



计算机科学

COMPUTER SCIENCE

基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测

吴刘宸, 张辉, 刘嘉轩, 赵晨阳

引用本文

吴刘宸, 张辉, 刘嘉轩, 赵晨阳. 基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测[J]. 计算机科学, 2023, 50(6A): 220200096-7.

WU Liuchen, ZHANG Hui, LIU Jiakuan, ZHAO Chenyang. Defect Detection of Transmission Line Bolt Based on Region Attention Mechanism and Multi-scale Feature Fusion [J]. Computer Science, 2023, 50(6A): 220200096-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于动态时空神经网络的城市交通流量预测方法](#)

City Traffic Flow Prediction Method Based on Dynamic Spatio-Temporal Neural Network
计算机科学, 2023, 50(6A): 220600266-7. <https://doi.org/10.11896/jsjcx.220600266>

[面向交通流量预测的时空Graph-CoordAttention网络](#)

Spatial-Temporal Graph-CoordAttention Network for Traffic Forecasting
计算机科学, 2023, 50(6A): 220200042-7. <https://doi.org/10.11896/jsjcx.220200042>

[基于多模态特征融合的时间序列异常检测](#)

Anomaly Detection of Time-series Based on Multi-modal Feature Fusion
计算机科学, 2023, 50(6A): 220700094-7. <https://doi.org/10.11896/jsjcx.220700094>

[联合人体姿态估计和多目标跟踪的跨数据集学习](#)

Cross-dataset Learning Combining Multi-object Tracking and Human Pose Estimation
计算机科学, 2023, 50(6A): 220400199-7. <https://doi.org/10.11896/jsjcx.220400199>

[基于改进Yolov4-tiny的轻量级目标检测算法](#)

Lightweight Target Detection Algorithm Based on Improved Yolov4-tiny
计算机科学, 2023, 50(6A): 220700006-7. <https://doi.org/10.11896/jsjcx.220700006>

基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测

吴刘宸¹ 张辉² 刘嘉轩¹ 赵晨阳¹

¹ 长沙理工大学电气与信息工程学院 长沙 410000

² 湖南大学机器人学院 长沙 410000

(liuchen1019@stu.csust.edu.cn)

摘要 螺栓在输电线路中起到了固定线路间连接的作用,一旦出现松动或者脱落,就可能会导致电力传输发生故障而引起大范围停电事故。显然,定时对输电线路上的螺栓进行检测,对确保整个电力系统的安全稳定有着至关重要的作用。现有的检测方法大多基于深度卷积神经网络,然而螺栓特征不明显、尺寸小的特点给检测工作带来了挑战。针对上述问题,提出了一种基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测方法。首先,提出了适用于目标检测的区域注意模块,将该模块嵌入至ResNet50的残差块中以增强网络对螺栓的特征提取。其次,在特征金字塔结构(FPN)的基础上,扩展一条自下而上的路径,同时对浅层特征进行充分利用,以提高对小物体的检测精度。最后,为了缓解样本间的不平衡问题,引入了PrIme Sample Attention(PISA)软样本采样策略。实验结果表明,所提方法在检测输电线路螺栓时,均值平均精度(mAP)达到了74.3%,平均召回率(AR)达到了86.4%,检测速度为8.2FPS。与其他检测网络相比,所提方法在不牺牲太多检测速度的基础上,提高了对螺栓缺陷的检测精度。

关键词: 输电线路螺栓;小目标检测;注意力机制;多尺度特征融合;采样策略

中图分类号 TM933;TN919.8;TM769

Defect Detection of Transmission Line Bolt Based on Region Attention Mechanism and Multi-scale Feature Fusion

WU Liuchen¹, ZHANG Hui², LIU Jiakuan¹ and ZHAO Chenyang¹

¹ School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410000, China

² School of Robotics, Hunan University, Changsha 410000, China

Abstract Bolts play a role in fixing the connection between lines in transmission lines. Once loose or detached, it may cause power transmission failures and cause large-scale power outages. Obviously, regular inspection of bolts in transmission lines is essential to ensure the safety and stability of the entire power system. Most of the existing detection methods are based on deep convolutional neural networks. However, the unobvious features and small size of the bolts pose a challenge to the detection work. Aiming at the above problems, this paper proposes a bolt defect detection method for transmission lines based on region attention mechanism and multi-scale feature fusion. Firstly, a region attention module suitable for object detection is proposed, which is embedded in the residual block of ResNet50 to enhance the network's feature extraction for bolts. Secondly, based on the feature pyramid networks(FPN), a bottom-up path is extended, and shallow features are fully utilized to improve the detection accuracy of small objects. Finally, in order to alleviate the imbalance between samples, the PrIme Sample Attention(PISA) soft sample sampling strategy is introduced. Experimental results show that the proposed method achieves a mean average precision (mAP) of 74.3% and an average recall(AR) of 86.4% with a detection speed of 8.2 FPS when detecting transmission line bolts. Compared with other detection networks, the proposed method improves the detection accuracy of bolt defects without sacrificing too much detection speed.

Keywords Transmission line bolts, Small object detection, Attention mechanism, Multi-scale feature fusion, Sampling strategy

1 引言

巨大的电力需求促使我国输电线路的覆盖范围不断扩大。据中国电力企业联合会统计,2020年末我国输电线路回

路总长达 215×10^4 km。其中,架空输电线路是输电线路的主要形式,也是整个电力系统的动脉。而强大的电力支撑,能为国家经济的稳定发展提供有利条件,因此定时对输电线路巡检是保证电力系统稳定高效运行的重要任务。在输电线路中,

基金项目:国家重大研究计划-重点支持项目(92148204);国家重点研发计划(2018YFB1308200);国家自然科学基金(61971071,62027810,62133005);湖南省杰出青年科学基金项目(2021JJ10025);湖南省重点研发计划(2021GK4011,2022GK2011);长沙市科技重大专项(kh2003026);机器人学国家重点实验室联合开放基金(2021-KF-22-17);中国高校产学研创新基金(2020HYA06006)

This work was supported by the Major Research Plan of the National Natural Science Foundation of China(92148204), National Key R & D Program of China(2018YFB1308200), National Natural Science Foundation of China(61971071,62027810,62133005), Hunan Science Fund for Distinguished Young Scholars(2021JJ10025), Hunan Key Research and Development Program(2021GK4011,2022GK2011), Changsha Science and Technology Major Project(kh2003026), Joint Open Foundation of State Key Laboratory of Robotics(2021-KF-22-17) and China University Industry-University-research Innovation Fund(2020HYA06006).

通信作者:张辉(zhanghuihy@126.com)

螺栓作为一种紧固件被广泛应用于输电线路与各电力部件之间的连接和紧固。但由于架空输电线常年暴露在外界环境中,容易受到恶劣天气的影响,如受风力牵引使线路摆动,导致螺栓松动,甚至出现销钉和螺母缺失等异常状况,严重时可能造成大面积输电线路故障,威胁电力系统安全。因此,研究一种有效的输电线路巡检方式,精准检测出线路上有故障的螺栓并及时更换有着重要的现实意义。

图1给出了输电线路巡检的主要方式。传统输电线路巡检主要依靠人工巡检,不仅存在作业强度大、周期长、成本高的缺点,对于高山、河流、雪地等恶劣环境下的输电线路,人工方式也难以到达指定地点。同时,由于螺栓尺寸小的特点,人工攀爬式检查的方法也存在安全隐患。随着空中飞行平台的普及,直升机、无人机巡检技术以其安全、高效、便捷的特点成为电力系统输电线路检测的主要载体^[1-3]。



图1 输电线路巡检方式

Fig. 1 Transmission line inspection methods

面对拍摄到的海量巡检图像,细小的螺栓很容易使工作人员产生视觉疲劳,难免出现判断失误从而导致漏检或误检情况^[4]。因此,研究一种有效的智能图像检测技术非常有必要。近年来,目标检测技术已经在电力系统中得到充分的应用。但是,传统的基于手工设计特征的目标检测算法^[5-7],在处理螺栓这类小目标时,无法获得令人满意的检测结果。随着计算机硬件的进步和大规模数据集的应用,基于深度学习的检测方法成为了巡检图像分析的主流。目前,针对架空输电线路检测的研究大都集中于绝缘子、防鸟刺以及防震锤等大中型输电线路设备上。相比这些设备,螺栓检测显然更加棘手。图2给出了螺栓及其缺陷的典型样例,其检测难点主要如下:1)螺栓的尺寸非常小,巡检图像中单个螺栓占整个图像的比例不足1%,因此我们能提取到的螺栓的特征是非常少的;2)螺栓的分布分散使得螺栓的检测变得更加困难;3)螺栓所占据区域的面积小,导致检测中经常遇到的正负样本不平衡的问题更加凸显,在模型训练时对重要样本(Prime Sample)的关注度不够。



图2 螺栓及其缺陷示例

Fig. 2 Examples of bolts and their defects

针对上述难点,本文提出了一种基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测方法。该方法的主要贡献包括:

(1)提出了区域注意力模块,将其融合至特征提取网络来增强螺栓的特征表示。实验表明,该模块能够使网络以较少的计算内存获得具有竞争力的结果。

(2)在FPN的基础上,提出了一种多尺度特征融合结构(MF-FPN),使网络更加重视对浅层特征中信息的提取,这有利于小目标的检测。

(3)引入PISA^[8]软采样策略,通过抑制对不重要负样本的采样来增强网络对重要样本的学习,以此来缓解小目标检测中凸显的正负样本不平衡问题,并在一定程度上也缓解了输电线路螺栓数据集中存在的缺陷类别不平衡问题。

2 相关工作

早期的输电线路检测研究采用传统图像处理技术来对输电线路设备进行识别,文献[9]首先使用阈值分割结合形态学的方法分割巡检图像中的防震锤,然后计算生锈面积比和色泽指数两个参数来定义出阻尼器的锈蚀程度。Zhao等^[10]基于方向角检测和二值形状先验知识对多个不同方向角的绝缘子进行定位。对于深度学习框架,在电力行业中首先被用于检测典型的输电线路金具。Tao等^[11]采用定位器与检测器级联的方法检测绝缘子及其缺陷,检测精度达到91%。此后,Zhao等^[12]提出了一种改进的区域全卷积网络(R-FCN)检测航拍巡检图像中的绝缘子目标。文献[13]在CenterNet的基础上结合EfficientNet-B0,提出了一种新的绝缘子缺陷检测模型,检测精度得到进一步提升。文献[14]通过结合锐化滤波器与YOLOv3网络的方法检测电力巡检图像中的防鸟刺设备。

虽然输电线路巡检技术取得了重大进展,但已有方法都侧重于典型输电线路部件的检测,如绝缘子、防震锤等特征明显的部件。对于螺栓,由于其目标小的特性,难以获得满意的检测结果。近年来,小目标检测逐渐成为研究的一大热点。文献[15]在采样阶段为了使小目标被充分采样,改进RetinaNet网络中的FPN结构,使小目标得到充分训练。Liang等^[16]提出了一种基于特征融合和尺度变换的单阶段检测器(FS-SSD),用于检测无人机图像中的小目标物体。随着小目标检测技术愈发的成熟,其被应用于输电线路螺栓的检测。Zhao等^[17]构建了一种针对输电线路销钉缺失的自动视觉形状聚类网络(AVSCNet)检测模型。文献[18]针对输电线路中的销钉缺陷,在FPN的基础上,设计了PinFPN,进一步增强了底层的语义信息和位置信息,提高了检测销钉的能力。然而,目前的方法仍然存在以下不足:1)航拍图像复杂的背景信息对输电线路螺栓检测的干扰;2)螺栓有限的分辨率和特征信息易丢失的问题仍然没有得到有效解决;3)对小目标的特征提取能力亟待加强。

3 输电线路螺栓缺陷检测方法

3.1 整体框架

针对上述不足,本文提出了一种基于区域注意力机制和多尺度特征融合的检测模型,用于解决输电线路巡检中螺栓检测存在的难题。模型的整体结构如图3所示,在Faster rcnn的基础上进行了三大改进:1)融合区域注意力机制的特征提取网络;2)基于多尺度特征融合的FPN模块(MS-FPN);3)针对区域提案(RPN)后样本的采样过程,引入PISA软采样策略,增加对重要样本的关注,缓解正负样本不平衡问题,同时提高稀疏种类的检测精度。

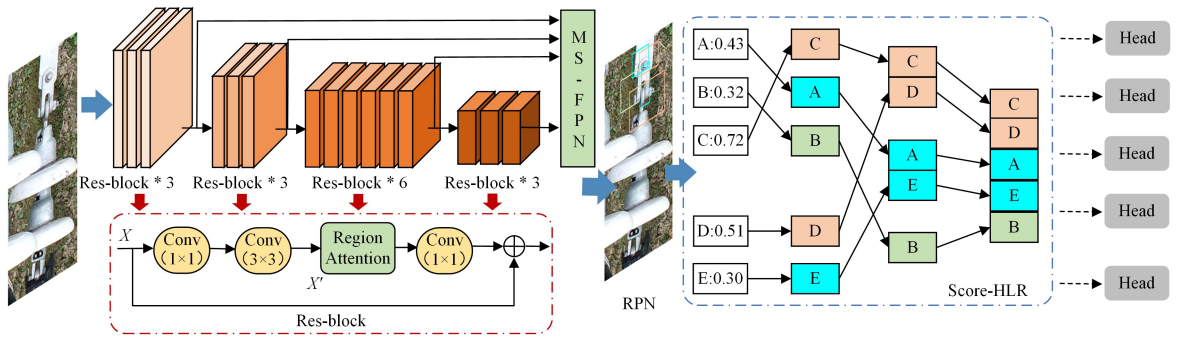


图3 基于区域注意力机制和多尺度特征融合检测模型的结构示意图(电子版为彩图)

Fig. 3 Structure of detection model based on region attention mechanism and multi-scale feature fusion

3.2 区域注意力模块

3.2.1 设计动机

在目标检测中,由于注意力的作用机制,其往往不能获得令人满意的性能提升。轻量级注意力模型(如 SENet^[19]和 CBAM^[20])通过挤压和激励特征映射来建立通道间的相互依赖关系,以提高模型对通道信息的敏感程度。虽然这种机制有助于对象的分类,但它侧重于编码图像通道间的信息,对目标位置信息的关注不够,这对目标回归是致命的。自注意力机制(如 Nonlocal^[21]和 DANet^[22])通过计算像素间嵌入特征的相似度,来聚合通道维度上的权重,以探索像素之间的关系。尽管这种方法在捕获图像中的长距离依赖性和上下文信息方面非常强大,但它通常需要相当大的计算成本。进一步考虑,螺栓只占整幅图像中的很小

一部分,如果给每个像素都计算相互间的依赖关系,则大部分计算都为背景像素与背景像素之间的关系,这对全局和局部的影响都是有限的。很显然,这种操作在目标检测中还会涉及到很多无效计算。因此,本文提出区域注意力模块,用于减少自注意力机制中由 $H \times W \times H \times W$ 操作而引起的庞大计算空间。特征分别在 X 和 Y 方向上进行聚合,生成的结果被编码到区域敏感的注意图中,以增强感兴趣区域的特征表示。

3.2.2 区域注意力模块

区域注意力模块可以看作是一个即插即用的网络操作单元,可以插入任何基于卷积的检测网络中。该模块可以在不改变输入大小和深度的情况下,输出权重变换后的特征图,结构如图4所示。

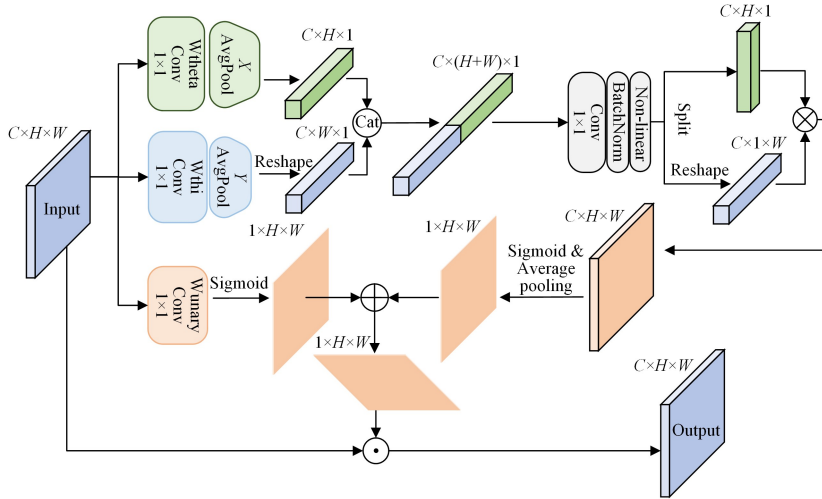


图4 区域注意力模块

Fig. 4 Region attention module

区域注意块的输入定义为 $Inputs \in R^{C \times H \times W}$ 。首先使用两个 1×1 卷积层 W_{θ} 和 W_{ϕ} 将其转换为潜在的特征空间,然后两个空间池化内核对卷积层的输出沿 X, Y 方向进行编码,编码方式可表示为:

$$P_c(h) = \frac{1}{W} \sum_{0 \leq j < W} W_{\theta} Input_c(h, i) \in R^{C \times H \times 1} \quad (1)$$

$$P_c(w) = \frac{1}{H} \sum_{0 \leq j < H} W_{\phi} Input_c(j, w) \in R^{C \times 1 \times W} \quad (2)$$

其中,下标 c 表示第 c 通道的特征。考虑到每个批次中数据分布不同,分别聚合 X, Y 方向上的数据,这很容易导致特征权重在两个方向上发生较大偏差。为了缓解这个问题,我们将编码的结果 concat 后输入至一个 1×1 的卷积层,并执行 batchnorm 操作以加速权重的收敛。此后,我们再次将特征分成两个独立的张量 $f^h \in R^{C \times H \times 1}$ 和 $f^w \in R^{C \times 1 \times W}$ 。通过该

方式,我们将原始的二维特征转化为按不同方向编码的一维特征,大大减少了模型的计算空间,然后 f^h 和 f^w 进行矩阵乘积,得到基于区域注意的特征图。特征图输入到 sigmoid 激活函数中,并使用一个空间池化内核在通道上对其进行编码,计算过程如下:

$$f_{\text{region}} = \frac{1}{C} \sum_{0 \leq c < C} \text{Sigmoid}(f_c(h) \cdot f_c(w)) \in R^{1 \times H \times W} \quad (3)$$

同时,考虑到两个一维特征张量的矩阵乘积可能会使对象的边界信息模糊,我们引入了文献[23]中的 unary 单元来建模物体的显著性边缘信息。因此,一条额外的分支被创建。在这个分支中,我们采用了一个卷积核为 1×1 ,输出通道为 1 的卷积层和一个 sigmoid 激活函数,计算式如下:

$$f_{\text{unary}} = \text{Sigmoid}(\text{Conv}_{1 \times 1}(Input)) \in R^{1 \times H \times W} \quad (4)$$

最后,对 f_{unary} 和 f_{region} 执行元素累加,然后将结果与特征 $Input$ 相乘,区域注意力模块的最终输出可以表示为:

$$Output = (f_{\text{region}} \oplus f_{\text{unary}}) \otimes Input \quad (5)$$

图 3 中的红色虚框 (Res-block) 给出了将区域注意力模块插入到 ResNet50 的残差块中的方法。

3.3 多尺度特征融合 (MS-FPN)

特征金字塔结构 (FPN) 旨在解决目标检测中存在的多尺度问题,通过充分利用卷积神经网络 (CNN) 中的特征分层结构,在基本不增加模型计算量的前提下,提升中、小物体的检测精度^[24]。然而,在面对输电线路螺栓检测时,单个螺栓在整幅图像中占据的区域不到 1%,单纯的 FPN 已不足以满足检测需求。然而我们发现 CNN 浅层特征关注的位置信息有益于小物体的检测,因此如何充分利用这些信息成为提高螺栓检测的关键。基于上述发现,我们在 FPN 的基础上提出了多尺度特征融合网络 (MS-FPN),通过在原来结构的基础上扩展一条自下而上的分支,使得浅层信息更容易传播,同时对浅层特征也进行多次利用以提高网络对小目标物体的关注能力。MS-FPN 的详细结构如图 5 所示。




图 5 多尺度特征融合金字塔网络 (MS-FPN)

Fig. 5 Multi-scale feature fusion pyramid network

图 5 中, C3—C6 代表特征提取网络中输出的 4 个特征层, C7 为 C6 特征层最大池化后所得, 特征分辨率分别为输入图像的 $1/2^i$ 。例如, 如果输入图像的分辨率是 640×640 , 则 C3 特征层的分辨率为 80×80 ($640/2^3 = 80$)。首先按照原始的 FPN 结构完成自上向下路径的搭建, 特征阶级 3~6 层输出的结果与 C3~C6 特征层进行加权特征融合。此后, 我们在此基础上完成了自下向上的路径扩展。在自下向上路径的特征融合中, 相邻阶级的特征通过一个内核为 3×3 、步长为 2 的卷积层调整至相同分辨率。最后, 针对螺栓这类小物体检测, 我们充分利用了最浅层的特征信息, 即将第 3 特征阶级的特征经过内核为 3×3 、步长分别为 2, 4, 8, 16 的 4 个卷积层后, 分别与第 4—7 特征阶级的特征相融合, 以提高对小物体的检测精度。

3.4 PISA 软样本采样策略

正负样本不平衡问题一直是目标检测中的一大难题, 尽管双阶段网络通过区域提案网络 (RPN) 剔除了大量的负样本, 但负样本的数量仍然远高于正样本数量, 尤其在面临小目标检测时, 该问题将更加凸显。为此, 我们引入了 PISA 软样本采样策略^[8], 对经过 RPN 回归后产生的 proposals 采用分层局部得分排序 (Score-HLR) 对负样本进行排序, 方法的

流程如图 3 中蓝色虚线框所示。首先使用非极大值抑制 (NMS) 将负样本分组到不同的集群中, 并将所有前景类别中的最高分数用作负样本的得分。随后, 按照分数对负样本进行降序排序。排序完后抽取每个组中的 Top1 放在最终 rank 的前面, 再抽出每个组中的 Top2 放在之前放入的 Top1 的后面, 持续上述步骤直到所有样本排序完成。采用这种方法, 网络将更加侧重于正样本和重要的负样本的学习。

在检测部分, PISA 还提出了分类感知回归损失 (CARL) 共同优化分类和回归分支, 提高重要样本的分数, 同时抑制其他不重要的样本。具体表达式如下:

$$\begin{cases} L_{\text{carl}} = \sum_{i=1}^n c_i L1(d_i, \hat{d}_i) \\ c_i = \frac{v_i}{\frac{1}{n} \sum_{i=1}^n v_i} \\ v_i = ((1-b)p_i + b)^k \end{cases} \quad (6)$$

其中, p_i 表示预测 i 样本为相应 ground truth 类别的概率, d_i 指回归分支输出的回归偏移量。指数函数将 p_i 转换为 v_i 后, 根据所有样本的平均值再对其进行重新缩放。L1 表示回归中常用的 smooth L1 损失。使用 CARL 后, 分类会受到回归损失的监督, 抑制了不重要样本的分数, 同时增强了对重要样本的关注度。

4 实验结果及分析

4.1 数据集及运行环境配置

本文所采用的数据集为输电线路螺栓数据集, 该数据集是通过使用无人机对输电线路进行近距离拍摄所得, 共包含 9752 张传输线的航空图像。其中, 9560 张图片用于网络训练, 192 张图片用于测试网络性能。所有图像使用 Labelme 软件进行标注, 标注有正常螺栓 (kkxwyc)、销钉缺失 (kkx-qs)、销钉松动 (kkxazbgf) 和螺母缺失 (lmqs) 4 种类别。

所有实验是在 Ubuntu 16.04 操作系统和 GPU 运行环境下进行的, 使用的显卡为 NVIDIA GeForce GTX1080。我们设置 8 为批处理大小, 选用 SGD 作为模型优化器。初始学习率设为 0.01, 网络共训练 36 个 epoch, 并分别在第 26 和第 32 个 epoch 时, 学习率衰减为原始的 1/10。

4.2 评价指标

模型的评价指标采用平均精度 (Average Precision, AP)、均值平均精度 (mean Average Precision, mAP)、平均召回率 (Average Recall, AR) 以及模型推理速度 (FPS), 需要注意的是在计算 AP 时, 我们设置 IoU 的阈值为 0.5。Precision, Recall 具体的计算式如下:

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$AP = \int Precision(Recall) \quad (9)$$

$$mAP = \frac{1}{N_c} \sum AP \quad (10)$$

$$AR = \frac{1}{N_c} \frac{1}{N_{IoUs}} \sum_N \sum_{N_{IoUs}} Max(Recall) \quad (11)$$

其中, TP 表示将正样本预测为正样本的数量, FP 表示将负样本预测为正样本的数量, FN 则为将正样本预测为负样本的数量。 N_c 和 N_{IoUs} 分别为所有类别和 IoUs 的数量。AP 的

值为 P-R 曲线中曲线与 x 轴中间区域的面积, mAP 则为计算所有类别的 AP 后求均值。AR 指在每幅图像中, 给定固定检测次数后的最大召回量在所有类别和 $IoUs$ 之间的平均值。FPS 指每秒传输帧数, 即模型推理时每秒处理图片的数量。

4.3 对比实验

为了验证本文方法在输电线路螺栓缺陷检测上的优越性,

我们在输电线路螺栓数据集上进行了实验, 将所提方法与当前先进的目标检测方法进行了对比, 其中包括单阶段检测网络 (SSD, YOLOv3, RetinaNet), 以及具有代表性的双阶段检测网络 (如 Faster rcnn, Cascade rcnn 和 TridentNet)。此外, 一些基于 anchor-free 的检测方法, 如 Fcos 和 Fsaf 也被用于进行对比实验。实验结果如表 1 所列。

表 1 与最先进方法的对比实验
Table 1 Comparison with state-of-the-art methods

Method	AP(%)				mAP/%	AR/%	FPS (task/s)	Params
	kxkxwyc	kxkxqs	kxkxazbgf	lmqs				
Faster rcnn	83.5	77.5	57.3	58.7	69.3	83.7	10.0	41.1×10^6
Cascadercnn	80.5	78.0	61.1	60.9	70.1	85.2	9.3	68.9×10^6
TridentNet	82.5	77.8	56.8	60.4	69.4	85.3	5.6	32.8×10^6
SSD512	76.6	75.5	49.4	58.1	64.9	80.8	14.4	24.8×10^6
YoloV3	75.5	80.1	49.6	57.0	65.6	83.9	15.7	61.5×10^6
RetinaNet	84.4	83.1	62.6	54.7	71.2	84.6	10.0	36.2×10^6
Fcos	79.4	77.0	47.5	50.5	63.6	82.5	10.7	31.8×10^6
Fsaf	83.7	77.2	51.6	50.5	65.7	74.0	10.1	36.0×10^6
Our	85.8	80.1	66.7	64.7	74.3	86.4×10^6	8.2	50.1×10^6

从表 1 中可以发现, 本文提出的模型在检测输电线路螺栓时, 与当前先进的目标检测方法相比, mAP 以及 AR 都具有明显的优势, 虽然在速度上有一些牺牲, 但与检测性能的提升相比, 这显然是能够接受的。具体而言, 相比原始的 Faster rcnn 网络, 我们仅用了 1.8FPS 的牺牲, 在 mAP 和 AR 上就分别获得了 5% 和 2.7% 的提升, 模型的参数量也只增加了 9×10^6 。继续分析表 1 还可以发现, 由于双阶段目标检测器采用了 RPN 结构采样来处理正负样本不均衡的问题, 因此表 1 中除了 RetinaNet 之外, 双阶段检测网络的检测精度和召回率普遍高于单阶段检测网络以及基于 anchor-free 的检测方法。然而, Lin 等^[25]在 RetinaNet 中提出了 focal loss, 针对性

地缓解了单阶段检测网络中的正负样本不平衡问题, 因此 RetinaNet 在针对输电线路螺栓这类小目标的检测时, 也能有很好地检测性能。TridentNet^[26]提出感受野来提高对检测任务中不同尺度大小物体的检测精度, 而螺栓检测只涉及到小尺度目标的检测, 因此 TridentNet 并不适用, 检测的 mAP 也仅比 Faster rcnn 高 0.1%。单阶段检测网络虽然检测精度不高, 但在速度上却优势明显, 能很好地满足实时检测的要求。基于 anchor-free 的方法由于小目标的特征信息少, 预测点的位置容易产生偏差, 因此在输电线路螺栓检测中检测性能最差。图 6 可视化了测试数据的检测结果。



图 6 测试数据的检测结果
Fig. 6 Test results of test data

观察图 6 可以发现,由于本文提出的模型在特征提取能力上的优秀性能,以及对输电线螺栓目标的充分训练,本文模型可以检测出其他模型无法检测出的目标,并且检测的质量更高,稳定性也更好,基本不会出现误检、漏检的情况。而对于输电线关键电力部件检测,显然误检和漏检的存在是非常致命的。具体来说,Faster rcnn,Cascade rcnn 以及 SSD 都存在误检情况,如第 1 幅测试图中,Faster rcnn 与 Cascade rcnn 将正常螺栓分别识别为了销钉缺失和销钉松动,SSD 则将第 2 幅测试图中的正常螺栓识别为了销钉松动。至于其他检测方法则都存在漏检的情况,如除了 Fcos 之外,其余方法都在第 1 幅测试图像中漏检了 1 个。Yolov3 的第 6 幅测试图以及 Fsaf 的第 4 幅测试图也都存在漏检情况。而 Fsaf 也在第 3 幅测试图像中漏检了一个。综上所述,本文提出的检测模型适用于输电线螺栓检测,其检测性能优于其他检测方法。各方法检测结果的 P-R 曲线图如图 7 所示。




图 7 各检测方法的 P-R 曲线

Fig. 7 P-R curves of each detection method

4.4 消融实验

本文提出的基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测方法包含了区域注意力机制、多尺度特征金字塔以及 PISA 软采用策略 3 个新颖的模块,为了验证这几个模块的有效性,本节执行了消融实验对它们进行对比分析。实验结果如表 2 所列。

表 2 消融实验

Table 2 Ablation experiments

Setting	PISA	Region Attention	MS-FPN	AP/%				mAP/%	FPS/(task/s)	Params
				kkxwyc	kkxqs	kkxazbgf	lmqs			
1	—	—	—	83.5	77.5	57.3	58.7	69.3	10.0	41.1×10^6
2	✓	—	—	81.9	75.7	61.5	61.8	70.2	9.6	41.1×10^6
3	✓	✓	—	84.9	79.2	64.1	63.7	73.0	8.8	44.9×10^6
4	✓	✓	✓	85.8	80.1	66.7	64.7	74.3	8.2	50.1×10^6




图 8 消融实验的损失曲线图

Fig. 8 Loss plot for ablation experiments

结束语 本文提出了一种基于区域注意力机制和多尺度特征融合的输电线路螺栓缺陷检测方法。首先,考虑到注意力昂贵的计算代价,提出了一种区域注意力模块,通过将二维特征转化为一维特征,提高目标区域的重要性得分。该模块可以插入到任何现有的卷积网络中,由于其高效的特征张量

表 2 中,从上至下我们逐渐增加了一个改进策略,从实验结果可以看出不同改进策略对检测效果的影响。实验 2 在实验 1 的基础上引入了 PISA 软采样策略,以缓解小目标检测中凸显的正负样本不平衡问题。同时 PISA 通过增强网络对重要样本的采样,在一定程度上也抑制了对样本数量多的类别的学习,从而提高了对稀疏缺陷类别的检测性能。实验结果表明,引入 PISA 采样策略后,销钉松动(kkxazbgf)和螺母缺失(lmqs)这两类数量少的缺陷类别的检测精度获得了提升,而正常螺栓(kkxwyc)以及销钉缺失(kkxqs)这两种数量多的类别的检测性能相应地受到了抑制。整体上,引入 PISA 后模型的 mAP 提高了 0.9%,由于 PISA 是一种采样策略,因此并没有增加网络的参数量,对检测速度的影响也基本没有。

与实验 2 相比,实验 3 在实验 2 的基础上,在特征提取网络即 ResNet50 中嵌入了区域注意力模块以加强对目标区域的特征提取。注意力机制通常用于突出对最终检索有积极影响的特征,本文所提出的区域注意力机制通过将二维特征转换为一维特征,使模型更加关注目标区域中的特征信息以及目标的位置信息,同时抑制了背景信息的干扰,防止焦点位置的偏移。实验结果表明,在仅增加 3.8×10^6 参数数量的前提下,模型的 mAP 获得了 2.8% 的提升,效果非常明显。

与实验 3 相比,实验 4 在实验 3 的基础上构建了多尺度特征金字塔模块,通过充分利用浅层信息来提高网络对小目标检测的能力。然而,充分利用浅层特征层,使模型的尺寸相比实验 3 中的设置增加了 5.2×10^6 ,检测速度也降低了 0.6 FPS,但 MS-FPN 模块使模型的 mAP 提高了 1.3%。经过上述实验的对比分析得出,3 种改进策略在针对输电线螺栓上是有效的。整体而言,本文方法在牺牲 1.8 FPS 检测速度的基础上,模型的 mAP 提高了 5%。图 8 给出了实验 1—实验 4 中模型训练时的损失曲线图,可以看出,实验 4 的训练损失曲线具有更快以及更加稳定的收敛速度,明显优于其他对比实验的损失曲线。

计算方式,使得网络能够以较少的计算内存获得具有竞争力的结果。其次,通过探索到卷积分层结构中的浅层特征更加关注于小物体检测的特点,提出多尺度特征融合框架,充分利用浅层特征来提高螺栓检测的精度。最后,在 RPN 结构后引入 PISA 软样本采样策略,提高对重要样本的采样关注度,缓解了正负样本不平衡以及缺陷类别不平衡的难题。实验表明,提出的螺栓缺陷检测模型的检测精度明显优于其他模型。然而,模型还不足以满足实时检测的要求。在未来的工作中,我们将继续探索提高模型检测精度以及速度的方法,进一步优化输电线路螺栓缺陷检测模型。

参考文献

- [1] SHAO G W, LIU Z, FU J, et al. Research progress in unmanned aerial vehicle inspection technology on overhead transmission lines[J]. High Voltage Engineering, 2020, 46(1): 14-22.

- [2] WU L Y, BI J G, CHANG W Z, et al. Research of Unmanned Aerial Vehicle Comprehensive Inspection for Distribution Network Overhead Transmission Lines[J]. *Electric Power*, 2018, 51(1):6.
- [3] SUIY, NING P F, NIU P J. Review on mounted UAV for transmission line inspection[J]. *Power System Technology*, 2020, 45(9):3636-3648.
- [4] GUC Y, LI Z, SHI J T, et al. Detection for Pin Defects of Overhead Lines by UAV Patrol Image Based on Improved Faster-RCNN[J]. *High Voltage Engineering*, 2020, 46(9):3089-3096.
- [5] VIOLA P, JONES M J. Robust real-time face detection[J]. *International Journal of Computer Vision*, 2004, 57(2):137-154.
- [6] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '05). IEEE, 2005:886-893.
- [7] FFELZENSZWALB P, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 32(9):1627-1645.
- [8] CAO Y, CHEN K, LOY C C, et al. Prime sample attention in object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:11583-11591.
- [9] HUANG X B, ZHANG X L, ZHANG Y, et al. A method of identifying rust status of dampers based on image processing [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(8):5407-5417.
- [10] ZHAO Z B, LIU N, WANG L. Localization of multiple insulators by orientation angle detection and binary shape prior knowledge[J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2015, 22(6):3421-3428.
- [11] TAO X, ZHANG D P, WANG Z H, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, 50(4):1486-1498.
- [12] ZHAO Z B, CUI Y P, QI Y C, et al. Detection method of insulator in aerial inspection image based on modified R-FCN[J]. *Computer Science*, 2019, 46(3):159-163.
- [13] LI F G, YILIHAMU Y, et al. Real-time Detection Model of Insulator Defect Based on Improved CenterNet [J]. *Computer Science*, 2022, 49(5):84-91.
- [14] Xinren M, Zhicheng L, Hao J, et al. Fault Detection of Power Tower Anti-bird Spurs Based on Deep Convolutional Neural Network[J]. *Power System Technology*, 2021, 45(1):126-133.
- [15] LUO Y T, JIANG P F, DUAN C, et al. Small Object Detection Oriented Improved-RetinaNet Model and Its Application[J]. *Power System Technology*, 2021, 48(10):233-238.
- [16] LIANG X, ZHANG J, ZHUO L, et al. Small object detection in unmanned aerial vehicle images using feature fusion and scaling-based single shot detector with spatial context analysis[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2019, 30(6):1758-1770.
- [17] ZHAO Z B, QI H Y, QI Y C, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(9):6080-6091.
- [18] LI X F, LIU H Y, LIU G H, et al. Transmission Line Pin Defect Detection Based on Deep Learning[J]. *Power System Technology*, 2021, 45(8):8.
- [19] 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.
- [20] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). 2018:3-19.
- [21] WANG X L, GIRSHICK R, GUPTA A, et al. Nonlocal neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:7794-7803.
- [22] FU J, LIU J, TIAN H J, et al. Dual attention network for scene segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:3146-3154.
- [23] YIN M H, YAO Z L, CAO Y, et al. Disentangled non-local neural networks[C]//European Conference on Computer Vision. Springer, 2020:191-207.
- [24] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:2117-2125.
- [25] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//Proceedings of the IEEE International Conference on Computer Vision. 2017:2980-2988.
- [26] LI Y, CHEN Y, WANG N, et al. Scale-aware trident networks for object detection[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:6054-6063.



WU Liuchen, born in 1996, B.S degree, master. His main research interests include image processing, deep learning and so on.



ZHANG Hui, born in 1963, Ph.D, professor. His main research interests include machine vision and sparse representation.