

DOI:10.19651/j.cnki.emt.2208922

基于改进 YoloX-s 的密贴检查器故障检测方法

徐哲玮 刘 昭 包建东 刘英舜
(南京理工大学自动化学院 南京 210094)

摘要: 为了降低密贴检查器维护和检修中的高运营成本,提高安全保障能力,提出了一种改进 YoloX-s 的密贴检查器故障检测方法。通过改进 YoloX-s 中的 PANet 路径融合网络,进一步增加了与浅层特征层的融合;此外,增加了 CA 注意力机制,将注意力集中在目标区域内,以获取细节信息;选用 CIoU 损失函数以聚焦目标框与检测框之间的重叠面积、中心点距离和长宽比,提高模型的定位精度。实验结果表明,相较于 YoloX-s 模型,所提模型有着更好的综合表现,动接点环平均精度为 97.73%,静接点片平均精度为 98.83%,平均精度均值为 98.28%。

关键词: 轨道交通;密贴检查器;故障检测;YoloX-s;深度学习

中图分类号: U216.3 **文献标识码:** A **国家标准学科分类代码:** 580.3020

A fault detection method of the closure detectors based on the improved YoloX-s

Xu Zhewei Liu Zhao Bao Jiandong Liu Yingshun

(School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In order to reduce a high operation cost of maintenance and recondition, as well as improving the security capability, we employed an improved YoloX-s detection method for the fault of closure detectors. By elevating the PANet path fusion network of the proposed model, a fusion with shallow feature layer is further strengthened. In addition, we added the coordinate attention(CA) attention mechanism to the model for the more detailed information in the target area. Moreover, the CIoU loss function is selected to enhance a positioning accuracy, which is aimed at the overlapping area, the center point distance and the aspect ratio between a target frame and a detection frame. After various tests, the experimental results showed that the presented model has a better comprehensive performance compared with the existing YoloX-s model. Furthermore, an average accuracy of moving contact reached 97.73%, an average accuracy of static contact reached 98.83%, and an average accuracy reached 98.28%.

Keywords: rail transit; closure detector; fault detection; YoloX-s; deep learning

0 引 言

随着我国铁路信息化发展步伐加快,轨道交通线路数量与日俱增,铁路列车速度也不断提高。设施设备数量的不断增加,带来了更多维护和管理的需求。2020年,国铁集团发布了《新时代交通强国铁路先行规划纲要》,纲要显示到2035年,全国铁路网要达到20万km左右,其中高铁7万km左右,20万人口以上城市实现铁路覆盖,50万人口以上城市高铁通达^[1]。

道岔作为一种铁道机车车辆从一股道转入另一股道的线路连接设备,是轨道当中最为薄弱和重要的部分。除了自身的结构复杂性,诸如列车动力作用、侵蚀、保养不当等外界因素也会对道岔设备寿命造成极大的不利影响^[2]。这

其中,道岔尖轨与基本轨不密贴已成为主要问题,将导致列车进入道岔时轮对卡在缝隙中形成挤岔,对行车构成严重威胁^[3]。作为检查道岔牵引点之间密贴和斥离状态的设备,密贴检查器串联在道岔的表示系统中。当尖轨与基本轨之间夹有异物、尖轨硬弯、尖轨侧磨、尖轨动程不足等因素时,基本轨和尖轨的间隙会变大。若影响到了行车安全,位于该处的密贴检查器会进行报警,并及时切断表示电路。因此,密贴检查器故障的快速检测具有十分重要的意义。

目前,密贴检查器的维护和检修模式多为人工检测,这种运维模式的效率低,且维护成本高。具体而言,接点组外观检测采用目测的方法,以此来判断是否满足相关标准。接点打入深度检测采用人工游标卡尺测量接触深度,即动接点环打入静接点片接触开始至动接点环完全打入静接点

收稿日期:2022-01-24

片后的差值。此外,对铁路设备的维护和检修也大多采用基于静态数据的“定期修”、“故障修”模式。因此,难以实现铁路运维系统对提高安全保障能力和降低运营成本的需求^[4]。

针对上述情况,深度学习算法提供了一个解决问题的新思路。目前,该类方法已在铁路运营、维护、检修等方面有着越来越广阔的应用前景。基于深度学习的目标检测算法可分为两大类:一阶段算法(one-stage)和两阶段算法(two-stage)。前者省略了候选区域生成阶段,直接得到目标分类和位置信息,其代表有 SSD^[5]、Yolo^[6-9] 系列算法;后者先对输入图像选取可能包含检测目标的候选区域,再对候选区域进行分类和位置回归以得到检测结果,其代表算法有 R-CNN^[10]、Fast R-CNN^[11]、Faster R-CNN^[12-13]。文献[14]使用 Faster R-CNN 和 RRPN^[15] 算法分别对接触网吊弦和接触网绝缘子进行定位及故障检测,该方法减少了人工需查看的图像数量,提高了接触网的故障检测效率。文献[16]利用卷积神经网络实现对列车 4 种经典故障即列车侧架键丢失、轴螺栓丢失、轴螺栓松动和螺栓丢失的识别,该方法在四种典型故障中均具有较高的识别准确率、较低的误报率和较低的漏报率。文献[17]针对接触网支撑装置上紧固件的缺失和松动等缺陷,提出了一种基于深度卷积神经网络(DCNN)的三阶段缺陷检测方法,该方法具有良好

的鲁棒性和较高的检测率,在复杂环境中具有较好的适应性。尽管深度学习已在铁路设施、设备故障的检测上有了较多成熟的应用,但该类方法尚未大规模、全面的应用于密贴检查器,尤其是针对动接点环和静接点片的相关研究。

综上,本文提出了一种改进 YoloX-s^[18] 算法的深度学习模型,通过对密贴检查器动接点环和静接点片进行目标检测,获得相应的位置信息,判断动接点环打入静接点片的深度是否满足相关标准,进而鉴别密贴检查器是否发生故障。该方法以 YoloX-s 为基础,改进了 PANet^[19] 路径融合网络,增加了与浅层特征层的融合,有利于提高模型对位置和细节信息的特征提取能力。而在加强特征提取网络部分,加入了 CA(coordinate attention)^[20] 注意力机制,提升了目标检测性能。此外,损失函数使用 CIoU(complete-IoU) Loss^[21] 增加了模型回归时的收敛速度及准确度。总之,文章所提模型,在满足实时检测的前提下,提升了密贴检查器动接点环和静接点片的检测精度及定位精度。该研究希望为密贴检查器的故障检测提供一种快速、准确的新思路。

1 YoloX-s 模型

作为 YoloX 模型的一个衍生版本,YoloX-s 模型包括主干特征提取网络,加强特征提取网络和分类回归层,具体细节如图 1 所示。

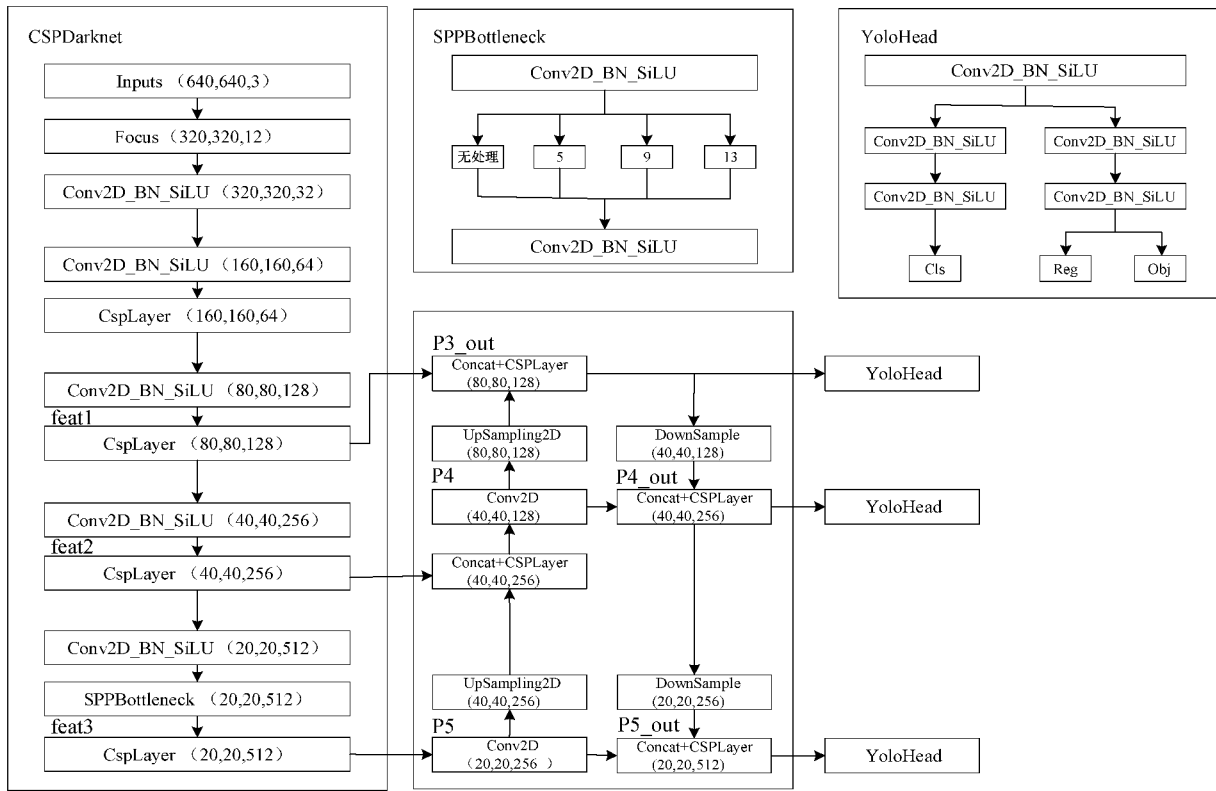


图 1 YoloX-s 模型结构

图 1 中,YoloX-s 的主干特征提取网络为 CSPDarknet,它利用了 YOLOv5 中的 Focus 网络结构。处理图片时,该结

构每隔一个像素获取一个值,在获取到 4 个独立的特征层后,通过堆叠特征层,宽高信息被集中到了通道信息,输入

通道也扩充了 4 倍。CSPDarknet 使用了 SPP (spatial pyramid pooling)^[22] 结构,通过不同池化核的最大池化进行特征提取,提高网络的感受视野。在 YOLOv4^[9] 中,SPP 用于加强特征提取网络,而在 YoloX-s 中,SPP 用于主干特征提取网络。YoloX-s 使用了 SiLU 激活函数,有着无上界、平滑、非单调等特性,因此在深层模型上,性能优于 ReLU 激活函数。YoloX-s 的加强特征提取网络针对 3 个在主干特征提取网络不同位置的特征层 (feat1, feat2 和 feat3)。该网络为 PANet 路径聚合网络结构,主干特征提取网络输出的特征层 feat3 进入 PANet 后,经过 2 次通道数调整 (获得 P4 和 P5) 及上采样后分别与 feat2 和 feat1 进行融合,然后经由 CSPLayer 特征提取后获得 P3_out, P3_out 经过 2 次下采样后分别与 P4 和 P5 堆叠,最后通过 CSPLayer 进行特征提取获得 P4_out 和 P5_out。YoloX-s 的分类回归层将 3 个加强特征层传入 YoloHead 以获得预测结果,不同于 Yolo 之前版本 (分类和回归在一个 1×1 的卷积核上),YoloHead 的分类和回归分别实现,最后预测的时候才整合。YoloX-s 使用无锚框 (anchor-free) 检测

器,减少了参数和检测器的 GFLOPs,因此它的检测速度更快,准确率更高。在获得预测结果后,得分排序与非极大抑制筛选被应用调整先验框以确定最终的预测框。YoloX-s 目标检测的损失函数包括 Reg 模块、Obj 模块和 Cls 模块。Reg 模块判断了特征点的回归参数,Obj 模块判断特征点是否包含物体,Cls 部分确定特征点包含的物体种类。YoloX-s 使用 SimOTA^[23] 技术,为不同大小的目标动态匹配正样本。

2 改进 YoloX-s 模型

YoloX-s 模型的改进体现在 3 个方面:1) 为提高模型的目标检测效果,在原有 3 个尺度特征层融合的基础上加入 160×160 浅层特征层,改进后的模型为 4 个尺度特征层相融合;2) 为使网络更加关注待测目标,忽略不必要的消息,在主干特征提取网络的 3 个特征层后及加强特征提取网络中引入 CA 注意力机制;3) 为提高模型的定位精度,用 Clou 损失函数替代原本的损失函数。每个改进部分将在之后章节具体介绍。YoloX-s 模型的改进结构如图 2 所示。

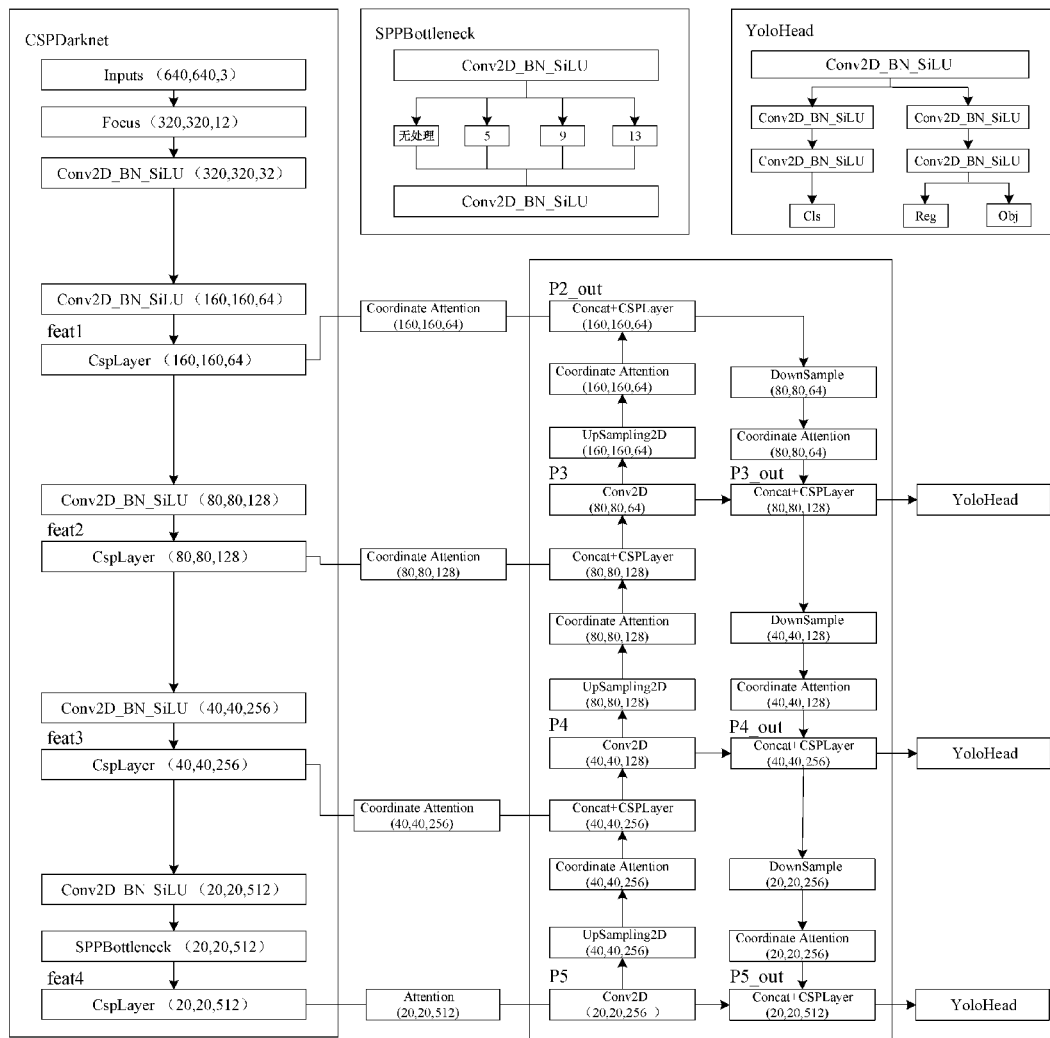


图 2 YoloX-s 模型的改进结构

2.1 PANet 改进

浅层网络的特点是特征图分辨率高,几何信息表征能力强;而深层网络有着特征图感受野较大,语义信息表征能力强的特征。在 YoloX-s 的 PANet 模块,文章将 $80 \times 80, 40 \times 40$ 和 20×20 三个尺度特征层与 160×160 浅层特征层相互融合,使融合单元能够传递浅层的强定位信息和边缘特征,进而提高目标检测效果。当检测密贴检查器接点组动接点环和静接点片时,需要结合预测框的坐标信息,判断动接点环进入静接点片的深度,因此,定位的准确度尤为重要。

2.2 添加 CA 注意力机制

注意力机制的核心是通过一定手段获取到每张特征图重要性的差异,将神经网络的计算资源更多地投入更重要的任务,利用任务结果反向指导特征图的权重更新,以便高效快速地完成相应任务^[24]。本文在 YoloX-s 中添加了 CA 注意力机制,该机制在水平方向和垂直方向上进行了平均池化,通过空间信息编码,以加权的方式融合了空间信息。具体而言,在主干特征提取网络的 3 个特征层后和加强特征提取网络中,模型增加了 CA 注意力机制。CA 注意力模块如图 3 所示。

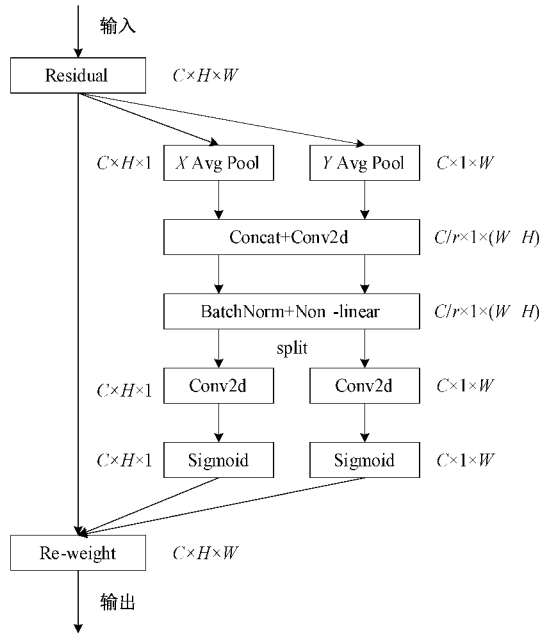


图 3 CA 注意力模块

结合图 3,CA 机制阐释如下:

首先,对于给定输入 X ,分别对水平方向和垂直方向进行平均池化,计算公式如式(1)、(2)所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (1)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (2)$$

式中: $z_c^h(h)$ 代表高度为 h 的第 c 通道的输出, $z_c^w(w)$ 代

表宽度为 w 的第 c 通道的输出。

其次,拼接并使用卷积变换对通道进行压缩,使通道数从 C 变为 $C/r, r$ 用于控制缩减率。批量归一化和非线性处理来编码垂直方向和水平方向的空间信息,计算公式如式(3)所示。

$$f = \delta(F_1([\cdot, \cdot])) \quad (3)$$

式中: F_1 代表 1×1 的卷积变换, $[\cdot, \cdot]$ 是拼接操作, δ 代表非线性激活函数。

再次将 f 分解为两个单独的张量 f^h 和 f^w , 并使用两个 1×1 的卷积变换 F_h 和 F_w , 得到了和输入 X 一样的通道数,计算公式如式(4)、(5)所示。

$$g^h = \sigma(F_h(f^h)) \quad (4)$$

$$g^w = \sigma(F_w(f^w)) \quad (5)$$

式中: F_h 和 F_w 代表 1×1 的卷积变换, σ 代表 Sigmoid 函数。

最后, CA 注意力模块的输出 Y 的计算公式如式(6)所示。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (6)$$

2.3 损失函数改进

IoU(intersection over union)^[25] 作为评价目标检测器性能的指标,计算了预测框与真实框之间交集和并集的比值。IoU 和损失函数 $Loss_{IoU}$ 的计算公式如式(7)、(8)所示。

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (7)$$

$$Loss_{IoU} = 1 - IoU \quad (8)$$

式中: A 代表检测框, B 代表真实框, $A \cap B$ 代表 A 与 B 的交集面积, $A \cup B$ 代表 A 与 B 的并集面积。

在 IoU 的基础上,GIoU(generalized intersection over union)^[26] 引入了预测框和真实框的最小外接矩形,用惩罚项反映检测框和真实框的相交情况^[27]。GIoU 和损失函数 $Loss_{GIoU}$ 的计算公式如式(9)、(10)所示。

$$GIoU = IoU - \frac{|C - (A \cup B)|}{|C|} \quad (9)$$

$$Loss_{GIoU} = 1 - GIoU \quad (10)$$

式中: A 代表检测框, B 代表真实框, C 代表包含检测框和真实框的最小外接矩形框, $C - (A \cup B)$ 代表惩罚项。

YoloX-s 损失函数的 Reg 为 $Loss_{IoU}$ 和 $Loss_{GIoU}$ 。本文选用了 $Loss_{CIoU}$ 作为损失函数的 Reg, CIoU 考虑了目标框回归三要素(重叠面积、中心点距离和长宽比),从而提高了目标框回归的稳定性^[28]。CIoU 相关图示如图 4 所示。

CIoU 和损失函数 $Loss_{CIoU}$ 的计算公式如式(11)~(14)所示。

$$CIoU = IoU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \quad (11)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (12)$$

$$v = \frac{4}{\pi^2} (\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h})^2 \quad (13)$$




图 4 CIoU 相关图示


$$Loss_{CIoU} = 1 - CIoU \quad (14)$$

式中: b 和 b^{gt} 分别代表预测框和真实框的中心点, $d = \rho^2(b, b^{gt})$ 代表预测框和真实框的中心点的欧氏距离。 c 代表预测框与真实框的最小外接矩形的对角线距离。 w 和 w^{gt} 分别代表预测框与真实框的宽度, h 和 h^{gt} 分别代表预测框与真实框的高度。


3 模型评估

3.1 样本集设置

实验数据集均来自现场实景,包括密贴检查器动接点环在不同运动位置的接点组图像。为了增强模型的泛化能力,避免网络过拟合^[29],通过翻折、对比度调节、亮度调节等图像处理方法对数据集进行数据增强,扩充数据集,扩充后图像共 954 张。本文划分训练集、验证集和测试集



(a) 改进YoloX-s训练结果



(b) YoloX-s训练结果

图 5 模型训练结果

3.3 评价指标

本文采用检测精度和检测速度来衡量模型在测试集上的性能。检测精度指标包括精确率 (precision, P)、召回率 (recall, R)、平均精度 (average precision, AP) 及平均精度均值 (mean average precision, mAP); 模型检测速度指标采用每秒检测图像帧数 (frames per second, FPS)^[30]。本文以 $IoU=0.75$ 计算 mAP, 即 $mAP@0.75$ 。计算公式如式 (15)~(19) 所示。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (15)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (16)$$

的比例为 6 : 2 : 2, 利用 LabelImg 标注了图像中密贴检查器的动接点环 (moving contact) 和静接点片 (static contact), 并将类别和位置信息保存到 xml 文件中。最后转化 xml 文件为 txt 文本, 用于评估网络模型。

3.2 模型训练

本文的实验平台为 Windows10 操作系统, CPU 为 AMD Ryzen 7 5800H, 内存为 16 GB, 显卡为 NVIDIA GeForce RTX 3060 Laptop 6 GB, 深度学习框架为 PyTorch。

在模型训练时, 本文采用了冻结训练的方式。具体而言, 在冻结阶段, 模型的主干被冻结, 特征提取网络不发生改变, 占用的显存较小, 仅对网络进行微调。在解冻阶段, 模型的主干不被冻结, 特征提取网络会发生改变, 占用的显存较大, 网络所有的参数都会发生改变。因而, 模型冻结训练可以加快训练效率, 防止权重被破坏。

本文训练参数设置如下: 图像尺寸为 640×640 ; 学习率调整方式为余弦退火衰减 (cosine annealing scheduler); 前 50 轮为冻结训练, 初始学习率为 0.001, 训练批次大小为 4; 后 50 轮为解冻训练, 初始学习率为 0.000 1, 训练批次大小为 2。

图 5(a) 和 (b) 分别是改进 YoloX-s 和 YoloX-s 的模型训练结果。两个模型的损失都随着训练轮数的增加而下降, 但是改进 YoloX-s 的模型损失下降的速度要大于 YoloX-s 的模型损失, 且在训练结束时的模型损失较小, 表明改进的方法有着更好的模型训练效果。

$$AP = \int_0^1 P(R) dR \quad (17)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (18)$$

$$FPS = \frac{N}{t} \quad (19)$$

式中: TP 代表正确预测的正样本个数; FP 代表错误预测的正样本个数; FN 代表错误预测的负样本个数; n 代表待检测的目标类别数; AP_i 代表第 i 个目标类别的平均精度; N 代表待检测图像个数; t 代表检测时间。

3.4 模型测试

将改进 YoloX-s 与 YoloX-s, YoloX-m 进行模型比较,

结果如表 1 所示。

表 1 模型性能对比

目标检测模型	AP/%		mAP@0.75/ %	FPS/ ($f \cdot s^{-1}$)
	Moving contact	Static contact		
YoloX-s	92.23	98.60	95.42	58.19
YoloX-m	95.75	98.80	97.28	38.41
改进 YoloX-s	97.73	98.83	98.28	45.61

表 1 显示,相较于 YoloX-s 和 YoloX-m 模型,改进模型在动接点环平均精度上分别提高了 5.5%,1.98%;在静接点片平均精度上分别提高了 0.23%,0.03%;在平均精度均值上分别提高了 2.86%,1.00%。尽管改进模型的 PANet 网络后,计算成本会增加,检测速度会下降,但本文所提模型在检测速度上仍优于 YoloX-m 模型,更好地满足了实时检测要求。

密贴检查器图像检测结果如图 6 所示。结果表明所提模型在动接点环和静接点片的检测上有着更高的预测分数和检测精度。




图 6 不同状态下模型检测结果

4 结 论

为了提高密贴检查器的运维效率,降低运维成本,本文提出了一种改进 YoloX-s 的密贴检查器故障检测方法。该方法改进了 PANet 网络,增加了与浅层特征层的融合;加入了 CA 注意力模块,并改进了损失函数。测试结果表明相较于 YoloX 模型,所提模型对密贴检查器动接点环和

静接点片的检测效果更优,有着更高的分类置信度,更好的准确率、召回率,因此该模型的检测精度及定位精度均较好,能够满足密贴检查器故障检测的需求。在未来本文拟作进一步研究:通过标定相机,获取已知图片某点像素坐标到现实世界坐标的映射关系,从而获得密贴检查器动接点环打入静接点片的实际深度,判断其故障的发生概率。

参考文献

- [1] 本刊编辑部. 新时代交通强国铁路先行规划纲要[J]. 铁道技术监督, 2020, 48(9): 1-6, 24.
- [2] 蔡红标. 提速道岔尖轨与基本轨不密贴分析及整治[J]. 铁路通信信号工程技术, 2016, 13(1): 101-104.
- [3] 王驰. 浅析城市轨道交通道岔尖轨不密贴病害原因与整治[J]. 人民交通, 2018(6): 68-70.
- [4] 宁滨. 智能交通中的若干科学和技术问题[J]. 中国科学: 信息科学, 2018, 48(9): 1264-1269.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016.
- [6] 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.
- [7] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [8] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, 2018, ArXiv: 1804.02767.
- [9] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, arXiv: 2004.10934.
- [10] 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.
- [11] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [13] 许德刚, 王露, 李凡. 深度学习的典型目标检测算法研究综述[J]. 计算机工程与应用, 2021, 57(8): 10-25.
- [14] 张子健. 面向高铁接触网缺陷检测的智能图像处理关键技术研究[D]. 杭州: 浙江大学, 2019.
- [15] MA J, SHAO W, YE H, et al. Arbitrary-oriented scene text detection via rotation proposals[J]. IEEE Transactions on Multimedia, 2018, 20(11): 3111-3122.
- [16] SUN J, XIAO Z, XIE Y. Automatic multifault recognition in TFDS based on convolutional neural network[J]. Neurocomputing, 2017, 222: 127-136.
- [17] LIU Z, ZHONG J, LYU Y, et al. Location and fault detection of catenary support components based on deep learning [C]. 2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), 2018: 1-6.
- [18] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv Preprint, 2021, ArXiv: 2107.08430.
- [19] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [20] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[J]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13708-13717.
- [21] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[J]. ArXiv, 2020, abs/1911.08287.
- [22] 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: 1904-1916.
- [23] GE Z, LIU S, LI Z, et al. OTA: Optimal transport assignment for object detection[J]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 303-312.
- [24] 冯兴杰, 张志伟, 史金钊. 基于卷积神经网络和注意力模型的文本情感分析[J]. 计算机应用研究, 2018, 35(5): 1434-1436.
- [25] YU J, JIANG Y, WANG Z, et al. UnitBox: An advanced object detection network[C]. Proceedings of the 24th ACM International Conference on Multimedia, 2016: 516-520.
- [26] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 658-666.
- [27] 刘丹, 汪慧兰, 曾浩文, 等. VoVNet-FCOS 道路行人目标检测算法研究[J]. 国外电子测量技术, 2021, 40(11): 64-71.
- [28] 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.
- [29] 薄景文, 张春堂. 基于 YOLOv3 的轻量化口罩佩戴检

测算法[J]. 电子测量技术, 2021, 44(23): 105-110.

- [30] 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.

作者简介

徐哲玮, 硕士研究生, 主要研究方向为交通安全技术。

E-mail: 1317137830@qq.com

刘昭, 硕士研究生, 主要研究方向为交通信息工程及

控制。

E-mail: 1486729439@qq.com

包建东, 博士, 副教授, 主要研究方向为智能仪器与检测技术。

E-mail: baojd025@163.com

刘英舜(通信作者), 博士, 副教授, 主要研究方向为交通安全技术、交通噪音、物流技术、城市公共交通运营管理。

E-mail: yingshun@njust.edu.cn