

DOI:10.3969/j.issn.1003-5060.2024.03.003

面向带钢表面小目标缺陷检测的改进 YOLOv7 算法

樊 嵘, 马小陆

(安徽工业大学 电气与信息工程学院, 安徽 马鞍山 243002)

摘要:带钢表面小目标缺陷检测是工业质检领域的研究热点。针对热轧带钢表面缺陷检测任务中小目标缺陷易产生漏检的问题,文章提出一种改进的 YOLOv7 算法。在骨干网络中融入通道空间注意力模块(convolutional block attention module, CBAM)和可重参数化卷积模块,以提升小目标特征的提取效率;采用改进的双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)颈部网络替换原有的路径聚合网络(path aggregation network, PANet)颈部网络,实现对小目标缺陷特征的高效提纯;采用解耦检测头进行检测结果输出,使网络在训练时进一步收敛至更高精度。实验结果表明,改进后的 YOLOv7 算法在小目标带钢缺陷检测场景下检测精度领先 YOLOv7 算法 4.3 AP50 精度,领先 YOLOv6 算法 5.0 AP50 精度,领先 YOLOX 算法 4.8 AP50 精度,说明该算法可以较好地应用于小目标带钢缺陷检测。

关键词:机器视觉;缺陷检测;YOLOv7 算法;双向特征金字塔网络(BiFPN);注意力机制

中图分类号:TP391.7 **文献标志码:**A **文章编号:**1003-5060(2024)03-0303-07

Improved YOLOv7 algorithm for small target defect detection on strip steel surface

FAN Rong, MA Xiaolu

(School of Electrical and Information Engineering, Anhui University of Technology, Ma'anshan 243002, China)

Abstract: The detection of small target defects on the surface of hot rolled strip steel is a hot research topic in the field of industrial quality inspection. An improved YOLOv7 algorithm is proposed for the problem of small target defects prone to miss detection in hot rolled strip steel surface defect inspection tasks. Convolutional block attention module (CBAM) module and RepConv module are incorporated in the backbone network to improve the efficiency of small target feature extraction. The original path aggregation network (PANet) neck network is replaced by the improved bi-directional feature pyramid network (BiFPN) neck network to achieve efficient purification of small target defect features. Decoupled detection heads are used for detection result output, so that the network can further converge to higher accuracy during training. Finally, it is shown experimentally that the improved YOLOv7 is ahead of YOLOv7 algorithm by 4.3 AP50 accuracy, ahead of YOLOv6 algorithm by 5.0 AP50 accuracy and ahead of YOLOX algorithm by 4.8 AP50 accuracy in detecting defects in small target hot rolled strip steel detection scenarios. The proposed algorithm can be better applied to small target strip steel defect detection.

Key words: machine vision; defect detection; YOLOv7 algorithm; bi-directional feature pyramid network (BiFPN); attention mechanism

收稿日期:2023-02-07; **修回日期:**2023-03-01

基金项目:国家自然科学基金资助项目(61872004;62172004);安徽省科技重大专项资助项目(202003a05020028)和安徽高校自然科学基金研究重点资助项目(KJ2019A0065)

作者简介:樊 嵘(1997—),男,安徽芜湖人,安徽工业大学硕士生;

马小陆(1979—),男,安徽无为,博士,安徽工业大学教授,硕士生导师,通信作者, E-mail: maxiaolu@ahut.edu.cn.

0 引言

热轧带钢作为我国钢铁工业的重要原材料之一,在航空航天、土地基建以及汽车制造等领域有重要的应用价值。热轧带钢的尺寸精度、表面质量以及性能是衡量带钢产品质量的关键因素。实际生产过程中,由于生产工艺及环境因素的限制,钢体易出现划痕、裂纹、污渍以及斑块等缺陷,不仅有损产品外观,而且易使产品锈蚀和损坏。因此,钢体表面缺陷检测成为工业质检领域的研究热点。

近年来,随着深度神经网络研究的不断进展,基于深度学习的物体表面检测算法逐步替代了传统的机器学习方法和人工检测方法。基于深度学习的物体表面缺陷检测方法主要分为端到端完成检测任务的一阶段检测算法和基于区域生成结构的二阶段检测算法。文献[1]通过使用加权 K -means 聚类方法以及对特征融合层进行改进,提升了算法的缺陷检测精度;文献[2]通过引入注意力机制并改进特征融合网络,提升了算法的缺陷检测精度;文献[3]在 SSD 网络中融入残差网络结构和多级特征融合策略,提升了算法的缺陷检测精度;文献[4]在 RetinaNet 网络中融入通道注意力机制和自适应空间特征融合模块,提升了网络的特征融合能力;文献[5]基于 Faster-RCNN 模型提出一个带钢缺陷检测系统;文献[6]使用特征递归金字塔结构和神经网络架构搜索技术对 Cascade-RCNN 网络进行改进,提升了算法缺陷检测精度。以上工作均有效提升了算法对金属表面缺陷的总体检测精度,但仍未针对金属表面小目标缺陷的漏检问题进行优化与改进,使得实际检测中带钢表面部分小目标缺陷仍存在漏检问题。

小目标缺陷在采样图中所占像素量较少,经过多次下采样后小目标缺陷分辨率会进一步降低,特征信息逐步减弱,使得检测难度提升。文献[7]通过采用 transformer 预测头并增加目标检测头个数提升了网络对小目标的检测性能;文献[8]通过采用改进的双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)提升了模型对小目标的检测效果;文献[9]提出多层特征金字塔网络(multi level feature pyramid network, MLFPN),将不同尺度的特征进行融合,有效缓解了小目标特征信息不足的问题;文献[10]利用空间金字塔池化和额外的特征转换生成不同

尺度的特征,然后将特征扩展到统一尺度并聚合上下文信息,有效缓解了小目标特征信息不足的问题;文献[11]通过将空洞卷积与特征融合相结合,有效增强网络提取的浅层特征的语义信息,提升了小目标的检测性能。以上工作均有效提升了算法对小目标物体的检测性能,但大多面向遥感场景,当面对分布复杂的密集工业缺陷检测场景时,检测效果提升有限。

针对以上问题,本文在 YOLOv7 网络^[12]的基础上进行以下 3 方面改进。

1) 将多分支卷积模块^[13]和通道空间注意力模块(convolutional block attention module, CBAM)^[14]融入特征提取骨干网络,提升网络在特征提取阶段对小目标特征的提取及后续提纯能力。

2) 采用融入 BiFPN^[15]思想的颈部网络对骨干网络提取的多尺度特征图进行双向加权融合,缓解小目标特征在下采样过程中的丢失问题。

3) 采用解耦检测头^[16]替换原有的目标检测头,将预测目标的类别信息与回归信息进行解耦输出,提升模型检测精度。

最终在经过小目标数据增强的 Neu-Det 数据集上与部分常用缺陷检测算法进行对比实验,实验结果表明,改进的 YOLOv7 算法有较好的小目标带钢缺陷检测能力。

1 相关工作

1.1 改进 YOLOv7 算法

YOLOv7 是最新的 YOLO 系列算法,其模型设计思路与 YOLOv4^[17]、YOLOv5 类似,功能上可将网络分为进行特征提取的骨干网络(Backbone)、进行特征融合的颈部网络(Neck)以及进行目标检测结果输出的检测头(Head)3 个部分。检测时输入图像被送入骨干网络进行特征提取;然后由颈部网络对提取的特征进行特征融合,并得到大、中、小 3 种尺寸的特征;最后由检测头对融合后的特征进行处理,并输出最终检测结果。由于采用了扩展的高效长程注意力网络(extended efficient layer aggregation networks, E-ELAN)以及 SPPCSPC 空间金字塔池化等模块,并在前向传播时引入了重参数化卷积以及辅助头检测等策略,YOLOv7 算法获得了较好的检测性能。

YOLOv7 采用 4 个常规卷积进行初期特征提取,使得小目标语义信息易被网络忽略;在特征

融合阶段 YOLOv7 沿用了 YOLOv5 的双向路径聚合网络(path aggregation network for instance segmentation, PANet)^[18]结构并加入了更多的卷积模块,导致骨干网络提取的小目标语义信息难以在特征融合时被有效提纯。

以上两点均易使 YOLOv7 在小目标带钢缺陷场景中产生漏检,因此本文从特征提取和特征融合 2 个角度出发,提升 YOLOv7 对小目标带钢缺陷的检测能力。

改进的 YOLOv7 网络结构如图 1 所示。

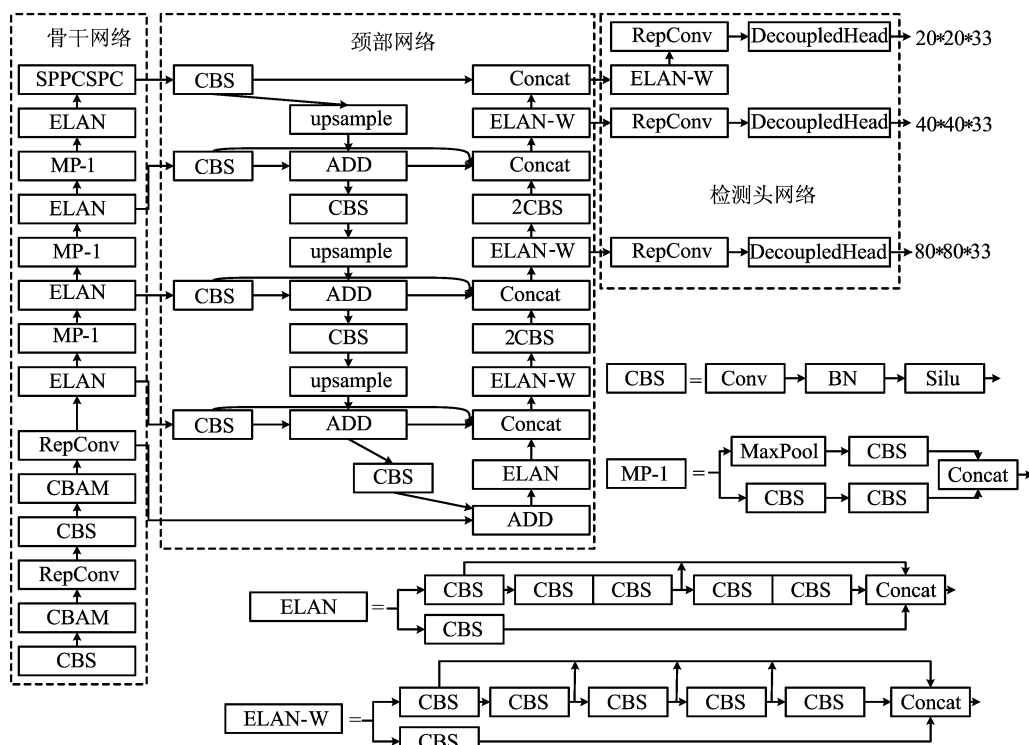


图 1 改进的 YOLOv7 结构图

1.2 改进的特征提取骨干网络

1.2.1 结构重参数化

针对 YOLOv7 初期特征提取时易丢失部分小目标信息的问题,本文采用可重参数化卷积(reparameterization convolution, RepConv)模块替换网络最初的第 2 层和第 4 层的常规卷积模块,使网络早期可以对重要特征进行更高效的提取,缓解重要特征在卷积操作中产生的丢失现象。重参数化(reparameterization, Rep)的核心思想是利用参数恒等变换实现网络结构的简化。RepConv 在训练阶段采用 3×3 卷积、 1×1 卷积、短接分支以及批归一化(batch normalization, BN)模块构建的多分支可重参数化卷积 RepConv 模块进行训练,训练完成后的推理阶段中,可重参数化卷积 RepConv 模块会被参数重构为一个与原分支性能等效的 3×3 卷积模块,使模型兼顾训练时的高精度和推理时的高速度。

可重参数化卷积 RepConv 模块结构如图 2 所示。

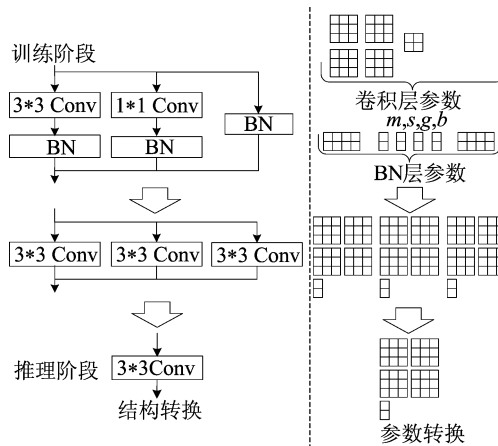


图 2 可重参数化卷积 RepConv 模块结构

RepConv 模块在进行结构重参数化时,先将短接分支结构等价转换为一个以单位矩阵为卷积核的 1×1 卷积,之后将 2 个 1×1 的卷积通过填充 0 转换为 2 个 3×3 的卷积,之后将 3 个 3×3 卷积分别与其对应的批归一化 BN 模块进行融合,融合过程如下:

$$W_i' = \frac{y_i}{\sigma_i} W_i \quad (1)$$

$$\beta_i' = -\frac{\mu_i y_i}{\sigma_i} + \beta_i \quad (2)$$

其中: W_i, W_i' 分别为转换前、后的卷积层参数; β_i, β_i' 分别为转换前、后的批归一化层偏移因子; y_i 为批归一化层的尺度因子; μ_i 为批归一化层的均值; σ_i 为批归一化层的方差。

卷积层和批归一化层融合后,可以用一个 3×3 卷积替换模型训练时使用的原始 3×3 卷积、 1×1 卷积、短接分支以及批归一化 BN 模块,模型重构后仅有一个 3×3 的卷积用于模型推理。

1.2.2 通道空间注意力模块

在含有较多小目标带钢缺陷的检测环境中,小目标缺陷像素往往分布于图像的少量区域,大

部分图像内容仍为正常带钢表面。小目标瑕疵尺寸小特征少且不明显,为了更好地对其特征进行提纯与学习,本文将通道空间注意力模块 CBAM 穿插于常规卷积模块以及可重参数化卷积模块之间,利用 CBAM 模块对卷积模块学习到的特征信息进行注意力权重重构,提高重要特征的权重,为颈部网络提供更为高效的特征图。

CBAM 模块是一种轻量级即插即用的卷积注意力模块,它会依次计算通道与空间 2 个维度的注意力图,并将注意力图与特征图相乘以进行自适应特征优化,模仿人类的注意力感知^[19],自动过滤不重要的信息,并把更多的计算资源用于需要重点关注的特征。

CBAM 模块结构如图 3 所示。




图 3 通道空间注意力 CBAM 模块结构

1.3 融合 BiFPN 结构的颈部网络

YOLOv7 沿用了 YOLOv5 采用的 PANet 颈部网络,实现了自顶向下和自底向上的双向特征融合,因此使网络可以有效结合不同尺度的特征进而提升检测精度。但在 YOLOv7 中 PANet 关注的仍是中高维度的特征图,由于经过多次卷积后,中高维度的特征图中小目标信息的含量较少,使得网络对小目标特征的学习效率较低,针对此问题本文提出融合 BiFPN 思想的改进颈部网络,并以此替换 YOLOv7 原有的 PANet 特征融合网络。

1.3.1 原始的 BiFPN 颈部网络

BiFPN 结构如图 4 所示。




图 4 单层 BiFPN 结构

BiFPN 是一种基于双向加权特征融合思想的高效多尺度特征融合方法,它与 PANet 一样采用双相多尺度特征融合操作,使网络可以有效结合不同尺度的特征。相较于 PANet, BiFPN 可以聚合更多不同尺度的特征并进行跨尺度特征融合,使网络拥有更高的重要特征提纯效率,且在进行特征融合时 BiFPN 引入了可学习的权重因子,使重要的特征在融合后得到了更好的保留。

1.3.2 改进的 BiFPN 颈部网络

为了充分利用改进骨干网络提取的包含大量小目标特征的多尺度特征图,本文借鉴了 BiFPN 的设计思想,在进行特征融合时,采用最近邻插值上采样模块^[20]和长短链路高效聚合网络(ELAN-W)模块分别作为上采样模块和下采样学习模块。同时为了进一步实现对小目标特征的有效保留及提纯,当经过上采样的高维特征与低维特征进行融合时,采用可学习的加权特征融合方式,使网络在训练过程中自适应学习更重要的特征;当经过下采样的低维特征与高维特征进行融合时,采用拼接特征融合方式,以最大限度地保留特征提取初期未被丢失的小目标信息。改进后的颈部网络在进行特征融合时,更偏向于提升初期卷积提取的包含较多小目标特征信息的特征图所占比重,

缓解多次卷积造成的小目标特征丢失现象。改进后的单层 BiFPN 结构如图 5 所示。

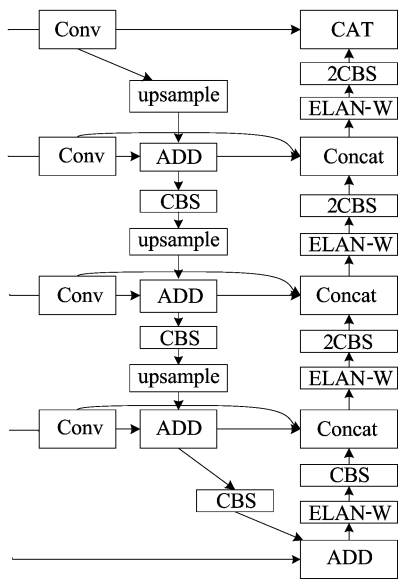


图 5 改进的单层 BiFPN 颈部网络

1.4 改进的目标检测头

在目标检测任务中,分类操作与回归操作对目标特征的关注点不同^[21]。分类操作更加关注目标的纹理特征信息,而回归操作更加关注目标的边缘信息。因此目标的置信度评价分数与回归框可能产生不一致性,即目标置信度分数最高的检测框不一定是回归最准的框,而回归最准的框也不一定是置信度分数最高的框。在原始的 YOLOv7 中,检测时仍然使用耦合检测头,导致分类、回归、置信度计算的操作产生耦合。

针对以上问题,本文采用任务解耦特征检测头,先使用一个 1×1 卷积特征图进行降维,之后分别通过 2 个 3×3 卷积将特征图转化为用于分类的特征图以及用于回归及置信度计算的特征图。用于分类的特征图通过 1 个 1×1 卷积后直接输出类别信息,用于回归及置信度计算的特征图通过 2 个 1×1 卷积分别进行位置回归输出以及置信度计算。采用解耦检测头后模型将目标的类别信息、置信度与回归信息进行解耦输出,使模型在训练过程中可以进一步收敛至更高精度。解耦检测头结构如图 6 所示。




图 6 解耦检测头

2 实验结果与分析

2.1 数据集与数据增强

为了获取含有较多小目标^[22]缺陷的带钢表面缺陷数据集,本文对东北大学制作的 NEU-DET 数据集^[23]进行随机拼接以及分辨率缩放数据增强。NEU-DET 数据集包含裂纹、杂质、斑纹、点蚀、氧化以及划痕 6 种常见的带钢表面缺陷共计 1 800 张图像。

本文从 1 800 张图像中随机抽取 16 张图像进行拼接,并将分辨率由拼接后的 800×800 缩放至 640×640 作为一张试验图像,经上述方法数据增强后得到拼接数据集共 1 800 张,以 8 : 2 划分为训练集与测试集。为了进一步提升算法的鲁棒性,训练过程中沿用了 YOLOv5 提出的 Mosaic 数据增强。

2.2 实验配置与评测标准

本文在 16 GiB 运行内存、Ryzen5-5600G 处理器、NVIDIA TeslaP40 显卡的硬件平台上进行模型训练,运行库版本为 CUDA11. 6,软件环境为 Pytorch1. 12. 1。为了更好地与其他检测网络进行性能对比,本文采用平均精度度 (average precision, AP) 衡量模型检测精度,平均精度度 IoU 阈值取 0. 50 以及 0. 50 ~ 0. 95,分别记作 AP50 和 AP50 : 95。

2.3 消融实验

为验证本文添加的各个模块是否起到作用,设置了消融实验。每组模型在数据增强后的 NEU 数据集上进行 300 轮训练,使用 AP50 和 AP50 : 95 作为模型的性能衡量指标。所有实验组均未使用预训练权重且均选择随机梯度下降 (stochastic gradient descent, SGD)^[24] 优化器进行优化,初始学习率为 0. 000 5。实验编号和实验结果见表 1 所列,其中“√”表示本组实验已使用该模块。

对比消融实验 A 与 B 可知,添加 CBAM 注意力模块可以有效提升模型的检测精度;对比消融实验 A 与 C 可知,采用 RepConv 模块替换常规卷积模块可以有效提升模型的检测精度;对比消融实验 A 与 E 可知,采用改进的 BiFPN 颈部网络可以有效提升模型的检测精度;对比消融实验 A 与 G 可知,采用解耦检测头 DecoupledHead 进行检测可以有效提升模型的检测精度;对比消融实验 B 与 D 可知,CBAM 注意力模块与 RepConv 模块的引入有效提升了骨干网络的特征提

取与提纯效率,可以有效提升模型的检测精度;对比消融实验 D 与 F 可知,改进的 BiFPN 颈部网络相较于原有的 PANet 颈部网络有更高的特征

融合效率,可以有效提升模型检测精度;对比消融实验 F 与 G 可知,添加解耦检测头可以进一步使网络收敛至更高精度。

表 1 消融实验结果数据

实验编号	YOLOv7	CBAM	RepConv	BiFPN	DecoupledHead	AP50	AP50 : 95
A	✓					0.719	0.368
B	✓	✓				0.730	0.385
C	✓		✓			0.737	0.387
D	✓	✓	✓			0.740	0.394
E	✓			✓		0.741	0.393
F	✓	✓	✓	✓		0.758	0.394
G	✓				✓	0.748	0.389
H	✓	✓	✓	✓	✓	0.762	0.399

2.4 横向对比实验

为验证本文算法的有效性,将本文算法在含有大量小目标的热轧带钢缺陷数据集中与常用缺陷检测算法 YOLOv5、YOLOv6、YOLOX、Faster-RCNN^[25]以及 YOLOv7 进行对比实验。每个模型在数据增强后的 NEU 数据集上进行 300 轮训练,使用 AP50 与 AP50 : 95 作为模型的性能衡量指标。所有实验组均未使用预训练权重且均选择 SGD 优化器进行优化,初始学习率为 0.000 5。横向对比实验结果见表 2 所列。

表 2 横向对比实验结果

算法	AP50	AP50 : 95
Faster-RCNN	0.563	0.272
YOLOv5	0.702	0.365
YOLOv6	0.712	0.378
YOLOX	0.714	0.381
YOLOv7	0.719	0.368
本文	0.762	0.399

由表 2 可知,在包含大量小目标带钢缺陷的检测场景中,本文检测精度高于 YOLOv5 及 YOLOX 等常见目标检测算法。

3 结论

本文以 YOLOv7 为基础框架,对骨干网络、颈部网络以及检测头分别作出改进。采用 RepConv 模块和 CBAM 模块对骨干网络进行改进,改进的骨干网络为模型提供了高效的多尺度特征图,使模型检测精度进一步提升;采用改进的 BiFPN 替换原有的 PANet 结构,使模型的特征融合效率得到提升,进一步提高了模型在小目标缺陷检测环境下的检测精度;采用解耦检测头替

换原有的预测头,使模型在训练中可以收敛至更高的精度。在含有大量小目标带钢缺陷的数据集中进行的对比实验结果表明,本文提出的改进 YOLOv7 算法精度高于 YOLOX、YOLOv6 等常用缺陷检测算法。

[参 考 文 献]

- [1] 李维刚,叶欣,赵云涛,等. 基于改进 YOLOv3 算法的带钢表面缺陷检测[J]. 电子学报,2020,48(7):1284-1292.
- [2] 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.
- [3] 李瑞生,张彦龙,翟登辉,等. 基于改进 SSD 的输电线路销钉缺陷检测[J]. 高电压技术,2021,47(11):3795-3802.
- [4] CHENG X, YU J. RetinaNet with difference channel attention and adaptively spatial feature fusion for steel surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement,2020,70:1-11.
- [5] 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.
- [6] 赵振兵,熊静,李冰,等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术,2022,48(3):1060-1067.
- [7] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. [S. l.]: IEEE,2021:2778-2788.
- [8] BENJUMEA A, TEETI I, CUZZOLIN F, et al. YOLO-Z: improving small object detection in YOLOv5 for autonomous vehicles [EB/OL]. (2021-12-22) [2023-01-03]. https://doi.org/10.48550/arXiv.2112.11798.

(下转第 316 页)

- [9] HOANG D T, KANG H J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image [J]. *Cognitive Systems Research*, 2018, 53: 42-50.
- [10] 余刃, 谢旭阳, 王天舒, 等. 基于深度学习波形图像识别的轴承故障诊断方法[J]. *海军工程大学学报*, 2021, 33(4): 76-82.
- [11] 马俊添, 张素明, 阎小涛, 等. 基于图像识别的机械振动信号特征提取与寿命预测方法研究[J]. *宇航总体技术*, 2021, 5(4): 33-42.
- [12] DALAL N, TRIGGS B. Histograms of oriented gradient for human detection[C]//*IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [S. l. : s. n.], 2005: 886-893.
- [13] 刘进博, 郭鹏宇, 李鑫. 基于梯度直方图的交叉点检测方法[J]. *国防科技大学学报*, 2021, 43(1): 33-40.
- [14] CARROLL J D, ARABIE P. Multidimensional scaling[J]. *Measurement Judgment and Decision Making*, 1980, 31: 607-649.
- [15] 张学工. 关于统计学习理论与支持向量机[J]. *自动化学报*, 2000, 26(1): 32-41.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode-decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62: 531-544.
- [17] 王琇峰, 文俊. 基于噪声信号和改进 VMD 的滚动轴承故障诊断[J]. *噪声与振动控制*, 2021, 41(2): 118-124.

(责任编辑 胡亚敏)

(上接第 308 页)

- [9] 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*. [S. l.]: AAAI, 2019: 9259-9266.
- [10] KIM S W, KOOK H K, SUN J Y, et al. Parallel feature pyramid network for object detection[C]//*Proceedings of the European Conference on Computer Vision*. [S. l.]: IEEE, 2018: 234-250.
- [11] QU J, SU C, ZHANG Z, et al. Dilated convolution and feature fusion SSD network for small object detection in remote sensing images [J]. *IEEE Access*, 2020, 8: 82832-82843.
- [12] 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/VCF Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2023: 7464-7475.
- [13] DING X, ZHANG X, MA N, et al. Repvgg: making vgg-style convnets great again[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2021: 13733-13742.
- [14] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision*. [S. l.]: IEEE, 2018: 3-19.
- [15] TAN M, PANG R, LE Q V. Efficientdet: scalable and efficient object detection[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2020: 10781-10790.
- [16] GE Z, LIU S, WANG F, et al. Yolox: exceeding yolo series in 2021 [EB/OL]. (2021-07-18) [2021-08-06]. <https://doi.org/10.48550/arXiv.2017.08430>.
- [17] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23). <https://doi.org/10.48550/arXiv.2004.10934>.
- [18] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2018: 8759-8768.
- [19] 胡丹丹, 张忠婷, 牛国臣. 融合 CBAM 注意力机制与可变形卷积的车道线检测[J/OL]. *北京航空航天大学学报*. (2022-12-15). <https://doi.org/10.13700/j.bh.1001-5965.2022.0601>.
- [20] WANG Z, CHEN J, HOI S C H. Deep learning for image super-resolution: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 43(10): 3365-3387.
- [21] SONG G, LIU Y, WANG X. Revisiting the sibling head in object detector[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2020: 11563-11572.
- [22] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft coco: common objects in context[C]//*Proceedings of the 13th European Conference on Computer Vision, Part V 13*. [S. l.]: Springer International Publishing, 2014: 740-755.
- [23] BAO Y, SONG K, LIU J, et al. Triplet-graph reasoning network for few-shot metal generic surface defect segmentation[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.
- [24] ROBBINS H, MONRO S. A stochastic approximation method[J]. *The Annals of Mathematical Statistics*, 1951, 22(3): 400-407.
- [25] REN S, HE K M, 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: 91-99.

(责任编辑 胡亚敏)