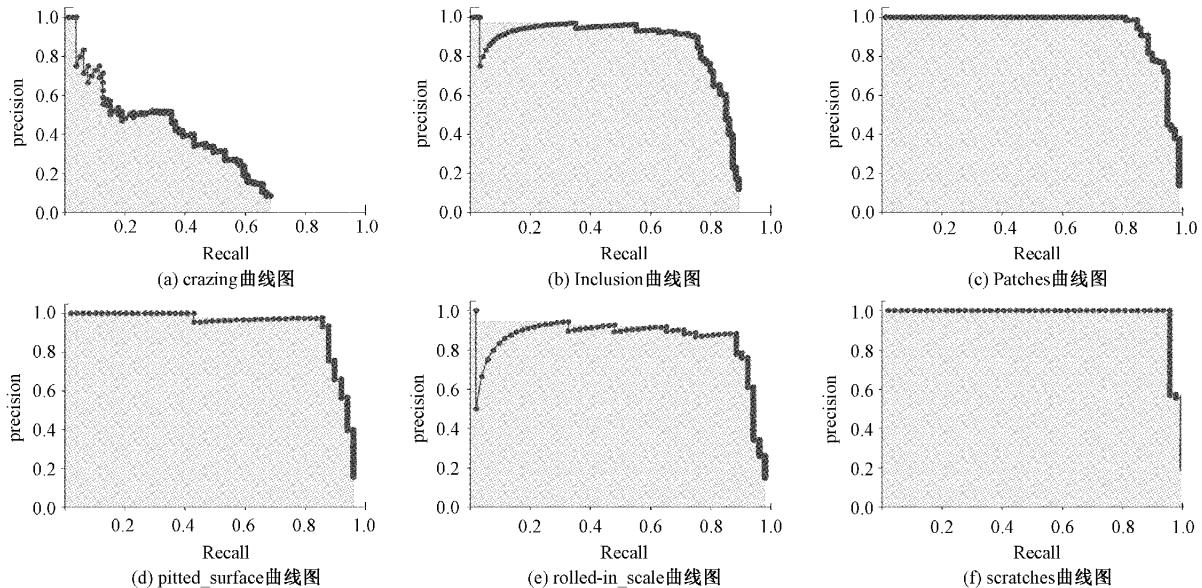


图 5 各缺陷类别的 P-R 曲线

2.5 消融实验

为进一步验证各优化部分对钢材表面缺陷算法的影响,在 NEU-DET 数据集上进行了消融实验,结果如表 3 所示。可以看出,在网络中加入 Swin Transformer 模块后,rolled-in_scale 该类缺陷的精度取得了较大的提升,进一步加入 BiFPN 后 crazing、inclusion、patches、rolled-in_scale 这四类缺陷的精度均有所提升,最后将定位损失函数改进为 CIoU 后所有缺陷类型精度均有所提高。缺陷 rolled-in_scale 在图像上比较零散,但是分布较广,而 Transformer 具有较强的全局信息建模能力,因此可以更好的在更大的邻域中收集与缺陷特征相关的信息,为模型增加捕获不同位置信息的能力。BiFPN 模块可以更好的

增强不同特征层间的信息交融合能力,使模型能够更适应变化较大的缺陷特征。CIoU 定位损失函数进一步考虑了真实框与预测框的中心点距离和宽高比,使各缺陷类别检测框的回归更加精确。但是同样可以看出在 crazing 和 inclusion 这两类缺陷上,本文提出的算法检测精度反而有所下降,这是由于这两类缺陷特征尺寸过小,导致 Transformer 在进行全局建模时对于小尺寸目标的关注有所不足。本文在 YOLOX-S 的基础上进行改进,虽然推理速度有所下降,但仍然能够满足实时检测的要求,而检测精度从 74.5% 提升到 80.7%,取得了较大的提升。通过对检测结果的分析,本文的改进策略有效的提升了模型的检测精度,因此有较高的实用性。

表 3 NEU-DET 数据集上的消融实验

	AP/%						mAP/%	FPS
	crazing	inclusion	patches	pitted-surface	rolled-in_scale	scratches		
baseline	35.1	82.1	92.1	91.4	53.6	92.9	74.5	52.4
+ Swin	30.2	78.5	91.1	92.1	82.5	94.6	78.2	25.3
+ BiFPN	31.0	80.0	93.6	91.0	86.8	92.9	79.2	23.9
+ CIoU	32.2	80.5	94.7	91.5	87.0	98.1	80.7	22.9

3 结 论

本文基于 YOLOX 和 Swin Transformer 设计了一种全新的钢材表面缺陷检测算法。针对缺陷难以辨别、图像背景复杂的问题,提出了在加强特征提取网络中加入 Swin Transformer 检测模块。针对缺陷尺度变化大的问题,提出了 BiFPN 结构,通过自适应加权融合不同尺度特征层,增强了模型对不同尺度缺陷的检测能力。最后,通过引入 CIoU 位置损失函数,考虑了预测边界框和真实边界框中心、宽高坐标之间的内部联系,既加快了模型的收敛速度又减少了模型的误检和漏检情况。通过在 NEU-DET 数据集测试,我们提出的模型 mAP 达到 80.7%,较原始 YOLOX-S 模型提升了 6.2%,说明该算法达到了很好的精度。

参考文献

- [1] KIM S, KIM W, NOH Y K, et al. Transfer learning for automated optical inspection[C]. 2017 International Joint Conference on Neural Networks (IJCNN), IEEE, 2017: 2517-2524.
- [2] VASWANI A, SHAZEE N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30, DOI: 10.48550/arXiv.1706.03762.
- [3] 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.
- [4] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [5] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. European conference on computer vision. Springer, Cham, 2016: 21-37.
- [7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [8] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Processing Systems, 2015, 28, DOI: 10.1109/TPAMI.2016.2577031.
- [10] 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.
- [11] AI Y, XU K. Surface detection of continuous casting slabs based on curvelet transform and kernel locality preserving projections[J]. Journal of Iron and Steel Research International, 2013, 20(5): 80-86.
- [12] LIU Y, XU K, WANG D. Online surface defect identification of cold rolled strips based on local binary pattern and extreme learning machine[J]. Metals, 2018, 8(3): 197.
- [13] 刘涛,张涛. 基于 GhostNet-YOLOv4 算法的印刷电路板缺陷检测[J]. 电子测量技术,2022,45(16):61-70.
- [14] 张明路,郭策,吕晓玲,等. 改进的轻量化 YOLOv4 用于电子元器件检测[J]. 电子测量与仪器学报,2021, 35(10):17-23.
- [15] 单明陶,高玮玮,杨亦乐,等. 基于改进 Faster R-CNN 的刹车零件缺陷检测算法[J]. 国外电子测量技术, 2022, 41(4):22-28.
- [16] 彭伟康,陈爱军,吴东明,等. 基于改进 Faster R-CNN 的水准泡缺陷检测方法[J]. 中国测试, 2021, 47(7): 6-12.
- [17] GE Z, LIU S, WANG F, et al. Yolox: Exceeding yolo series in 2021 [J]. ArXiv Preprint, 2021, ArXiv:2107.08430.
- [18] 田永林,王雨桐,王建功,等. 视觉 Transformer 研究的关键问题: 现状及展望[J]. 自动化学报, 2022,

- 48(4):957-979.
- [19] CHEN P Y, CHANG M C, HSIEH J W, et al. Parallel residual bi-fusion feature pyramid network for accurate single-shot object detection [J]. IEEE Transactions on Image Processing, 2021, 30: 9099-9111.
- [20] ZHAO Q, SHENG T, WANG Y, et al. M2det: A single-shot object detector based on multi-level feature pyramid network [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 9259-9266.
- [21] 王宸, 唐禹, 张秀峰, 等. 基于改进 EfficientNet 的锻件磁粉探伤智能检测方法研究[J]. 仪器仪表学报, 2021, 42(9):89-96.
- [22] SONG K, YAN Y. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects [J]. Applied Surface Science, 2013, 285: 858-864.
- [23] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]. European Conference on Computer Vision, Springer, Cham, 2020: 213-229.

作者简介

熊聪,硕士研究生,主要研究方向为计算机视觉。
E-mail: xiongcong@cqust.edu.cn

于安宁(通信作者),讲师,主要研究方向为信号处理、图像处理。
E-mail: anning865@163.com

曾孝平,教授,主要研究方向为信号处理。
E-mail: zxp@cqu.edu.cn