

一种基于 STI-YOLO 的锌花背景干扰下带钢表面缺陷检测方法

魏明军^{a,b}, 陈钊^a, 纪占林^{a,b}, 周太宇^a, 闫旭文^a, 刘铭^a

(华北理工大学 a.人工智能学院;b.河北省工业智能感知重点实验室,河北 唐山 063210)

摘要:针对有花镀层钢板表面缺陷检测过程中由于锌花底纹干扰导致缺陷识别率低的问题,提出一种以目标检测算法 YOLOv5s 为基础并通过引入通道注意力机制和金字塔卷积网络的 Spangles Texture Interference-YOLO(STI-YOLO)算法模型.根据缺陷数据集重新聚类,优化先验框;在特征融合网络 PANet 之前引入通道注意力机制 SENet,抑制锌花背景的干扰;在预测网络之前添加金字塔卷积网络,取得更加丰富的上下文特征.实验结果表明,STI-YOLO 模型提升了带钢表面缺陷的检测精度,平均精度均值 mAP 达到了 95.79%,较 YOLOv3、YOLOv4 和 YOLOv5s 算法分别提高了 13.13 个百分点、14.59 个百分点和 2.07 个百分点.检测速度为 54.14 frame/s,满足实时性要求,可见 STI-YOLO 模型具有较好的检测性能.

关键词:缺陷检测;特征融合;注意力机制;多尺度特征;锌花背景干扰

中图分类号:TP391.41

文献标志码:A

钢材表面缺陷检测经历了人工检测、传统光电检测和机器视觉检测 3 个主要发展阶段^[1-2].从 20 世纪 60 年代以来,机器视觉技术的出现使得工业上的缺陷检测有了质的提升.与国外相比,国内对于缺陷识别的研究起步较晚.1991 年华中理工大学的罗志勇^[3]将线列 CCD 用于检测钢板的孔洞缺陷.1996 年,又再次研究出由许多面阵 CCD 和 DSP、PC 机相结合组成的一套新的图像检测系统^[4],实现了对冷轧带钢表面缺陷进行检测.2011 年,杨永敏等^[5]研究了基于机器视觉的冷轧带钢表面缺陷检测系统.2022 年,布申申等^[6]提出一种用于带钢表面缺陷检测的神经网络模型 Ds-DenseNet,该模型主要解决现有带钢表面缺陷检测方法准确率低、特征泛化性不强、参数多、识别速度慢等问题.但其缺点是只针对以前无花的普通带钢进行检测,对于具有锌花纹理的新型镀层钢板无专门的训练检测.在检测过程中锌花会对产品表面缺陷的检测造成干扰,从而使检测的精度受一定影响.目前,国内未见公开发表的针对锌花背景干扰下带钢表面缺陷检测的研究成果,本文针对某钢厂镀锌生产线采集的真实缺陷图谱展开研究,通过 STI-YOLO 模型抑制锌花背景的干扰,同时增大预测特征图的感受野,从而提高检测精度,改善漏检.

YOLOv5 算法与之前的 YOLO 系列算法^[7-9]相比较,仍由主干特征提取网络、特征融合网络和回归预测三部分组成,主干特征提取网络使用的是 CSP-Darknet53^[10]网络,不同的是加入了 Focus 网络结构,使输入的通道数快速扩张 4 倍,并且将空间金字塔池化结构(Spatial Pyramid Pooling, SPP)加入到主干特征提取网络中,增大感受野的尺寸.在特征融合网络结构部分,依然采用了路径聚合网络(Path Aggregation Network, PANet),达到了提取上下文特征的目的.PANet 网络结构通过自下而上的路径缩短了底层和最顶层之间的信息路径,避免信息丢失问题,同时融合后的特征图既包含底层位置信息也包含较强的语义特征.YOLOv5 总共包含 s、m、l、x 4 个算法模型,YOLOv5s 网络最小,速度最快,平均精度也最低.其他的 3 种网络,

收稿日期:2022-06-29;修回日期:2022-11-17.

基金项目:科技部重点研发项目(2017YFE0135700).

作者简介:魏明军(1969-),男,河北迁安人,华北理工大学教授,研究方向为信息安全技术、图像处理,E-mail:109849249@qq.com.

通信作者:陈钊,E-mail:870656030@qq.com.

在 s 基础上,不断加深加宽网络,平均精度也不断提升,但速度的消耗也在不断增加.本文以 YOLOv5s 算法为基础,在特征图输入到特征融合网络 PANet 之前先引入通道注意力机制(Squeeze-and-Excitation Network, SENet)^[11],抑制锌花背景的干扰,提高有效特征的利用率,滤除冗余的锌花背景信息.再将进行特征融合之后的 3 个不同尺度的特征图输入到金字塔卷积(Pyramidal Convolution, PyConv)^[12]网络中,提取更加丰富的缺陷信息,使得用于预测的特征图具有更好的鲁棒性.

1 STI-YOLO 算法

1.1 STI-YOLO 模型网络结构

STI-YOLO 模型的输入是分辨率为 640×640 的图片,其网络结构如图 1 所示.

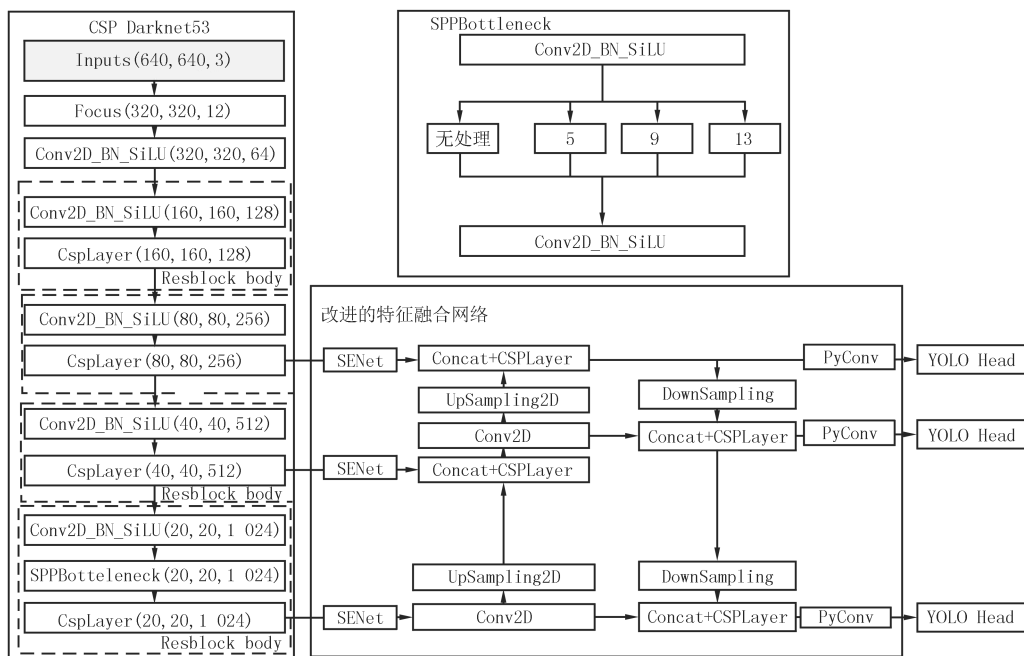


图1 STI-YOLO网络结构

Fig.1 STI-YOLO network structure

算法执行的具体步骤如下:

- 1) 输入尺寸大小为 640×640 、通道数为 3 的图片.经过 Focus 网络结构,将输入通道扩充了 4 倍;
- 2) 经过 DarknetConv2D_BN_SiLU 模块通道扩充为 64;
- 3) 经过 4 个 Resblock body 模块,提取到低层、中层和高层特征图,其尺度大小分别为 80×80 、 40×40 和 20×20 ;
- 4) 将主干特征网络提取到大小 20×20 、 40×40 和 80×80 的特征图分别输入到 SENet 网络中抑制锌花背景的干扰;
- 5) 利用 PANet 进行特征融合,获得 3 个不同尺度的特征图.然后将上采样和下采样产生的新特征图利用横向连接进行 Concat 连接;
- 6) 对生成的新特征图输入到金字塔卷积网络中,进行多尺度特征处理,产生更丰富的特征信息,增加预测特征图的鲁棒性;
- 7) 生成的特征图输入到 YOLO Head 中进行预测;
- 8) 生成预测框.

1.2 改进的特征融合网络

在深度卷积神经网络中,高层特征图包含更多有利于目标分类的强语义信息,但分辨率低,位置信息粗糙.低层特征图包含更多有利于目标定位的位置信息和轮廓细节,但其分辨率高,语义信息弱.YOLOv5s 算

法使用 PANet 进行加强特征融合,在主干网络提取的特征图里包含了部分锌花背景干扰造成的冗余特征.为了解决这一问题,抑制锌花背景对缺陷检测的干扰,引入 SENet.如图 2 所示,具体操作是将主干特征网络提取的特征图输入到 SENet 中突出重要特征,减少锌花背景的干扰.从而有利于 PANet 得到更有效的特征,提高缺陷识别的准确率.并在预测之前加入金字塔卷积,从而使得增加感受野的同时获取更丰富的上下文特征.




图2 改进的特征融合网络

Fig.2 Improved feature fusion network

1.2.1 SENet 模块

SENet 通过对通道关系进行建模从而提升网络性能,主要包括 Squeeze(压缩)和 Excitation(激发)两个关键操作.模型通过学习自动获取每个通道的重要程度,然后根据每个通道的重要程度提升有用特征的权重并抑制对当前任务有干扰的冗余特征.

如图 3 所示:输入通道数为 c_1 的特征 x ,通过一系列卷积操作(F_{tr})将特征通道数变为 c_2 .然后再进行压缩(F_{sq})操作和激发(F_{ex})操作.




图3 SENet模块

Fig.3 Squeeze-and-Excitation block

SENet 通过网络学习特征权重,获取到每个特征图的重要程度,然后按照重要程度对每个特征通道赋予一个权重值,对任务重要的特征图赋予较大的权重,对不重要的特征图赋予较小的权重,从而使模型达到更好的训练效果.SENet 的结构如图 4 所示.图 4 中表示输入一个大小为 $H \times W \times C$ 的特征图,共 C 个通道数.然后进行一次空间的全局平均池化,每个通道得到一个标量,输出为 $1 \times 1 \times C$,然后再送入两层的全连接神经网络,同时保持特征图大小不变,然后再通过一个 Sigmoid 函数得到 C 个 $0 \sim 1$ 之间格式为 $1 \times 1 \times C$ 的权重,作为 C 个通道各自的权重,然后将对应通道的每个元素与权重分别相乘.其中 H 代表特征图的高, W 代表特征图的宽, r 表示降维系数.

1.2.2 PyConv 模块

PyConv 中包含不同大小和深度的卷积核,以此捕捉不同尺度的细节信息.原 PANet 网络中的下采样操作会造成输入特征图的信息损失,影响模型性能.而使用 PyConv 模块可以在不增加额

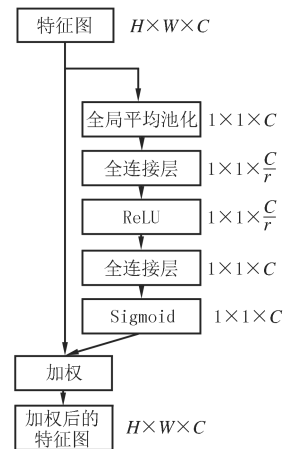


图4 通道注意力网络结构

Fig.4 Squeeze-and-Excitation network structure

外计算量的同时扩大感受野,通过采用不同尺寸的卷积核捕获多尺度的细节信息.

如图 5 所示,金字塔卷积网络包含一个具有 n 个不同大小卷积核的金字塔网络结构.在不增加计算成本或模型复杂性的情况下,以不同的卷积核大小处理输入.每个卷积核都包含不同的空间大小,从金字塔的底部到顶部卷积核大小逐渐增加,随着卷积核大小从 1 到 n 逐渐增加,卷积核的深度从 n 到 1 逐渐降低,形成互为反向链接的金字塔结构.

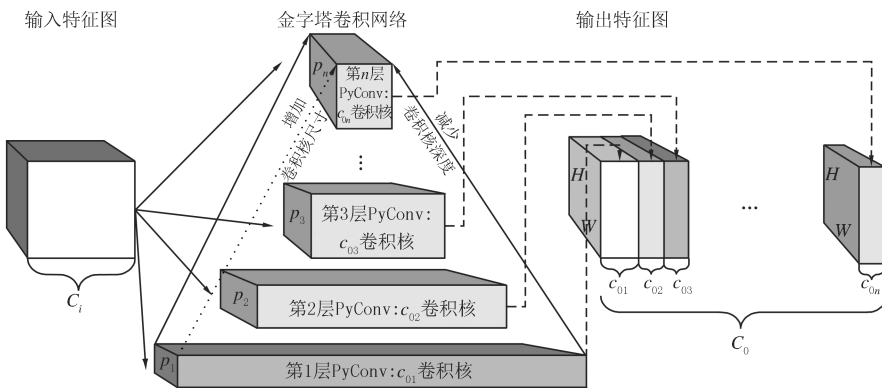


图5 金字塔卷积

Fig.5 Pyramidal convolution

通过分组卷积,对每个级别使用不同深度的卷积核.如图 6 所示,输入 8 个特征图,(a)为标准卷积,(b)和(c)分别表示 group 为 2 和 4 的分组卷积,(b)和(a)相比核的深度减少 2.当卷积组的数量增加到 4 时,卷积核的深度减少,参数量和计算成本减少.




图6 分组卷积

Fig.6 Grouped Convolution

在进入 YOLO Head 进行分类预测之前,根据不同的特征图尺寸对输入的特征图进行分组卷积以扩大感受野.PyConv 网络结构如图 7 所示.

以通道数 $C_i=256$ 的特征图为例,首先经过 1×1 的卷积将输入特征通道数由 256 减少到 64,经过 PyConv 模块分组卷积,4 个卷积核的大小分别为: $9 \times 9, 7 \times 7, 5 \times 5, 3 \times 3$.此外,卷积核的深度在每个级别上都有所不同,从 $G=16$ (分组为 16)到 $G=1$ (标准卷积的分组).每个卷积核输出的通道数为 16,最后输出的特征图通道数为 64.然后用 1×1 卷积恢复输入的通道数 256.每个 1×1 卷积前后都有标准化函数 BN 和 ReLU 激活函数.右侧为快捷连接,可以有效回传梯度.

1.3 先验框的优化

YOLOv5s 算法一共生成 3 个特征图,每个特征图对应 3 种不同类型的先验框,所以 YOLOv5s 算法一共生成 9 个先验框.

YOLOv5s 算法的 9 个默认先验框由 K-means 算法对 MS COCO^[13] (Microsoft Common Objects in Con-




图7 PyConv网络结构

Fig.7 PyConv network structure

text)数据集的目标框聚类得到.根据本文缺陷数据集用 K-means 算法重新聚类得到新的先验框尺寸,使得先验框与真实框更加匹配,以减少默认先验框对检测精度的影响.大、中、小目标分别对应 20×20 、 40×40 、 80×80 的特征图.默认先验框和调整先验框与预测特征图大小的对应关系如表 1 所示.

表 1 预测特征图与先验框的对应关系

Tab. 1 The relationship of the predicted feature map and the anchor box

预测特征图	预测目标	默认先验框	调整后先验框
20×20	大	[142,110],[192,243],[459,401]	[638,104],[112,632],[581,587]
40×40	中	[36,75],[76,55],[72,146]	[73,80],[97,106],[102,224]
80×80	小	[12,16],[19,36],[40,28]	[51,46],[64,56],[86,67]

2 实验设计

2.1 平台搭建

硬件环境:CPU: Intel(R) Core(TM) i5-11400F;显卡:NVIDIA GeForce RTX 3050;内存:16 GB RAM.

软件环境:操作系统:Windows10;编程语言:Python;运行框架:PyTorch.

2.2 数据集构建与模型训练

本文使用自制带钢表面缺陷数据集,其中图片来源于某钢厂镀锌生产线采集的真实缺陷图谱.本文自制数据集包含常见的 6 种缺陷图片 3 190 张,训练集图片与测试集图片数量的比例为 9 : 1,标签分为焊缝(We)、划伤(Sc)、锌渣(Zn)、漏镀(Sk)、锌流纹(Fo)、油斑(Sp)6 类,其中主要缺陷图片如图 8 所示.对数据集用 Labelimg 对目标缺陷进行标注.训练参数为迭代 300 个 epoch,学习率设置为 0.01,前 150 次进行冻结主干网络训练,batch_size 设置为 16,后 150 次解冻训练将 batch_size 设置为 8.




图8 数据集图片示例

Fig. 8 Sample dataset pictures

2.3 评价指标

本文以平均精度均值(P_{MA})和平均精度(P_A)来评价算法的缺陷检测识别效果, P_{MA} 和 P_A 的值越大表明检测效果越好.采用单位时间内检测的图片数量(S_{FP})作为模型检测速度的评价标准,单位时间内检测的图片数量越多,模型的检测速度越快.计算公式如下:

$$P_A = \int_0^1 p(r) dr, \quad (1)$$

$$P_{MA} = \frac{\sum P_A}{k}, \quad (2)$$

$$S_{FP} = \frac{F_c}{T_t}, \quad (3)$$

式(1~3)中: p 为查准率, r 为召回率, $p(r)$ 表示某个 r 对应的 p 的值; P_A 为平均精度值, k 表示缺陷的种类数; F_c 表示检测的图片数量, T_t 表示检测所消耗的总时间.

2.4 优化实验

确定使用的模型后对 SENet 的降维系数以及 SENet 的位置进行实验,调整先验框尺寸,以使得改进后的网络效果更优,前两个实验结果均基于默认先验框得出.

2.4.1 SENet 模块降维系数实验

通过对数据集训练显示平均精度均值并不是随着 SENet 的降维系数 r 的增长而增长,当降维系数 $r = 16$ 时,平均精度均值最高为 94.73%,因此设定降维系数 r 的值为 16.

2.4.2 SENet 模块位置实验

将 SENet 分别添加在两次上采样之后、一次上采样之后和一次下采样之后、PANet 网络之前,经过实验对比显示将 SENet 添加在 PANet 网络之前平均精度均值为 94.73%,优于其他位置.虽检测速度略有下降,但本文更多考虑精度需求,因此将 SENet 添加到 PANet 网络之前.

2.4.3 先验框的优化实验

通过实验对比,YOLOv5s 模型根据本文数据集重新聚类调整先验框之后比调整之前 P_{MA} 提高了 0.53 个百分点,STI-YOLO 模型调整先验框之后比调整之前 P_{AM} 提高了 0.36 个百分点,重新聚类后取得的先验框尺寸对提高模型的检测精度有效.

2.5 消融实验

为了验证改进点对于网络模型的作用,通过消融实验进行对比,只添加 PyConv 模块和只添加 SENet 模块相较于原模型分别提升了 0.50 个百分点和 0.59 个百分点,使用所有改进之后提升了 1.54 个百分点.

3 实验结果与分析

使用本文数据集训练 SSD300(输入图片尺寸大小为 300×300)、YOLOv3、YOLOv4、YOLOv5s 以及 STI-YOLO 模型(本文模型),并进行效果对比.

如图 9 所示,5 种算法模型均能检测出焊缝(We)缺陷,SSD300 模型的置信度为 1.00,YOLOv3 模型置信度为 0.97,YOLOv4 置信度为 0.97,YOLOv5 置信度为 0.90,STI-YOLO 置信度为 0.92.所有模型检测焊缝缺陷的置信度均在 0.90 以上,但 YOLOv4 和 YOLOv5s 在检测过程中出现锌流纹(Fo)的错检情况,STI-YOLO 模型未发生错检.




图9 焊缝缺陷的检测结果

Fig.9 Detection results of weld defect

图 10 所示为划伤(Sc)缺陷的检测结果,YOLOv3 和 YOLOv5s 分别出现划伤缺陷的 1 处漏检,YOLOv4 出现油斑(Sp)1 处错检.相比其他模型,STI-YOLO 模型对缺陷检测的边界框更加准确,精准识别出 2 处划伤缺陷和 2 处锌渣(Zn)缺陷.




图10 划伤缺陷的检测结果

Fig.10 Detection results of scratch defect

图 11 所示为锌渣(Zn)缺陷的检测情况,SSD300、YOLOv3、YOLOv4、YOLOv5s 均有漏检的情况,STI-YOLO 模型对锌渣缺陷没有发生漏检。




图11 锌渣缺陷的检测结果

Fig. 11 Detection results of zinc defect

图 12 所示为漏镀(Sk)缺陷的检测结果,SSD300、YOLOv3、YOLOv4、YOLOv5s 均出现漏检,YOLOv3、YOLOv4 和 YOLOv5s 仅检测出较大漏镀缺陷,对于较小的漏镀缺陷无法识别,STI-YOLO 模型基本将带钢表面的漏镀缺陷检出。




图12 漏镀缺陷的检测结果

Fig. 12 Detection results of skip plating defect

图 13 所示为油斑(Sp)缺陷的检测结果,除了 YOLOv5s 模型的置信度相对较低为 0.83,其余 4 种模型在检测油斑缺陷的置信度上均在 0.9 以上。




图13 油斑缺陷的检测结果

Fig. 13 Detection results of spot defect

图 14 所示为锌流纹(Fo)缺陷的检测结果,5 种模型均能检测出锌流纹缺陷,SSD300、YOLOv3、YOLOv4 检测结果的置信度均在 0.95 以上,YOLOv5s 检测的置信度较低为 0.76,STI-YOLO 模型检测的置信度为 0.85。

综合分析可知:STI-YOLO 模型在有锌花背景干扰下对于缺陷的检测效果更好,对于被锌花背景干扰严重的锌渣和划伤缺陷的检测效果有较大的提升,与其他主流算法相比整体的检测效果更符合检测要求,对于容易出现漏检的锌渣、漏镀缺陷以及出现容易被错检的锌流纹缺陷均能识别。

不同模型对于缺陷检测的性能如表 2 所示。从表 2 可知:SSD300 和 YOLOv5s 的检测速度分别为 58.69、60.88 frame/s,检测速度较快,STI-YOLO 模型虽然检测速度低于 SSD300 和 YOLOv5s,但速度优于 YOLOv3 和 YOLOv4,为 54.14 frame/s,仍能满足缺陷检测的要求,STI-YOLO 模型较 YOLOv5s 的平均精度均值 P_{MA} 提高了 2.07 个百分点。虽然 STI-YOLO 模型在锌流纹(Fo)缺陷上的平均精度稍逊色于

SSD300,但差距仅为 0.04 个百分点.但 STI-YOLO 模型对于较难检测的划伤缺陷和受锌花背景干扰严重的锌渣缺陷表现比较优秀,通过对比,对于划伤(Sc)缺陷,STI-YOLO 模型的平均精度较 SSD300、YOLOv3、YOLOv4 以及 YOLOv5s 分别提高了 7.37 个百分点、22.12 个百分点、12.75 个百分点和 4.03 个百分点.对于受锌花背景干扰严重的锌渣(Zn)缺陷,STI-YOLO 模型有大幅度提高,STI-YOLO 模型较 SSD300、YOLOv3、YOLOv4 以及 YOLOv5s 分别提高了 16.62 个百分点、33.56 个百分点、36.12 个百分点和 4.52 个百分点.油斑(Sp)和焊缝(We)的检出率为 100%,同时漏镀缺陷的检出率为 98.26%,较好解决了漏检问题.

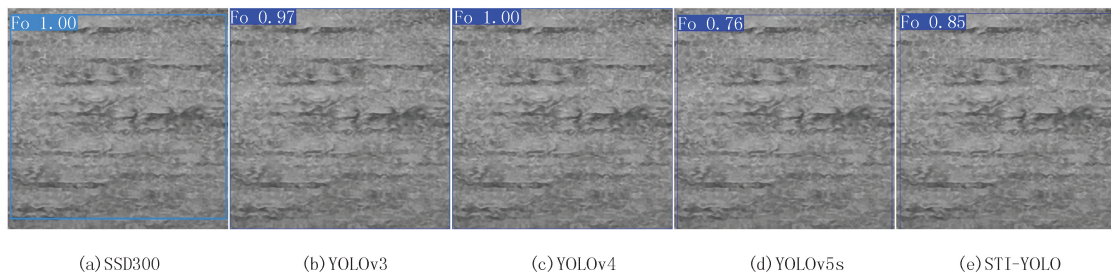


图14 锌流纹缺陷的检测结果

Fig. 14 Detection Results of Zinc flow lines defect

表 2 模型性能对比

Fig. 2 Model performance comparison

算法	$P_A/\%$						平均精度均值 $P_{MA}/\%$	平均速度 $S_{FP}/(\text{frame} \cdot \text{s}^{-1})$
	Sc	Sk	Sp	We	Fo	Zn		
SSD300	83.00	94.66	99.93	98.85	100.00	69.50	90.99	58.69
YOLOv3	68.25	84.72	92.25	99.99	98.17	52.56	82.66	35.06
YOLOv4	77.62	83.04	86.24	98.71	91.61	50.00	81.20	26.66
YOLOv5s	86.34	97.46	98.23	98.84	99.86	81.60	93.72	60.88
STI-YOLO	90.37	98.26	100.00	100.00	99.96	86.12	95.79	54.14

这是因为 STI-YOLO 模型在主干特征网络提取到有效特征图之后,在特征图输入到特征融合网络之前添加了 SENet 通道注意力机制,在不损失重要位置信息和语义信息的前提下提高有效特征信息的利用率,同时抑制由于锌花背景干扰产生的冗余信息,在进入 PANet 之前更高效地利用有效信息,滤除冗余信息,提高了网络的检测精度.同时在进行特征融合之后的 3 个不同尺度的特征图输入到金字塔卷积网络中,提取更加丰富的缺陷信息,使得预测的特征图具有更好的鲁棒性.

4 结 论

针对原始 YOLOv5s 算法在有锌花背景干扰下对划伤缺陷和锌渣小目标检测效果欠佳的问题,根据本文缺陷数据集进行重新聚类调整先验框的尺寸,在特征融合网络 PANet 之前引入通道注意力机制 SENet,增强特征图有效信息的提取,突出重要特征,抑制锌花复杂背景对缺陷检测的干扰,从而减少冗余特征的影响,同时增加金字塔卷积网络丰富预测特征图的感受野,提取更有效的语义信息.STI-YOLO 模型有效提高了 YOLOv5s 算法在有锌花背景干扰下的缺陷检测精度,同时进一步改善了原模型存在漏检以及错检的问题.

参 考 文 献

- [1] ZHAO Z Q,ZHENG P,XU S T,et al.Object detection with deep learning:a review[J].IEEE Transactions on Neural Networks and Learning Systems,2019,30(11):3212-3232.
- [2] 韩芳芳.表面缺陷视觉在线检测关键技术研究[D].天津:天津大学,2012.
HAN F F.Key techniques for surface defects online detection based on machine vision[D].Tianjin:Tianjin University,2012.

- [3] 罗志勇.用线列 CCD 测量钢板宽度和检测孔洞缺陷的信号处理[J].量子电子学,1991,8(1):9.
LUO Z Y.Signal processing of measuring steel plate width and detecting hole defects with linear CCD[J].Chinese Journal of Quantum Electronics,1991,8(1):9.
- [4] 罗志勇,刘栋玉,江涛,等.新型冷轧带钢表面缺陷在线检测系统[J].华中理工大学学报,1996,24(1):75-78.
LUO Z Y,LIU D Y,JIANG T,et al.A new on-line surface defect inspecting system for the cold-rolled steel strip[J].Journal of Huazhong University of Science and Technology,1996,24(1):75-78.
- [5] 杨永敏,樊继壮,赵杰.冷轧带钢表面缺陷视觉检测系统[J].吉林大学学报(理学版),2011,49(5):911-917.
YANG Y M,FAN J Z,ZHAO J.Cold rolling strip surface defect vision detection system[J].Journal of Jilin University(Science Edition),2011,49(5):911-917.
- [6] 布申申,田怀文.基于卷积神经网络的带钢表面缺陷检测算法[J].机械设计与制造,2022(7):29-33.
BU S S,TIAN H W.Strip surface defect detection algorithm based on convolutional neural network[J].Machinery Design & Manufacture,2022(7):29-33.
- [7] 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).[s.l.:s.n.],2016:779-788.
- [8] REDMON J,FARHADI A.YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).[s.l.:s.n.],2017:6517-6525.
- [9] REDMON J,FARHADI A.YOLOv3: an incremental improvement[EB/OL].[2022-06-10].<https://arxiv.org/abs/1804.02767>.
- [10] LECUN Y,BOTTOU L,BENGIO Y,et al.Gradient-based learning applied to document recognition[J].Proceedings of the IEEE,1998,86(11):2278-2324.
- [11] HU J,SHEN L,SUN G.Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition.[s.l.:s.n.],2018:7132-7141.
- [12] DUTA I C,LIU L,ZHU F,et al.Pyramidal convolution: rethinking convolutional neural networks for visual recognition[EB/OL].[2022-06-11].<https://arxiv.org/abs/2006.11538>.
- [13] LIN T Y,MAIRE M,BELONGIE S,et al.Microsoft COCO: common objects in context[C]//Proceedings of 2014 European Conference on Computer Vision.Berlin:Springer,2014:740-755.

A method for detecting surface defects of strip steel under the background interference of spangles based on STI-YOLO

Wei Mingjun^{a,b}, Chen Zhao^a, Ji Zhanlin^{a,b}, Zhou Taiyu^a, Yan Xuwen^a, Liu Ming^a

(a. College of Artificial Intelligence; b. Hebei Provincial Key Laboratory of Industrial Intelligent Perception, North China University of Science and Technology, Tangshan 063210, China)

Abstract: Aiming at the problem of low defect recognition rate due to the interference of zinc flower shading in the surface defect detection of patterned coated steel plate, the Spangles Texture Interference-YOLO(STI-YOLO) algorithm model based on the target detection algorithm YOLOv5s and improved by introducing channel attention mechanism and pyramid convolution network is proposed. According to the defect data set, this paper reclusters & optimizes the anchor box. The SENet is introduced before the PANet to suppress the interference of the zinc flower background. The pyramid convolution network is added before the prediction network to obtain richer context features. The experimental results show that the STI-YOLO model improves the detection accuracy of strip surface defects, and the average accuracy mAP reaches 95.79%, which is 13.13 percentage points, 14.59 percentage points and 2.07 percentage points higher than that of YOLOv3, YOLOv4 and YOLOv5s algorithms respectively. The detection speed is 54.14 frame/s, meeting the real-time requirements. The STI-YOLO model has better detection performance.

Keywords: defect detection; feature fusion; attention mechanism; multiscale feature; zinc flower background interference