

改进 YOLOv5s 的接触网小零件检测方法 *

何奕霏 刘晓东 赵兴 吴桐 李花

(大连交通大学詹天佑学院 大连 116000)

摘要:铁路接触网是向电力牵引车辆供电的核心设备,其状态直接影响列车运行安全。在6C系统检测接触网状态时,准确定位各类零部件的位置是首要任务。针对铁路接触网关键小零件(开口销、管套和定位器支座的螺母)因尺寸小、环境复杂导致难以精确定位的问题,提出了一种基于改进YOLOv5s的小目标检测方法。首先,将特征提取网络的C3模块与线性可变形卷积(LDConv)结合,设计出新的C3_LD模块。该模块通过可变形卷积核自适应调整感受野,有效捕捉小目标的几何形变特征,提高特征提取能力的同时降低了参数量;其次,替换原本快速空间金字塔池化(SPPF)结构设计了SPPFCSPC_group结构,通过分组卷积与多尺度空间金字塔结合,提高了网络多尺度特征表达能力;最后,将原损失函数替换为SIoU函数,通过预测框和真实框之间的空间约束来提高边界框的回归精度。消融实验和对比实验结果表明,改进后的算法在接触网小零件检测任务中实现了93.2%的平均精度均值(mAP)和93.1%的召回率,相较于原算法分别提高了1.9%和3.6%,有效缓解了接触网小零件的漏检和误检问题。

关键词:铁路接触网;小目标检测;YOLOv5;线性可变形卷积;空间金字塔结构

中图分类号: U225.4; TN911.73 文献标识码: A 国家标准学科分类代码: 520.2060

Detection method for contact mesh small parts based on improved YOLOv5s

He Yifei Liu Xiaodong Zhao Xing Wu Tong Li Hua

(School of Zhan Tianyou, Dalian Jiaotong University, Dalian 116000, China)

Abstract: Railway catenary system is the core equipment to supply power to electric traction vehicles, and its state directly affects the safety of train operation. In order to solve the problem that the key small components (split pin, tube sleeve and nut of positioner bracket) in the railway catenary are difficult to accurately locate due to their small size and complex environment, a small target detection method based on improved YOLOv5s is proposed. Firstly, the C3 module of the feature extraction network is combined with the linear deformable convolution (LDConv) to design a new C3_LD module. The proposed module employs deformable convolution kernels to dynamically adjust receptive fields, which effectively captures geometric deformation characteristics of small targets. This design not only enhances feature extraction capability but also reduces parameter. Secondly, the SPPFCSPC_group structure is designed to replace the original SPPF structure, and the multi-scale feature expression ability of the network is improved by combining group convolution with multi-scale spatial pyramid. Finally, the original loss function is replaced by spatial intersection over union (SIoU), which enhances bounding box regression accuracy through spatial constraints between predicted and ground-truth boxes. The results of ablation experiments and comparison experiments show that the improved algorithm in this paper achieves 93.2% mean average precision (mAP) and 93.1% recall rate in the detection task of railway catenary mesh small components, which are 1.9% and 3.6% higher than those of the original algorithm, which effectively alleviates the missed detection and false detection problems of railway catenary small components.

Keywords: railway catenary; small object detection; YOLOv5; linear deformable convolution; spatial pyramid structure

0 引言

作为电气化铁路的重要组成部分,接触网的工作状态直接影响着机车能否获得充足的电能。而接触网装置的零部件长期工作在复杂的室外环境,难免会发生脱落、断裂等故障,这些安全隐患将严重影响高速列车的稳定运行,日常维护接触网状态的检查尤为重要^[1-2]。接触网支撑装置的组成复杂,共包含 40 多种不同尺寸的零部件^[3]。在 2012 年我国就采用了高速铁路供电系统安全检测监测(6C 系统),其中 4C 系统是利用安装在检测车顶部上的高清摄像机对不同角度的接触网支撑零部件进行拍摄,再通过人工对照片中的接触网支撑装置零部件状态进行判别。4C 系统虽然节省了人工巡视的人力物力,但还需要人工进行筛查,人工检测容易受主观因素的影响,很可能导致接触网小零件漏检与误检^[4]。

随着技术的发展,接触网检查方法逐渐趋向智能化、自动化。深度学习的出现推动了机器视觉和人工智能等领域的深刻变革,目标检测算法也取得了显著突破。国内外研究人员正尝试将基于深度学习的目标检测算法应用于铁路接触网零部件的检测。目前,基于深度学习的目标检测算法可分 One-stage 和 Two-stage 检测算法。One-stage 目标检测算法以 SSD 和 YOLO 系列为代表。Wang 等^[5]提出了一种基于改进 YOLOv3 算法的两阶段定位开口销的方法,第 1 阶段用于定位支撑装置上的 5 个关节组件,第 2 阶段在关节组件图像中定位开口销,可以有效地解决开口销尺寸太小而难以精确定位的问题。石强等^[6]基于 YOLOX 模型,引入了卷积块注意力机制模块(convolutional block attention module, CBAM)^[7]关注图像重要区域,并设计了 SC-PAN(skip connection PAN)结构来增强特征表达能力,从而实现了 U 型抱箍开口销的精确检测。Two-stage 目标检测算法以 R-CNN、Faster R-CNN 等为代表。王昕钰等^[8]提出三级级联架构检测开口销缺陷,该架构通过 Faster R-CNN 实现定位,利用深度卷积生成对抗网络(DCGAN)扩充缺陷数据集,最后基于 VGG16 网络训练分类模型以检测开口销缺陷;顾桂梅等^[9]通过 K 均值聚类算法优化 Faster R-CNN 中区域候选网络(region proposal network, RPN)层生成的 anchor boxes 比例及面积,实现了管帽的精准定位;Tan 等^[10]提出一种基于掩膜区域卷积神经网络(MASK R-CNN)^[11]和图像处理模型的接触网智能缺陷检测算法,利用垂直投影技术实现绝缘子的单棚定位和精确切割,并通过梯度、纹理和灰度特征融合结合 K-means 聚类分析模型来检测破碎绝缘子、污垢、异物和闪络;胡代弟^[12]使用 Faster R-CNN 模型的 9 种不同尺寸比例的目标候选框进行定位,优化图像的灰度值和增益因子,并结合直方图均

衡化原理进行细节去噪处理,提高了检测开口销的准确性。

上述研究表明,现有接触网设备的缺陷检测和故障诊断方法大多属于单个零部件的分析,难以满足实际需求。此外,对于小尺寸零件的检测和定位,Two-stage 检测模型复杂、检测速度慢,而 One-stage 检测算法对小目标的识别效果较差,且改进后往往导致参数量的增加。

针对上述问题,本文提出一种基于改进 YOLOv5s 的目标检测算法,并以 3 种接触网上故障高发的小尺寸零件——开口销、管帽和定位器支座的螺母作为检测对象。本文设计 C3_LD 模块替代原本的 C3 模块,通过线性可变形核实现动态感受野调整,在减少参数量的同时提升特征提取精度;结合分组卷积(group convolution)和快速空间金字塔池化-跨阶段局部通道(spatial pyramid pooling faster cross stage partial channel, SPPFCSPC)构建的 SPPFCSPC_group 结构提高了网络多尺度特征表达能力;引入 SIoU 损失函数建立空间约束,显著提升定位精度。实验结果表明,本文改进后的 YOLOv5s 算法能实现对多种小尺寸零件的高精度检测。

1 YOLOv5 网络

YOLOv5 继承了 YOLOv1-v4 的优势,并提高了检测精度与速度。YOLOv5 的网络架构包括骨干网络(backbone)、颈部网络(neck)和头部网络(head)^[13]。YOLOv5 的网络架构如图 1 所示。

在 YOLOv5 中,骨干网络通过 CBS 模块进行基础特征提取,C3 模块在增加网络深度的同时控制计算量,SPPF 模块则通过多尺度特征融合提升尺度适应性。颈部网络采用 Upsample 上采样和 Concat 特征拼接操作,结合路径聚合机制实现跨尺度特征融合,可有效捕获大、中、小目标的语义信息。最终,检测头通过全卷积结构生成目标候选框,基于锚框机制完成分类与定位预测。

YOLOv5 供包含 4 种尺寸的网络模型,从小到大为 s、m、l 和 x,其网络结构相同^[14],准确度随着模型的大小提升,速度也随之下降。本文选择参数量最少的 YOLOv5s 作为基准模型。

2 改进 YOLOv5s 网络

2.1 改进 C3 模块

卷积核的目的是为了提取输入物的特征。二维卷积包括两个步骤:1)在输入特征映射 x 上使用规则网格 R 进行采样;2)对于输出特征图 y 上的每个位置 p_0 ,求采样值加权 w 的总和。定义如下:

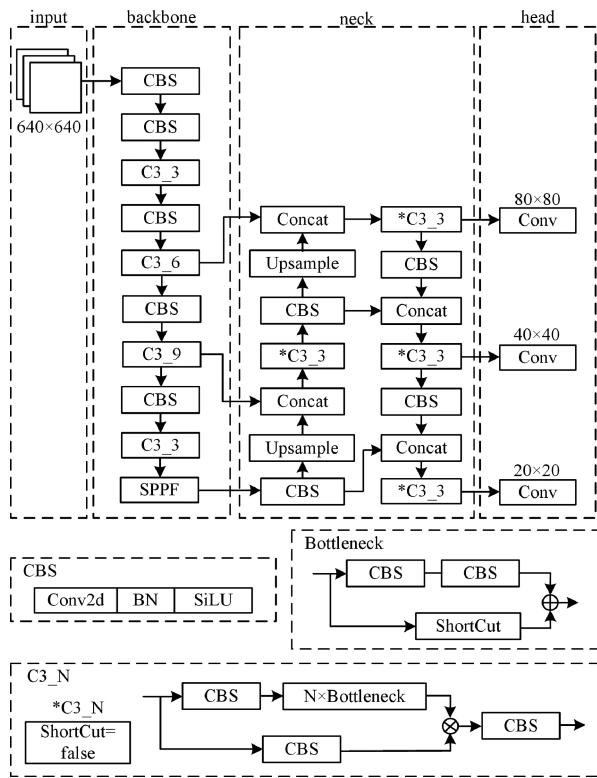


图 1 YOLOv5 算法的网络结构

Fig. 1 Network structure diagram of YOLOv5 algorithm

$$R = \{(-1, -1), (-1, 0), \dots, (0, -1), (1, 1)\} \quad (1)$$

$$y(p_0) = \sum_{p_n \in R} w(p_0) \cdot x(p_0 + p_n) \quad (2)$$

式中: p_n 为卷积核的位置; w 为卷积核。

传统卷积核的尺寸和权重通常是固定的,这种设计导致其主要问题是对于未知的变化适应性较差、泛化能力不足^[15]。

为解决此问题研究者提出了可变形卷积(deformable Conv, DConv)。可变形卷积通过动态学习采样点的偏移和权重^[16-17],如式(3)所示,可灵活调整卷积核的采样形状,从而更好地适应目标的变化,提高网络特征提取能力。

$$y(p_0) = \sum_{p_n \in R} w(p_0) \cdot x(p_0 + p_n + \Delta p_n) \cdot \Delta m_n \quad (3)$$

其中, $\{\Delta p_n | n = 1, \dots, N\}$, $N = |R|$, Δp_n 为偏移量, Δm_n 为介于 0~1 的权重系数。

但 DConv 只能定义 $k \times k$ 的卷积操作来提取特征,未能探索不同初始样本形状对网络性能的影响,而且参数量的增加呈平方级增长,导致计算复杂度上升。针对上述问题,本文引用了线性可变形卷积(linear deformable conv, LDConv)^[18]。与传统的固定采样形状相比,LDConv 通过重采样动态调整每个位置的采样形状,使卷积参数的数量呈线性上升或下降趋势,从而有效减少参数量和计算开销。以大小为 5 的卷积核为例,其结构如图 2 所示。

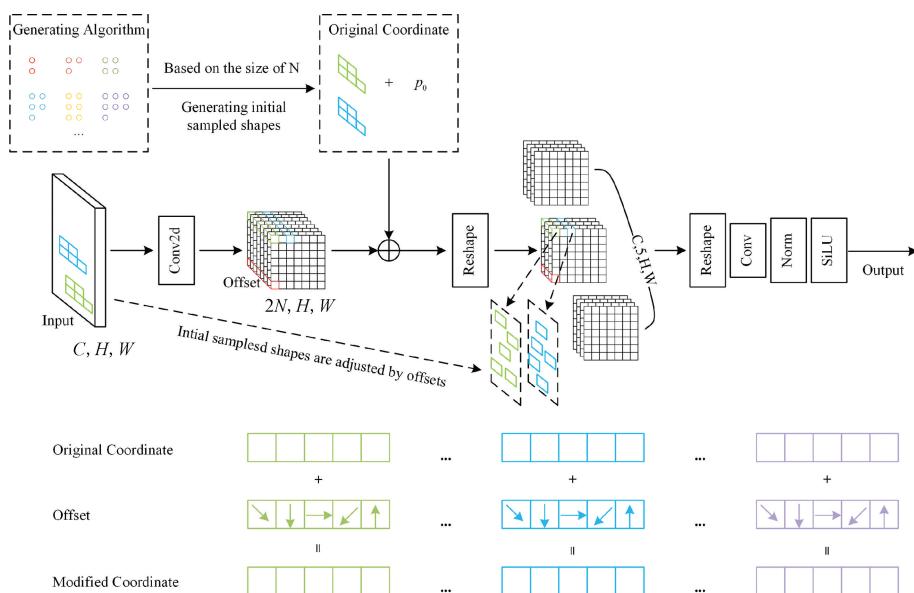


图 2 线性可变形卷积算法的结构

Fig. 2 Structure diagram of LDConv algorithm

LDConv 将初始采样坐标分配给任意大小的卷积,并通过可学习的偏移量来调整采样形状。LDConv 首先通过卷积运算生成偏移量,其运算维度为 $(B, 2N, H, W)$,其中 N 为卷积核大小。然后将偏移量和原始坐标相加,

得出调整后的采样坐标 $(p_0 + \Delta p_n)$ 为解决不规则卷积核采样位置特征提取困难的问题,将特征转换为四维张量 (C, N, H, W) ,然后利用步长和卷积大小 $(N, 1, 1)$ 的三维卷积 Conv3d 进行特征提取,降维至 (C, H, W) 。最

后在列方向上堆叠重新采样的特征,并应用大小为 $(N, 1)$ 和 $(1, N)$ 的行卷积,LDConv就可实现不规则卷积特征的提取。

检测接触网小零件过程中存在不同目标的尺寸不同的问题,LDConv通过动态调整采样形状,能有效提高模型对多尺度目标的检测精度,同时降低了模型的计算复杂度。

为进一步增强YOLOv5s特征提取能力,本文将LDConv与C3模块结合,构建新的C3_LD模块,其结构如图3所示。

2.2 改进SPPF模块

SPPFCSP^[19]融合了YOLOv5中SPPF结构高效提取尺度特征的能力和SPPCSPC模块^[20]的跨级部分通道思想,SPPCSPC模块如图4(a)所示。SPPFCSPC将SPPCSPC中的3个不同尺寸的最大池化操作统一为相

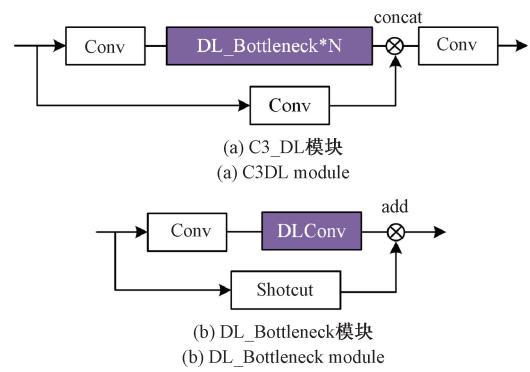


图3 C3_DL模块和DL_Bottleneck模块

Fig. 3 C3_DL module and DL_Bottleneck module

同尺寸的最大池化,在保持多尺度特征提取能力的同时简化了计算流程,其结构如图4(b)所示。

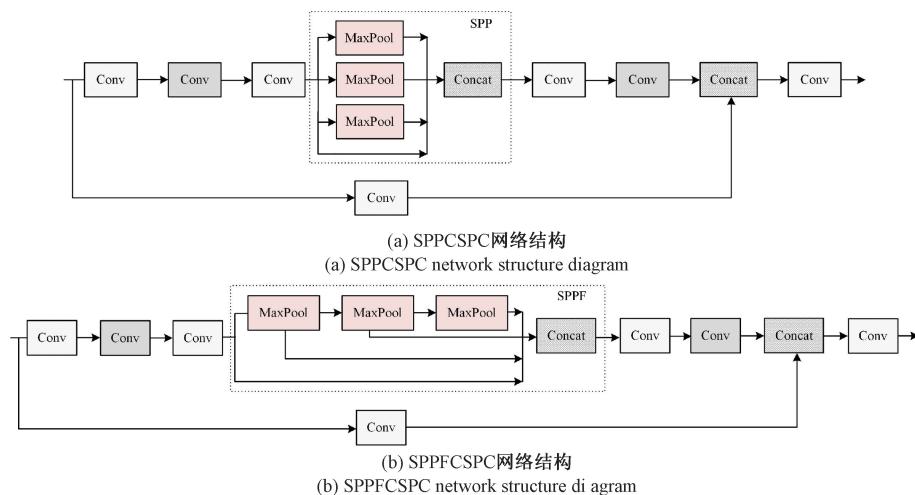


图4 空间金字塔网络结构

Fig. 4 Spatial pyramid network structure diagram

本文结合了SPPFCSPC结构和分组卷积,在增强特征融合能力的同时压缩参数,从而在保持感受野不变的情况下实现了速度提升。

分组卷积是一种卷积操作的变体,将输入和卷积核分成多个组后,每组分别进行卷积操作,最后将结果拼接起来。

假设输入特征图为 $x \in R^{C_{in} \times H \times W}$,卷积核为 $w \in R^{C_{out} \times \frac{C_{in}}{g} \times k \times k}$,群卷积 Y 的输出为:

$$Y = \text{Concat}(y_1, y_2, \dots, y_g) \quad (4)$$

式中: C_{in} 为输入特征图通道数; C_{out} 为输出特征图通道数; $k \times k$ 为卷积核大小; g 为分组数; $\frac{C_{in}}{g}$ 为每组输入的通道数。第 i ($1 \leq i \leq g$)组的输出 y_i 为:

$$y_i = x_i \cdot c_i \quad (5)$$

式中: x_i 大小为 $\frac{C_{in}}{g} \times H \times W$; w_i 大小为 $\frac{C_{in}}{g} \times \frac{C_{out}}{g} \times k \times k$ 。

标准卷积参数量为 $C_{out} \times C_{in} \times k \times k$,分组卷积参数量则为 $C_{out} \times \frac{C_{in}}{g} \times k \times k$ 。

SPPFCSPC_group模块的流程步骤如下:

1)输入特征:

$$x(B, c_1, H, W)。$$

2)分支1处理:

(1) x 依次经过卷积 $\text{Conv}(c_1, c_1, k=1, s=1, g)$, $\text{Conv}(c_1, c_1, k=3, s=1, g)$, $\text{Conv}(c_1, c_1, k=1, s=1, g)$,输出 x_1 ;

(2)多级池化:对 x_1 进行3次级联最大池化($k=5, s=1$),生成 x_2, x_3, x_4 ;

(3) 特征拼接与融合: 将 x_1, x_2, x_3, x_4 拼接, 依次经过 2 次卷积 $Conv(4c_-, c_-, k = 1, s = 1, g), Conv(c_-, c_-, k = 3, s = 1, g)$, 输出 y_1 。

3) 分支 2 处理:

x 经过卷积 $Conv(c_1, c_-, k = 1, s = 1, g)$ 输出 y_2 。

4) 最终输出:

拼接 y_1 和 y_2 , 经过卷积 $Conv(2c_-, c_2, k = 1, s = 1, g)$, 输出特征 $y(B, c_2, H, W)$ 。其中, c_1 和 c_2 分别是输入、输出特征图的通道数, $g = 4$ 为分组数, $c_- = \text{int}(2 \cdot c_2 \cdot e)$ 为隐藏通道数, (e 为扩展因子)。每个 $Conv$ 都将输入通道分为 4 组, 每组使用独立的 $k \times k$ 卷积核后输出 $1/4$ 的输入通道, 最后将所有组的输出在通道维度拼接, 计算量减少了 $1/4$ 。

原始 SPPFCPCF 结构和具有分组卷积的 SPPFCSPC 结构的参数比较如表 1 所示。从表 1 可以看出, 具有分组卷积的 SPPFCSPC 模块相较于原模块, 参数量减少了 5.31×10^6 , 计算量减少了 4.2 GFLOPs。

表 1 SPPFCSPC 和 SPPFCSPC_group 的参数

Table 1 Parameters of SPPFCSPC and SPPFCSPC-group

模型	参数量/($\times 10^6$)	计算量/GFLOPS
YOLOv5s(SPPF)	7.02	15.8
YOLOv5s+SPPFCSPC	13.46	21.1
YOLOv5s+ SPPFCSPC_group	8.15	16.9

2.3 改进损失函数 Loss

交并比(intersection over union, IoU)是一种计算两个区域重叠比例的算法, 广泛用作深度学习领域的目标检测或语义分割任务的评估指标, 定义为:

$$IoU = \frac{I_{area}}{U_{area}} \quad (6)$$

式中: I_{area} 为区域相交面积; U_{area} 为区域并集面积。

YOLOv5 采用 ClIoU Loss (complete intersection over union loss)^[21] 计算边界框损失。ClIoU Loss 考虑了预测框与真实框的重叠面积, 同时还引入了中心点距离和长宽比的相似性, 定义为:

$$L_{ClIoU} = IoU - \frac{\rho^2(b, b^{gt})}{C^2} - \alpha \cdot v \quad (7)$$

式中: b 和 b^{gt} 分别代表实际框和预测框; $\rho^2(b, b^{gt})$ 表示两个框中心点的欧氏距离; α 是权重函数; v 是用来度量长宽比的相似性。

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

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

式中: w^{gt}, w, h^{gt}, h 代表真实框、预测框的宽度和高度。

由上述公式可知, ClIoU 考虑了边界框的中心点距离、对角线距离和宽高比惩罚项, 能在一定程度上加快预测框的回归收敛过程。然而, 参考文献[22]可知, 当收敛到预测框和真实框的宽和高呈现线行比例时, 就会导致预测框回归时的宽和高无法同时增大或者减少, 从而影响回归精度。为解决这一问题, 本文采用 SIoU Loss (scylla intersection over union loss)^[23], 其通过引入向量角度, 重新定义了惩罚指标。SIoU Loss 由角度代价、距离成本、形状成本和 IoU 组成, 定义如下:

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (10)$$

式中: Δ 为距离成本; Ω 为形状成本。

距离成本计算公式如下:

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma p_t}) \quad (11)$$

$$\text{其中, } \rho_x = \left(\frac{b_{c_x}^{gt} - b_{c_x}}{c_w} \right)^2, \rho_y = \left(\frac{b_{c_y}^{gt} - b_{c_y}}{c_h} \right)^2, \gamma = 2 - \Lambda,$$

Λ 为角度代价, 公式如下:

$$\Lambda = 1 - 2 \sin^2 \left(\arcsin \left(\frac{C_h}{\rho^2(b, b^{gt})} - \frac{\pi}{4} \right) \right) = \sin 2\alpha \quad (12)$$

形状成本定义为:

$$\Omega = \sum_{t=x,y} (1 - e^{-w_t})^\vartheta \quad (13)$$

式中: ϑ 的值定义了形状成本; $w_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}; w_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}$ 。

本文采用 SIoU Loss 替换原始 ClIoU Loss。迄今为止 ClIoU 和提出其他的方法在计算边界框损失时, 都没有考虑到与实际的边界框与预测的边界框之间的方向偏差。SIoU 通过在损失函数代价中引入方向性, 加快了训练阶段的收敛速度, 推理性能更好。

最终, 本文改进的 YOLOv5 算法网络结构如图 5 所示。

3 实验结果与分析

3.1 数据集、实验环境与超参数配置

1) 数据集

本实验数据集源自我国 300 km/h 高铁接触网检测车动态采集系统。采用 labelImg 软件对图像中的检测目标进行标注, 包括水平/垂直于地面的开口销(SP_A/SP_B)、管帽(TC)、定位器支座的螺母(DB_N)和绝缘子(IST), 如图 6 所示。其中, SP_A/SP_B/TC/DB_N 为小尺寸目标, IST 作为大尺寸目标用于模拟实际检测场

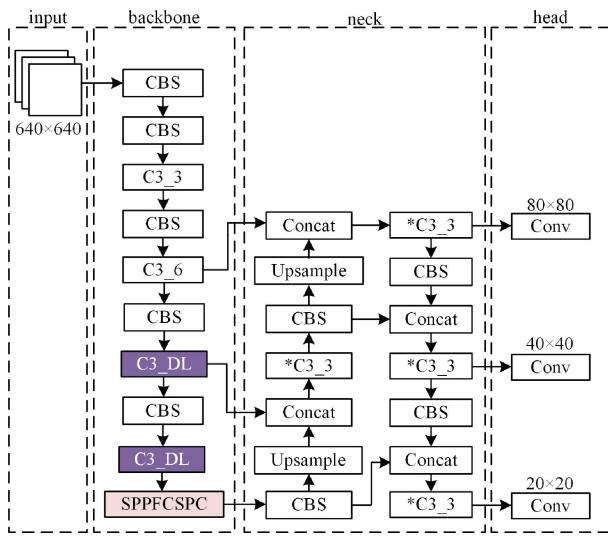


图 5 改进的 YOLOv5s 算法网络结构

Fig. 5 Network structure diagram of improved YOLOv5s algorithm

景中的尺寸差异。本文数据集共包含 2 000 张图像,按 8:2 分为训练集和验证集。

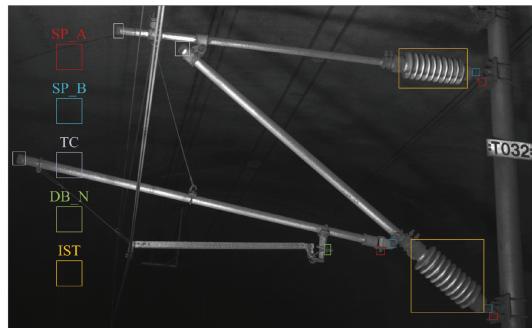


图 6 目标零件标注图

Fig. 6 Target part marking drawing

2) 实验环境配置

本文实验是在云服务器 AutoDL 上进行, 镜像环境为 python3.8、pytorch1.9、cuda11.1, 实验配置的 CPU 型号为 7 核 Intel(R) Xeon(R) CPU E5-2680 v4 @ 2.40 GHz, GPU RTX3060, 显存 12 GB。

3) 超参数配置

实验超参数配置如下: 本文使用随机梯度下降法优化参数, 学习率为 0.01, 学习率动量为 0.937, 置信度阈值为 0.5, 训练批次设置为 120, 输入图像大小为 640×640, 批数量为 4。

3.2 评价指标

本文采用召回率 (recall, R)、平均精度均值 (mean average precision, mAP)、参数量、浮点计算量和迭代完成时间 T 5 个指标对模型进行性能评估。其定义如下:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (14)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (15)$$

$$AP = \int_0^R P dR \quad (16)$$

$$mAP = \frac{\sum_{i=1}^k AP_i}{i} \quad (17)$$

式中: TP 为正识别且分类准确的零件数量; FP 为误检为其他类别的零件数量; k 为类别数; FN 为未检出到真实零件数量。召回率反应模型对 TP 的查全能力, mAP 综合评估模型在多类别场景下的检测精度。

3.3 消融实验

为验证本文提出的改进 YOLOv5s 的有效性, 在 YOLOv5s 的基础上对改进模块进行消融实验, 依次引入 C3_DL、SPPFCSPC_group 和 SIoU 改进组件, 实验结果如表 2 所示, 其中“Π”表示使用对应改进组件。

表 2 改进算法消融实验结果

Table 2 Experimental results of improved algorithm ablation

+C3_LD	+SPPFCSPC_group	+SIoU	参数量/(×10 ⁶)	mAP/%					
				SP_A	SP_B	TC	DB_N	All	
×	×	×	7.0	91	86.1	93.8	94.2	91.3	
Π	×	×	6.7	92.4	86.7	94	95.7	92.2	
Π	Π	×	7.5	92.6	87	94.3	95.9	92.5	
Π	Π	Π	7.5	93.3	88.8	94.5	96.2	93.2	
+C3_LD			计算量/ GFLOPs	T/h	R/%				
×	×	×			SP_A	SP_B	TC	DB_N	All
Π	×	×	15.8	10.14	91.2	84.1	90.9	92.1	89.5
Π	Π	×	14.6	10.01	91.5	84	91	95.2	89.7
Π	Π	Π	15.5	10.35	91.9	84.3	91.6	95.7	90.9
Π	Π	Π	15.5	10.25	92.5	87.5	95.5	97	93.1

实验结果表明,本文提出的改进算法提升了检测效果,其中 mAP 值达到 93.2%,召回率达到 93.4%,分别提升了 1.9% 和 3.6%,而且对于 YOLOv5s 检测结果中表现最差的 SP_B,改进算法提升效果最显著。C3_DL 在提升检测精度的同时还减少了模型的参数量和浮点数,实现了模型的轻量化;SPPFCSPC_group 对 mAP 和召回率的

提升都有帮助;SIoU 对 R 值的提升显著,同时还缩短了迭代完成的时间。对于大尺寸目标 IST,改进算法保持了优异的检测性能, mAP 和召回率分别保持在 99% 和 99.5%。

本文改进算法与 YOLOv5s 的检测效果如图 7 所示。

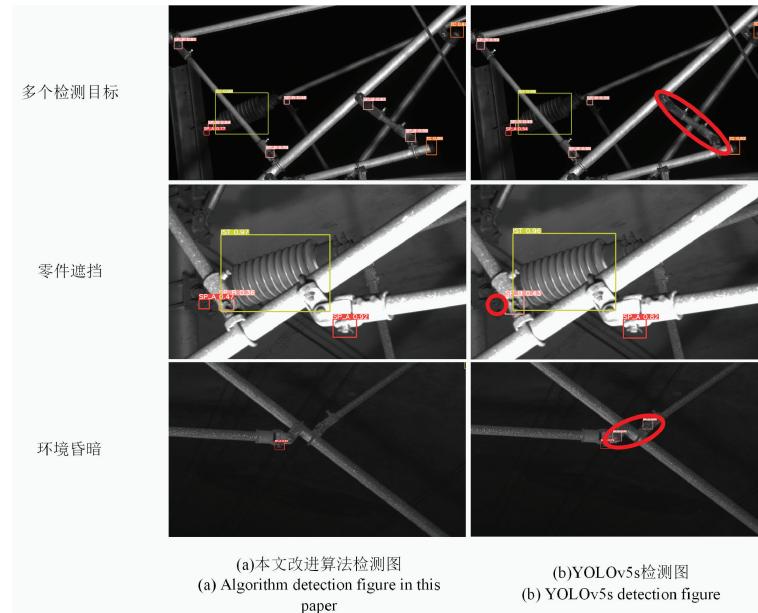


图 7 检测结果

Fig. 7 Test result diagram

当检测场景为多检测目标或有遮挡目标情况时,改进算法有效解决了漏检问题;在环境昏暗的环境下,改进算法没有出现误检的问题,而且整体的置信度都比 YOLOv5s 的高,可以看出本文改进算法在实际应用中有较好的检测效果。

3.4 对比实验

为了进一步验证本文改进算法的有效性,将其与当前主流 One-stage 目标检测算法 (SSD、YOLOv3、YOLOv5s、YOLOv8) 以及其他学者改进的 YOLO 算法 (YOLOv5s_ECA、YOLOv5s_SE、YOLOv5s_DCN) 进行了对比实验。其中, YOLOv5s_ECA、YOLOv5s_SE 和 YOLOv5s_DCN 分别为添加了通道注意力机制 (efficient channel attention, ECA)^[24]、通道注意力机制 (squeeze-and-excitation, SE)^[25] 和引入了可变形卷积 DCN 的 YOLOv5s,所有实验均在相同超参数设置下进行,实验结果如表 3 所示。

由表 3 可知,本文改进算法在 mAP 和召回率两项关键指标均达到最优,其中 mAP 值相较于 SSD、YOLOv5s、YOLOv5s_ECA、YOLOv5s_SE、YOLOv5s_DCN 和 YOLOv8 的分别高出了 17%、1.9%、1%、0.9%、0.8% 和

2.3%,召回率值分别高出了 9.3%、3.6%、2.3%、2.4%、3.4% 和 9.3%。尽管本文算法的参数量并非最低,但其综合性能优于其他算法。

表 3 将改进后的算法与其他算法进行了比较的结果

Table 3 The improved algorithm is compared with the results of other algorithms

算法	参数量/($\times 10^6$)	mAP/%	召回率/%
SSD	39.8	76.2	83.8
YOLOv5s	7.0	91.3	89.5
YOLOv5s_ECA	7.0	92.2	90.8
YOLOv5s_SE	7.5	92.3	90.7
YOLOv5s_DCN	7.1	92.4	89.7
YOLOv8	11.1	90.9	83.8
本文	7.5	93.2	93.1

4 结 论

本文针对接触网小尺寸零件检测困难的问题,提出一种改进的 YOLOv5s 算法。首先,将 YOLOv5s 的骨干网络的 C3 模块结合线性可变形卷积 LDConv,在增强特征

提取能力的同时实现了网络的轻量化;其次,将 SPPF 模块改进为 SPPFCSPC_group 模块,通过分组卷积降低参数量的同时提高了网络多尺度特征表达能力;最后,采用 SIoU Loss 替换原 CIoU Loss,通过引入方向性和形状惩罚项,加快了模型的收敛速度并提升了检测精度。实验表明,本文改进算法在接触网小零件数据集上的检测精度 mAP 与召回率分别达到 93.2% 和 93.1%,充分证明本文改进算法能满足实际检测场景的需求。

下一步工作重点是模型的轻量化,探索动态结构化剪枝与自适应量化技术,在保证检测精度的前提下研究更高效、参数更少的检测方法。

参考文献

[1] 尚晶. 高速铁路接触网检测技术 [M]. 成都: 西南交通大学出版社, 2021. 1: 1-2.

SANG J. High Speed Railway Contact Network Detection Technology [M]. Chengdu: Southwest Jiaotong University Press, 2021: 1-2.

[2] CHEN Y, SONG B, ZENG Y, et al. A deep learning-based approach for fault diagnosis of current-carrying ring in catenary system [J]. Neural Computing and Applications, 2023, 35: 23725-23737.

[3] 程敦诚, 王倩, 吴福庆, 等. 基于深度学习的接触网顶紧螺栓状态智能检测 [J]. 铁道学报, 2021, 43(11): 52-60.

CHENG D CH, WANG Q, WU F Q, et al. Research on intelligent detection of state of catenary puller bolt based on deep learning [J]. Journal of the China Railway Society, 2021, 43(11): 52-60.

[4] LI B, CUI F F. Inception module and deep residual shrinkage network-based arc fault detection method for pantograph-catenary systems [J]. Power Electron, 2022, 22: 991-1000.

[5] WANG J, LUO L F, YE W, et al. A defect-detection method of split pins in the catenary fastening devices of high-speed railway based on deep learning [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69: 9517-9525.

[6] 石强, 刘广文, 刘利民, 等. 基于改进 YOLOX 的接触网 U 型抱箍开口销检测算法 [J]. 国外电子测量技术, 2023, 42(7): 154-163.

SHI Q, LIU G W, LIU L M, et al. Detection algorithm of catenary U-shaped hoop cotter pin based on improved YOLOX [J]. Foreign Electronic Measurement Technology, 2023, 42(7): 154-163.

[7] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. Computer Vision-ECC 2018. Cham: Springer International Publishing, 2018: 3-19.

[8] 王昕钰, 王倩, 程敦诚, 等. 基于三级级联架构的接触网定位管开口销缺陷检测 [J]. 仪器仪表学报, 2019, 40(10): 74-83.

WANG X Y, WANG Q, CHENG D CH, et al. Defect detection of contact line positioning tube cotter pin based on three-stage cascade architecture [J]. Chinese Journal of Scientific Instrument, 2019, 40(10): 74-83.

[9] 顾桂梅, 陈充, 余晓宁, 等. 基于改进 Faster R-CNN 的接触网管帽目标定位算法 [J]. 激光与光电子学进展, 2022, 59(4): 132-142.

GU G M, CHEN CH, YU X N, et al. Target location algorithm for catenary tube caps based on improved Faster R-CNN [J]. Laser & Optoelectronics Progress, 2022, 59(4): 140-150.

[10] TAN P, LI X F, DING J, et al. Mask R-CNN and multifeature clustering model for catenary insulator recognition and defect detection [J]. Journal of Zhejiang University-SCIENCE A, 2022, 23(9): 745-756.

[11] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.

[12] 胡代弟. 基于 Faster-RCNN 算法的无人机高速铁路接触网开口销缺陷检测方法的研究 [J]. 电子测试, 2023, 37(2): 104-108.

HU D D. Research on the defect detection method of split pins in the high-speed railway catenary by UAV based on the Faster-RCNN algorithm [J]. Electronic Test, 2023, (2): 104-108.

[13] 郎松, 曹选, 张艳微, 等. 融合改进 YOLOv5 算法的图像全站仪全自动测量方法 [J]. 仪器仪表学报, 2022, 43(5): 120-127.

LANG S, CAO X, ZHANG Y W, et al. Fully automated measurement method of image total station based on the improved YOLOv5 algorithm [J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 120-127.

[14] 王浩然, 李廷会, 曹玉军, 等. 改进 YOLOv5s 网络在缺陷检测中的应用 [J]. 网络新媒体技术, 2022, 11(2): 58-65.

WANG H R, LI T H, CAO Y J, et al. Application of improved YOLOv5s network in defect detection [J]. Network New Media Technology, 2022, 11(2): 58-65.

[15] 陈彦蓉, 高刃, 吴文欢, 等. 改进 YOLOv5 的新能源电池集流盘缺陷检测方法 [J]. 电子测量与仪器学报, 2023, 37(5): 58-67.

CHEN Y R, GAO R, WU W H, et al. Defect detection method for new energy battery collector disc based on improved YOLOv5 network [J]. Journal of Electronic

Measurement and Instrumentation, 2023, 37(5):58-67.

[16] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 764-773.

[17] ZHU X, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308-9316.

[18] ZHANG X, SONG Y, SONG T, et al. LDConv: Linear deformable convolution for improving convolutional neural networks [J]. Image and Vision Computing, 2023, 149: 105190.

[19] KHANAM R, HUSSAIN M. What is YOLOv5: A deep look into the internal features of the popular object detector [J]. ArXiv preprint arXiv:2407.20892, 2024.

[20] 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/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.

[21] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.

[22] 宋存利, 柴伟琴, 张雪松. 基于改进 YOLOv5 算法的道路小目标检测 [J]. 系统工程与电子技术, 2024, 46(10): 1-11.

SONG C L, CHAI W Q, ZHANG X S. Road small object detection based on improved YOLOv5 algorithm [J]. Systems Engineering and Electronic Technology, 2024, 46(10): 1-11.

[23] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv: 2205.12740, 2022.

[24] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.

[25] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.

作者简介



何奕霏, 2021 年于南京邮电大学获得学士学位, 现为大连交通大学硕士研究生, 主要研究方向为图像处理。

E-mail: 1430395646@qq.com

He Yifei received her B. Sc. Degree from Nanjing University of Posts and Telecommunications in 2021. She is now a M. Sc. Candidate at Dalian Jiaotong University. Her main research interest includes image processing.



李花(通信作者), 2008 年于韩国国立釜庆大学获得工学博士学位, 现为大连交通大学詹天佑学院教授, 主要研究方向为图像处理、故障诊断。

E-mail: lihua@ djtu. edu. cn

Li Hua (Corresponding author) received her Ph. D. in Engineering from the National Korea Maritime and Ocean University (Pukyong National University) in 2008. She is now a professor at Zhan Tianyou College, Dalian Jiaotong University. Her main research interests include image processing and fault diagnosis.