

DOI: 10.13382/j.jemi.B2205682

改进 RetinaNet 的绝缘子精确定位研究

李荣铎 王国志 陶祝同

(西南交通大学机械工程学院 成都 610031)

摘要:接触网图像中绝缘子部件的自动精确定位是绝缘子故障检测的基础,绝缘子在接触网图像中存在倾角,采用水平框进行检测难以精确契合目标。针对此问题,提出一种改进 RetinaNet 的绝缘子精确定位方法。首先利用高效 Ghost 模块代替原特征提取网络中的卷积操作获得多尺度特征图,减少模型计算量;其次将注意力机制嵌入网络中,抑制次要特征对目标检测的影响;然后引入旋转框作为模型的预测框实现绝缘子精确定位,降低冗余背景噪声的干扰;最后重新定义训练过程中的正负样本,解决了添加旋转框导致学习错误样本的问题。实验结果表明,该方法可以精确地定位绝缘子,抑制冗余背景信息,与原算法相比检测精度提高 2.8%,检测速度为 25.6 FPS,参数量减少 42.8%,具有良好的检测性能。

关键词: 绝缘子;图像处理;目标检测;RetinaNet;旋转框

中图分类号: TP391; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research on insulator accurate location based on improved RetinaNet

Li Rongduo Wang Guozhi Tao Zhutong

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Automatic and accurate location of insulator components in catenary images is the basis of detecting insulator fault. The insulators in the catenary images are incline-angled, so it is difficult to locate the object accurately by using horizontal box. To solve this problem, an insulator accurate location approach was proposed based on improved RetinaNet. To begin with, the efficient Ghost module was adopted to replace the convolution operation in the original feature extraction network to obtain multi-scale feature maps and reduce the computational burden of the model. Next, in order to suppress the influence of secondary features on object detection, the attention mechanism was embedded in the network. Then, the rotating box was introduced as the prediction box of the model to realize the accurate location of insulators and reduce the interference of redundant background noise. Finally, the positive and negative samples were redefined in the training process. By doing so, the problem of learning wrong samples that caused by adding rotating box was resolved. Experimental results demonstrate that the proposed approach featuring good detection performance can locate the insulator accurately and prevent redundant background information. Compared with original algorithm, the detection accuracy increases by 2.8%, the detection speed reaches to 25.6 FPS, and the number of network parameters reduces by 42.8%.

Keywords: insulator; image processing; object detection; RetinaNet; rotating box

0 引言

随着我国铁路运行里程的增加,日益庞大的铁路网对接触网系统的可靠性提出了更高要求^[1]。绝缘子是接触网系统的重要部件,同时起结构支撑与绝缘作用^[2]。由于绝缘子长期暴露在大气环境中,易受外部因素影响

产生各种故障并威胁铁路安全,因此必须定期对绝缘子进行检测^[3]。近年来,鉴于传统的人工检测方法危险性高、效率低,国内外已逐步开展利用自动化设备及图像处理技术代替人工进行绝缘子故障检测的研究。绝缘子故障检测的关键是在图像中精确定位目标,因此,研究绝缘子的精确定位方法具有重大意义,是完成后续故障检测任务的重要基础。

目前,针对接触网部件的故障检测方法主要可分为传统图像处理方法和深度学习方法。传统图像方法基于人工构建低维特征如颜色、纹理、形状等和模板匹配^[4-6],对不同情况下的不同目标都需要重新设计,鲁棒性较弱。文献[7]利用中值滤波和频域滤波完成边缘锐化,再使用双阈值算法完成目标检测。文献[8]将图像转化为HSV格式,通过比较各分量中不同区域的特点对图像进行填充,再进行分水岭变换得到待检测区域与轮廓。文献[9]利用阈值分割去除背景干扰,然后以支架为参考将绝缘子识别转换成支架识别,最后根据绝缘子与支架间相对位置定位绝缘子。文献[10]采用HOG特征与局部二值化对绝缘子进行分割,并根据轮廓特征提取绝缘子,实现绝缘子定位。

随着深度学习的不断发展,部分学者将其引入到接触网检测领域中^[11]。文献[12]采用多层融合模块合成融合特征图,再通过多区域自适应模块增强特征,最后使用RPN(region proposal network)进行绝缘子位置预测。文献[13]通过K均值聚类算法(K-means)对锚框进行改进,改善了接触网小尺度部件的定位困难情况,在小部件检测上具有较好的表现。文献[14]将YOLOv4算法与ORB算法深度融合,还原绝缘子相对坐标,实现绝缘子准确定位。文献[15]改进Faster R-CNN算法的特征提取网络解决多尺度识别问题,并对非极大抑制算法进行优化,仿真结果表明算法可以有效识别绝缘子图像中不

同尺度的目标。

受拍摄角度和安装位置影响,大部分绝缘子图像均存在倾斜角度,采用水平预测框难以精确契合目标,对后续故障检测造成影响^[16]。针对上述问题,本文提出一种改进RetinaNet^[17]的绝缘子精确定位方法,首先采用Ghost模块轻量化特征提取网络获得多尺度特征图;然后添加卷积注意力模块(convolutional block attention module, CBAM)使网络更关注关键特征信息;最后引入旋转边界框并重新定义正负样本实现绝缘子精确定位。在自制数据集上进行训练并测试,验证本方法的有效性。

1 改进绝缘子目标检测算法

受拍摄角度、光照强度及沿线环境影响,绝缘子图像往往大不相同。在对绝缘子进行检测时需同时兼顾精度与效率,因此本文选择表现良好的一阶段目标检测模型RetinaNet作为基础框架并进行改进。如图1所示,改进RetinaNet主要由特征提取网络、特征金字塔FPN及预测网络3部分组成。整体检测流程如下:输入图片通过改进特征提取网络G_Resnet50进行特征提取得到有效特征图,特征图通过CBAM模块获得注意力权重,后经FPN完成多尺度特征融合进入预测网络,根据分类及回归结果调整锚框并预测种类得到最终预测结果。




图 1 改进模型结构

Fig. 1 Structure of improved model

1.1 改进特征提取网络

Resnet^[18]网络使用残差结构避免了随网络加深而出

现的梯度爆炸或梯度消失问题,然而大量的卷积操作在生成丰富乃至冗余的特征图同时,也占用了巨大的运算

资源。特征图的冗余是一个成功深度神经网络的重要特征,因此不必试图减少冗余映射,而是应尝试以较低成本来实现它^[19]。如图 2 所示,Ghost 模块通过 1×1 卷积和计算量很少的简单线性变换获得本征特征图和相似特征图并将它们拼接,最终得到与普通卷积操作近似的效果。




图 2 Ghost 模块

Fig. 2 Ghost module

为使模型轻量化,本文将原 Resnet50 网络的残差结构替换为如图 3 所示由 Ghost 模块组成的 G-bneck 结构。与残差结构类似,G-bneck 共有两种形式,当需要改变特征图大小时,便使用步长为 2,含有深度卷积的 G-bneck 结构;否则便使用步长为 1 的 G-bneck。将改进后的特征提取网络命名为 G_Resnet50,其参数数量为 7.796 M,仅约为原特征提取网络的 30%。




图 3 不同步长的 G-bneck 模块结构

Fig. 3 Ghost bottlenecks structure of different stride

1.2 注意力机制

特征提取网络在进行一系列卷积操作后会输出 3 个有效特征图,其中低层特征图具有更多的位置信息和较少的特征语义信息,而高层特征图则具有丰富的特征语义信息和较少的位置信息。特征金字塔 FPN 结构通过自上而下的连接和侧向连接实现特征的跨层融合,将低层特征传导到高层特征层中,减少了高层到低层特征流通所需穿越的卷积层数。同时,自上而下的连接生成粗粒度特征,自下而上的连接通过侧向连接加入细粒度特征,有效解决了多尺度目标检测问题^[20]。为了增强 FPN 的特征融合能力,使网络更加关注关键信息,本文将 CBAM 模块添加在特征提取网络的 3 个有效特征层与 FPN 间。如图 4 所示,CBAM 将通道注意力与空间注意力结合,输入特征图分别在通道与空间维度上产生注意力权重,获得需要加强或抑制的特征信息,并经过逐元素相乘后得到最后的输出特征图。




图 4 CBAM 模块结构


Fig. 4 Structure of CBAM module

设输入特征图为 F ,输出特征图为 F'' ,则 CBAM 模块的计算过程表达式为:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (1)$$


式中: M_c 表示通道注意力操作, \otimes 表示逐元素相乘; F' 表示通道注意力模块输出, M_s 表示空间注意力操作。

通道注意力模块具体流程如图 5(a) 所示,输入在分别经过基于其宽高全局最大池化和平均池化后,再通过共享 MLP 模块输出两个特征矩阵,输出的特征逐元素相加并通过 sigmoid 激活得到通道注意力权重;空间注意力模块流程如图 5(b) 所示,输入经池化操作得到两个空间特征矩阵,特征图拼接后再通过卷积及 sigmoid 激活得到空间注意力权重。



(a) 通道注意力模块

(a) Channel attention module



(b) 空间注意力模块

(b) Spatial attention module

图 5 通道注意力模块与空间注意力模块结构

Fig. 5 Structure of channel attention module and spatial attention module

1.3 旋转框与预设锚框

RetinaNet 使用水平框检测物体,但由于绝缘子存在角度,使用水平框会保留过多噪声影响后续流程,因此引入旋转框进行绝缘子精确定位。如图 6 所示,本文采用长边表示法定义旋转框,将矩形的长边和短边分别定义为 w 与 h ,角度 θ 定义为 x 轴正方向顺时针旋转到长边 w

所经过的角度,取值范围为 $[0, 180)$ 。




图 6 旋转框长边表示法

Fig. 6 Rotated box long side representation

模型的输入在经一系列特征提取和特征融合后会输出 P3~P7 五个不同大小的特征图,并在每个特征图上以特征点为中心预设大小不同的锚框以检测不同尺寸的目标。其中 P3~P7 上的预设锚框面积分别为 $\{32, 64, 128, 256, 512\}$,且每个锚框存在 3 种面积比例因子 $\{2^0, 2^{1/3}, 2^{2/3}\}$ 与 3 种长宽比例因子 $\{1:2, 1:1, 2:1\}$,即每个特征层的任意特征点上都具有 9 个不同的锚框。由于绝缘子长宽比例较为固定,因此在对真实绝缘子长宽比数据进行线性拟合后修改长宽比例因子为 $\{0.3:1\}$,并在每个预设锚框中引入 $\{0, 30, 60, 90, 120, 150\}$ 6 种角度因子进行绝缘子精确定位。每个特征点的锚框数量由原本的 9 个水平锚框变为 18 个旋转锚框,即对于 $W \times H$ 大小的特征图,一共有 $W \times H \times 18$ 个锚框,每个锚框以 $(x_a, y_a, w_a, h_a, \theta_a)$ 形式表示。

1.4 训练正负样本定义

交并比(intersection over union, IoU)常用于度量两个矩形框之间的重叠程度,训练过程中,RetinaNet 对每一个锚框与事先标注好的真实框进行 IoU 计算,若 IoU 大于 0.5 则认定锚框为正样本,若 IoU 小于 0.4 则认定为负样本,正负样本继续参与后续的训练,其余的进行舍弃。然而对于旋转矩形框,角度分量对 IoU 的计算影响较大,很容易出现锚框与真实框中心坐标及宽高近似但 IoU 小于阈值而被认定为负样本的情况,对候选框的学习不利。因此为了提高算法的检测效果,需要对正负样本重新进行定义。由于旋转框角度分量取值范围为 $[0, 180)$ 且锚框的角度设置为 $\{0, 30, 60, 90, 120, 150\}$,因此对于任意角度的真实框,每个特征点上都必然存在与其角度之差绝对值小于 15° 的锚框。将正样本重新定义为与真实框的 IoU 大于 0.5 且相对角度小于 15° 的锚框,将负样本定义为与真实框的 IoU 小于 0.4 或与真实框的 IoU 虽然大于 0.5 但相对角度大于 15° 的锚框,正负样本继续参与训练,其余的锚框进行舍弃。

1.5 预测网络与损失函数

如图 7 所示,RetinaNet 模型的有效特征图最终被送

入权值共享的预测网络来对每一个锚框进行预测,特征图在预测模块中经过 4 次连续卷积进一步提取特征,最终通过卷积层调整通道数进行类别与位置的预测。其中分类子网络负责预测每个锚框的种类置信度,最后一层通道数可表示为 $W \times H \times KA$, W 与 H 分别表示特征图的宽高; K 表示待检测目标的类别个数,本文中只有绝缘子一个类别,因此 K 取 1; A 表示预测特征层在每一个特征点上生成的锚框数量,由上文可知 $A=18$ 。位置回归子网络进行目标物体的位置预测,原 RetinaNet 只需对中心点坐标及边界框宽高进行预测,故最后一层通道数为 $W \times H \times 4A$ 。改进模型引入了旋转矩形框机制,因此需要额外预测角度变量,即需要预测 $(x', y', w', h', \theta')$ 5 个位置分量,因此最后一层通道数调整为 $W \times H \times 5A$,其中 W, H 表示特征图的宽高, A 与分类子网络中相同,预设 18。




图 7 预测网络

Fig. 7 Prediction network

由图 7 易知,RetinaNet 总损失由分类损失与位置回归损失组成,其表达式为:

$$L = \frac{\lambda_1}{N} \sum_{n=1}^N t'_n \sum_{i \in (x, y, w, h, \theta)} L_{reg}(t_{ni}', t_{ni}) + \frac{\lambda_2}{N} \sum_{n=1}^N L_{cls}(p_n, t_n) \quad (2)$$

式中: N 表示锚框总数; t_n' 表示前景/背景(当锚框为前景时 t_n' 取 1,当 t_n' 为背景时取 0); L_{reg} 表示位置回归损失; L_{cls} 表示分类损失;参数 λ_1 与 λ_2 取默认值 1。

位置回归子网络的损失 L_{reg} 通过预测框与真实框的差异进行计算。本文使用 smooth L1 函数,计算公式如下:

$$SL_1(t_i - t'_i) = \begin{cases} 0.5(t_i - t'_i)^2 & |t_i - t'_i| < 1 \\ |t_i - t'_i| - 0.5 & \text{其他} \end{cases} \quad (3)$$

式中: t_i 表示真实框与锚框的相对坐标, t'_i 表示预测框与锚框的相对坐标。

分类子网络的损失 L_{cls} 使用 Focal Loss 进行计算:

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (4)$$

$$p_t = \begin{cases} p, y = 1 \\ 1 - p, \text{其他} \end{cases} \quad (5)$$

式中: y 为真实类别; p 为 $y=1$ 的概率值; α_t 平衡正负样本,默认值取 0.25; γ 为聚焦参数,默认值取 2。

2 实验与结果分析

本实验在 Windows 系统下基于 Pytorch 框架及 Python 语言完成网络搭建并进行接触网绝缘子目标检测的训练和测试。硬件配置包括 Intel i5-10400F CPU, NVIDIA RTX3060 12 GB GPU 及 16 GB 内存, 训练和测试过程均使用 GPU 进行加速。

2.1 数据集预处理

目前网络上并没有公开的接触网绝缘子数据集, 因此对国内某铁路接触网检测图像进行人工筛选, 最终获得含绝缘子的初始数据集, 图片统一为 jpg 格式, 每张大小都是 5120×5120, 包含正定位型、反定位型、双定位型及带棘轮定位型等多种接触网形式, 背景复杂多样。为了增强模型泛化能力, 防止训练过程中过拟合, 对原始数据集随机进行包括翻转、缩放、旋转和亮度调整等数据增强方法中的一种或几种, 最终得到 2154 张含绝缘子的有效接触网图像。使用标注工具 roLabelImg 将所有图像中的绝缘子用旋转矩形框按 VOC 数据集格式精确标注, 获得包含绝缘子信息的 xml 文件, 完成绝缘子数据集制作。将扩充后的绝缘子数据集随机划分为训练集、验证集和测试集。其中训练集包含 1550 张图片, 测试集包含 431 张图片, 剩余图片用作验证集。

2.2 模型评价指标

为了对本文改进方法的可用性进行评价, 采用平均精度 AP (average precision)、单张图片检测时间 (time) 及参数量 (params) 作为模型的评估指标。计算公式为:

$$AP = \int_0^1 P(R) dR \quad (6)$$

$$\begin{cases} P = \frac{TP}{TP + FP} \\ R = \frac{TP}{TP + FN} \end{cases} \quad (7)$$

式中: TP 为正确检出的正样本数量; FP 为被错分为正样本的负样本数量; FN 为被错分为负样本的正样本数量; P、R 分别表示准确率与召回率。

2.3 模型训练与结果分析

将改进模型在自制数据集上进行训练, 训练过程中所有送入网络的图片均被压缩到分辨率为 640×640, 具体训练参数如下: 训练轮次 (epoch) 为 50, 批训练数 (batch size) 设置为 8, 采用 Adam 优化器, 初始学习率设置为 0.0005。训练过程中 loss 随 epoch 增加而变化的损失曲线如图 8 所示。从图中可以看出改进模型在训练刚开始时 loss 下降速度较原模型略慢, 当超过 25epoch 时, 两者均逐渐趋向收敛, 且改进模型最终收敛值更小。

将常见的一阶段、二阶段目标检测模型 Faster R-




图 8 损失迭代曲线

Fig. 8 Loss-epoch curve

CNN, YOLOv4 及原始 RetinaNet 在绝缘子数据集上进行与本文方法硬件配置完全相同的训练并测试, 测试结果如表 1 所示。结果表明, 改进后的 Retinanet 模型较原模型 AP 提高 2.8%, 单张检测速度为 0.039 s, 参数量大幅降低。与其他检测模型相比, 改进后的模型 AP 最高, 不但高于其他一阶段模型, 同时高于二阶段模型 Faster R-CNN; 单张检测时间与其他一阶段模型相比差别不大且远超 Faster R-CNN, 同时参数量最少。总体来说, 本文改进方法在保证速度的情况下, 精度得到提升, 同时检测效果获得了改善, 满足检测需求。图 9 为不同模型检测效果可视化。

表 1 不同网络模型对比


Model	Input size	AP/%	Time/s	Params/M
Faster R-CNN	600×600	98.8	0.081	136.689
YOLOv4	416×416	95.4	0.041	63.937
RetinaNet	600×600	96.7	0.034	36.330
Our method	640×640	99.5	0.039	20.794

结合表 1 与图 9 可以看出, 改进 RetinaNet 模型较原模型及其他检测模型检测效果更好, 更能够精确定位绝缘子; 速度稍逊于原模型可能的原因是输入图片尺寸的不同以及引入旋转框后每个特征点上预设锚框数量的变化。


3 结论

本文针对原始 RetinaNet 特征提取方法操作冗余, 无法关注有效特征信息的问题, 利用 Ghost 模块替换卷积操作, 结合 CBAM 注意力机制, 有效减少了模型的参数量, 提高了目标关键特征提取能力。再利用旋转矩形框进行绝缘子精确定位, 通过对训练过程中使用的正负样本重新定义, 增加网络候选框的学习能力, 提高了绝缘子识别定位效果。


实验结果表明, 本文提出的方法能够有效避免环境




(a) YOLOv4模型检测结果
(a) Detection results of YOLOv4



(b) RetinaNet模型检测结果
(b) Detection results of RetinaNet



(c) Faster R-CNN模型检测结果
(c) Detection results of Faster R-CNN



(d) 改进RetinaNet模型检测结果
(d) Detection results of improved RetinaNet

图 9 绝缘子检测效果示例

Fig. 9 Examples of insulator detection effect

噪声的干扰准确定位绝缘子,检测精度较原模型得到了提高并保证了检测速度,满足绝缘子目标精确检测的要求,为后续的绝缘子故障诊断研究奠定了基础。

参考文献

- [1] 孙忠国,张文轩,王卫东. 电气化铁路接触网绝缘子污闪预警检测技术综述[J]. 中国铁路, 2016(10): 68-72.
SUN ZH G, ZHANG W X, WANG W D. Review of the pollution flashover warning detection technology for insulators of electrified railway catenary [J]. China Railway, 2016(10): 68-72.
- [2] 王思华,刘阳. 考虑 CaSO₄ 溶解度的绝缘子闪络电压修正研究[J]. 铁道工程学报, 2020, 37(7): 89-94.

- WANG S H, LIU Y. Research on the flashover voltage correction of insulator considering CaSO₄ solubility [J]. Journal of Railway Engineering Society, 2020, 37(7): 89-94.
- [3] XU R H, LAI Y C, HUANG K L. Decision support models for annual catenary maintenance task identification and assignment [J]. Transportation Research Part E, 2021, 152.
- [4] 郑太雄,江明哲,冯明驰. 基于视觉的采摘机器人目标识别与定位方法研究综述[J]. 仪器仪表学报, 2021, 42(9): 28-51.
ZHENG T X, JIANG M ZH, FENG M CH. Vision based target recognition and location for picking robot: A review [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 28-51.
- [5] ABHAYARATHNE M A I M, ATTHANAYAKE I U. Automatic fabric defects inspection machine [J]. Instrumentation, 2021, 8(3): 16-25.
- [6] 罗久飞,邱广,张毅,等. 基于自适应双阈值的SURF双目视觉匹配算法研究[J]. 仪器仪表学报, 2020, 41(3): 240-247.
LUO J F, QIU G, ZHANG Y, et al. Research on speeded up robust feature binocular vision matching algorithm based on adaptive double threshold [J]. Chinese Journal of Scientific Instrument, 2020, 41(3): 240-247.
- [7] 陈明曦,侯涛,赵晏章,等. 基于新型改进 Canny 算法的轨道边缘检测研究[J]. 国外电子测量技术, 2021, 40(11): 48-52.
CHEN M X, HOU T, ZHAO Y ZH, et al. Research on rail edge detection based on new improved Canny algorithm [J]. Foreign Electronic Measurement Technology, 2021, 40(11): 48-52.
- [8] 覃乔,黄力. 基于带标记分水岭的复合绝缘子憎水性图像提取算法[J]. 电子测量技术, 2019, 42(2): 88-91.
TAN Q, HUANG L. Composite insulators' hydrophobic image extraction algorithm based on marking watershed [J]. Electronic Measurement Technology, 2019, 42(2): 88-91.
- [9] 林文文,邓斌,于兰英,等. 一种基于颜色和相关参照特征的铁路绝缘子识别方法[J]. 电瓷避雷器, 2016(6): 40-44.
LIN W W, DENG B, YU L Y, et al. Identification method for railway insulator based on color and relevant reference feature [J]. Insulators and Surge Arresters, 2016(6): 40-44.
- [10] 游诚曦. 基于接触网成像技术的绝缘子故障检测方法[J].

- 现代城市轨道交通,2019(10):5-10.
- YOU CH X. Insulator fault detection method based on OCS imaging technology [J]. Modern Urban Transit, 2019(10): 5-10.
- [11] 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.
- [12] WANG Z X, LIU X Z, PENG H Y, et al. Railway insulator detection based on adaptive cascaded convolutional neural network [J]. IEEE Access, 2021, 9: 115676-115686.
- [13] 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): 140-150.
- GU G M, CHEN CH, YU X N, et al. Target location algorithm of contact network pipe cap based on improved Faster R-CNN [J]. Laser & Optoelectronic Progress, 2022, 59(4): 140-150.
- [14] 廖国庆,吴文海,曾鑫鹏. YOLOv4 与 ORB 深度融合的绝缘子识别定位研究[J]. 电子测量与仪器学报, 2022,36(2): 131-138.
- LIAO G Q, WU W H, ZENG X P. Research on insulator identification and location based on deep fusion of YOLOv4 and ORB [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 131-138.
- [15] 杜晓亮,姜香菊. 基于改进 Faster R-CNN 的铁路接触网绝缘子识别[J]. 兰州交通大学学报,2021,40(6): 62-68.
- DU X L, JIANG X J. Railway catenary insulator identification based on improved Faster R-CNN [J]. Journal of Lanzhou Jiaotong University, 2021, 40(6): 62-68.
- [16] 张国生,冯广,李东. 基于姿态表示的航空影像旋转目标检测网络[J]. 广东工业大学学报,2021,38(5): 40-47.
- ZHANG G SH, FENG G, LI D. Pose-based oriented object detection network for aerial images [J]. Journal of Guangdong University of Technology, 2021, 38(5): 40-47.
- [17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, DOI: 10.1109/TPAMI.2018.2858826.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2016: 770-778.
- [19] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 1577-1586.
- [20] 朱佩佩,吴元,赖作镁. 一种实时多尺度目标检测识别算法[J]. 电讯技术,2022,62(5): 619-624.
- ZHU P P, WU Y, LAI Z M. A real-time multi-scale object detection and identification algorithm [J]. Telecommunications Engineering, 2022, 62(5): 619-624.

作者简介



李荣铎(通信作者),2020年于西安理工大学获得学士学位,现为西南交通大学硕士研究生,主要研究方向为机器视觉。

E-mail: 15229236216@163.com

Li Rongduo (Corresponding author) received his B. Sc. degree from Xi'an University of Technology in 2020. Now he is a M. Sc. candidate at Southwest Jiaotong University. His main research interest includes machine vision.