

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0832

基于 SAW-PCL 的输电线路缺销螺栓弱监督检测方法

赵振兵^{1, 2, 3, *}, 马迪雅¹, 丁洁涛⁴, 翟永杰^{3, 5}, 赵文清^{3, 5}, 张珂^{1, 2}

(1. 华北电力大学 电气与工程学院, 保定 071003; 2. 华北电力大学 河北省电力物联网技术重点实验室, 保定 071003;

3. 华北电力大学 复杂能源系统智能计算教育部工程研究中心, 保定 071003; 4. 河北远东通信系统工程有限公司,

石家庄 050200; 5. 华北电力大学 控制与计算机工程学院, 保定 071003)

摘 要: 螺栓作为输电线路中不可或缺的紧固件, 其缺销必然会引起重大的安全隐患。针对螺栓目标较小、标注难度大的问题, 提出了一种基于 SAW-PCL 的输电线路缺销螺栓弱监督检测方法。该方法通过图像级标注信息即可定位到螺栓目标。在主网络中引入卷积块注意模块 (CBAM), 抑制无用的背景特征, 提取螺栓精细特征, 提高螺栓的检测能力。针对弱监督检测中缺销螺栓的检测精度远低于正常螺栓及不平衡性问题, 提出自适应加权损失函数 (SAW), 动态调节模型对不同类别样本的学习程度, 均衡不同类别之间的检测精度, 并定义了平均类间检测精度差 (ADPD) 来评价不平衡性。构建的自适应加权损失函数可以提升缺销螺栓的检测精度, 对正常螺栓和缺销螺栓的检测精度有一定的均衡能力, 定义的 ADPD 可以评价模型检测性能的平衡度。在自建数据集 V1 上的实验结果表明: 改进方法的平均准确率均值 (mAP) 提高了 19.7%, ADPD 值降低了 21.8, 在 mAP 和 ADPD 双重指标评估下的模型表现出了更好的缺销螺栓检测能力。

关 键 词: 缺销螺栓检测; 弱监督; 平均类间检测精度差; 自适应加权损失函数; 深度学习
中图分类号: TP391.4

文献标志码: A

文章编号: 1001-5965(2024)11-3319-08

在中国新一代电力系统的发展中, 输电线路处于重要地位, 保障其可靠传输是智能电网建设和能源电力可持续发展的重要内容^[1]。螺栓作为输电线路中用来维持结构稳定性的紧固件, 长期处于风吹雨淋等恶劣环境中, 难免出现螺栓销钉脱落的情况。因此, 定期对输电线路进行巡检, 及时排查出缺销螺栓, 对电网系统的安全运行具有重大意义。

人工巡检是输电线路的传统巡检方式。输电线路沿线部分通常存在地形环境复杂、条件恶劣的地区, 使得人工巡检难度较大, 出现问题得不到及时反馈。随着电力系统规模的不断扩大, 以及深度学习等新兴人工智能算法的理论突破, 将无人机 (unmanned aerial vehicle, UAV) 巡检加入到输电

路巡检中, 使其发展成为“无人机巡检为主, 人工巡检为辅”的运维模式^[2], 大大提升了巡检效率, 可以随时了解输电线路的运行状况, 出现问题及时解决, 保障了输电线路能源的安全传输。

无人机巡检的关键技术是目标检测^[3]。相比于分类, 目标检测可以给出图像前景和背景的理解, 并从背景中分离出感兴趣的目标, 从而确定检测目标的类别信息和位置信息。Faster R-CNN^[4]、YOLO^[5-6]、SSD^[7] 等是具有代表性的深度卷积神经网络。文献 [8] 提出了一种基于区域卷积神经网络 (region-based convolutional neural network, R-CNN)^[9] 的深度学习算法来识别和裁剪图像中的螺栓, 基于霍夫变换的图像处理算法从裁剪的螺栓图像中

收稿日期: 2022-10-04; 录用日期: 2023-01-17; 网络出版时间: 2023-02-06 15:00

网络出版地址: link.cnki.net/urlid/11.2625.V.20230206.1146.001

基金项目: 国家自然科学基金 (61871182, U21A20486); 河北省自然科学基金 (F2020502009, F2021502008, F2021502013)

*通信作者. E-mail: zhaozhenbing@ncepu.edu.cn

引用格式: 赵振兵, 马迪雅, 丁洁涛, 等. 基于 SAW-PCL 的输电线路缺销螺栓弱监督检测方法 [J]. 北京航空航天大学学报, 2024, 50 (11): 3319-3326. ZHAO Z B, MA D Y, DING J T, et al. Weak supervision detection method for pin-missing bolts of transmission lines based on SAW-PCL [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (11): 3319-3326 (in Chinese).

估计螺栓角度,达到检测螺栓松动的目的。文献[10]通过更换更深层的卷积网络,改进Faster R-CNN的目标检测算法,提升了穿刺线夹及螺栓的检测精度。文献[11]通过添加时间差模块(temporal difference module, TDM)^[12]的SSD算法对具有顶紧螺栓的斜撑套筒进行小目标检测,并对斜撑套筒上的顶紧螺栓进行语义分割,构建了一种阶段性的检测算法,达到了检测顶紧螺栓缺陷的目的。文献[13]在输电线路螺栓缺陷图像分类中引入知识蒸馏技术,提出了一种基于动态监督知识蒸馏的输电线路螺栓缺陷图像分类算法,实现了对螺栓缺陷的高效分类,在大模型产生的计算资源大量消耗问题中,达到了精度与资源消耗的平衡。文献[14]基于深度卷积神经网络(deep convolution neural network, DCNN)^[15]模型,提出了一个两阶段深度学习模型,采用ResNet-101^[16]骨干提取缺陷特征,引入改进的区域方案网生成缺陷方案,通过训练一个完全卷积神经网络操作像素分割,达到检查缺失小紧固件的目的。文献[17]基于DCNN的自动视觉形状聚类方法和3种优化方法,构建了一种自动视觉形状聚类网络的缺销螺栓缺陷自动检测模型,其中,聚类部分是无监督学习,聚类后的部分是监督学习,2部分统一,达到有效检测输电线路中的缺销螺栓的目的。文献[18]针对销钉缺陷目标较小的特点,对特征金字塔进行改进得到PinNet,并设计了PinFPN用于进一步加强底层特征提取,从而达到提高模型的检测能力的目的。

螺栓图像属于小目标,特征受环境影响较大,进行数据集标注工作时需要具备相关专业知识,目标级标注过程比较困难,还会耗费大量人力和时间。综上,对缺销螺栓的弱监督检测研究具有重要意义。

弱监督检测通常依赖区域推荐算法,注意目标的显著特征,容易出现目标框不完整或目标框范围过大的情况,对目标的整体特征没有足够的辨别能力,不能满足标准目标检测要求。启用深度残留网络进行弱监督目标检测(enabling deep residual networks for weakly supervised object detection, DRN-WSOD)^[19],通过更小的卷积核和最大池化下采样,提供了更精细的目标分界,实现了小目标的弱监督检测。弱监督深度检测网络(weakly supervised deep detection network, WSDDN)^[20]通过ImageNet^[21]预训练的卷积神经网络特征去描述传统图像分析出的推荐区域特征,迫使得分最高的区域提案及其空间重叠提案特征相同,实现了一种端到端的弱监督检测任务。在线实例分类提纯(online instance classi-

fier refinement, OICR)^[22]弱监督深度检测网络通过多阶段实例分类器与基本检测网络集成,假设空间重叠提案的特征处于统一流形,使用得分最高的区域提案来生成推荐聚类,提高检测能力。区域聚类学习(proposal cluster learning, PCL)^[23]弱监督检测网络在OICR的基础上选择排名靠前的区域提案作为聚类中心,将每个提案中心作为一个小的新包,通过聚类中心的空间重叠提案生成推荐区域聚类,达到端到端训练和提高检测性能的目的。

本文在构建螺栓缺陷检测数据集时,加入正常螺栓样本作为对比特征,有利于模型更好地学习缺销螺栓特征。针对缺销螺栓检测精度远低于正常螺栓及不平衡性问题,提出了一种基于SAW-PCL的输电线路缺销螺栓弱监督检测方法,仅利用图像级标注的训练数据就能实现螺栓缺陷的目标检测,并在主网络中引入了卷积块注意模块(convolutional block attention module, CBAM)^[24],抑制无用的背景特征,提取螺栓精细特征,提高螺栓的检测能力。本文提出的自适应加权损失函数(self-adaptation weighted loss function, SAW)能动态调节模型对不同类别样本的学习程度,将注意力集中到缺销螺栓特征的学习上,提升缺销螺栓的检测精度,平衡模型对不同类别的检测性能;定义的平均类间检测精度差(average detection precision difference among classes, ADPD)评价指标,弥补了只有平均准确率均值(mean average precision, mAP)单评价指标的局限性,对模型的检测性能做出更全面的评估,在mAP和ADPD双重指标评估下的模型表现出更好的缺销螺栓检测能力。

1 SAW-PCL 模型整体框架

SAW-PCL模型如图1所示。螺栓图像经过主网络输出特征图,将主网络输出的特征图作为输入,通过CBAM模块将注意力映射到沿特征图的通道与空间2个独立的维度中,将注意力乘以输入特征映射,对输入的特征图进行自适应特征细化,得到增强特征图,同时利用选择性搜索得到候选框,将候选框和增强特征图输入到感兴趣域池化层,把不同大小的候选域特征图缩放到统一大小,经过全连接层得到候选域特征向量,分别送入多实例学习网络和实例分类提纯网络,利用本文设计的SAW指导多实例学习网络训练,动态调节样本对损失值的贡献,得到初步检测结果,实例分类提纯网络经过K层分类器后为候选框分配更合适的标签,最终利用非极大值抑制算法得到检测结果。




图 1 模型整体框图

Fig. 1 Overall block diagram of model

2 本文方法

2.1 自适应加权损失函数

从 PCL 模型在数据集 V1 上的检测结果中发现, 缺销螺栓的检测精度严重低于正常螺栓。本文希望模型在训练过程中, 使模型把更多的学习注意力转移到缺销螺栓, 提升缺销螺栓的检测精度, 使用如下加权损失函数, 达到平衡正常螺栓和缺销螺栓检测精度的目的。

$$L = -\alpha(1 - p_i) \ln p_i \tag{1}$$

式中: α 为负样本平衡系数, 取值为 0.25; p_i 为某类的得分, 值为 0~1。

由于样本非平衡性会造成损失函数倾斜, 在加权损失函数的基础上引入自适应损失值调节因子 γ , 自适应调节难易样本在总损失值中的权重, 形成自适应加权损失函数。设计的 SAW 表示为

$$L = -\alpha(1 - p_i)^\gamma \ln p_i \tag{2}$$

$$\gamma = \frac{1}{\beta(1 - p_i)} \tag{3}$$

式中: γ 为自适应损失值调节因子; $\beta > 0$, 可以控制自适应损失值调节因子 γ 的相对损耗。

当 p_i 越大时, 损失值 $1 - p_i$ 越小, 样本越容易被分类, 此时样本损失值在调节因子 γ 的作用下会大幅降低, 当样本的易分类程度越好时, 调节因子 γ 越大, 损失值降低程度越大; 当 p_i 越小时, 损失值 $1 - p_i$ 越大, 样本越不容易被分类, 样本损失值在调节因子 γ 的作用下会小幅下降, 调节因子 γ 越小, 对样本的损失值保持越好。因此, SAW 更能突出缺销螺栓在损失值中的贡献, 使模型对缺销螺栓的学

习程度更强, 提升缺销螺栓的检测精度, 此时会减少模型对正常螺栓的学习程度, 也就达到了平衡二者检测精度的目的。

2.2 平均类间检测精度差定义

通过观察 PCL 模型在数据集 V1 上的检测结果发现, 正常螺栓的检测精度远高于缺销螺栓, 表现出一种不平衡性, 此时的 mAP 不能充分说明模型对缺销螺栓的检测性能。为评价模型在数据集 V1 上检测性能的平衡度, 定义了 ADPD, 表示为

$$D = \frac{\sum_{i=0}^{N-2} \sum_{j=i+1}^{N-1} |P_i - P_j|}{C_N^2} \tag{4}$$

式中: N 为类别数, $N \geq 2$; C_N^2 表示需要作差的次数; P_i 表示编号为 i 的类别的检测精度, P_j 表示编号为 j 的类别的检测精度。

检测精度 P 指在所有被识别出的目标中识别正确的概率, 模型的检测精度越高, 误检率就越低。 P 的计算式为

$$P = \frac{T_p}{T_p + F_p} \tag{5}$$

式中: T_p 为识别正确的正样本数量; F_p 为将负样本识别成正样本的数量。

ADPD 表示所有不同类别间检测精度差值的平均值, 值越小, 说明模型在不同类别上的检测能力越是趋于相近; 值越大, 说明模型对不同类别检测能力的差距越大。

计算 ADPD 的具体过程如下: 首先, 对类别进行编号, 分别为 0, 1, ..., $N-1$; 然后, 对不同类别间检测精度作差, 如图 2 所示, 从编号 0 开始依次与大于 0 的编号作差取绝对值, 编号 0 完成后, 编号 1




图 2 计算 ADPD 作差过程

Fig. 2 Calculation of ADPD difference

按照相同的方式进行相减取绝对值,直至所有编号完成相减操作,得到 C_N^2 个值;最后,对 C_N^2 个值求平均值,即为 ADPD。

2.3 CBAM 模块

卷积运算混合了空间信息和通道信息一起提取信息特征,因此,使用 CBAM 来关注空间轴和通道轴这 2 个主要维度上的重要特征,抑制不必要特征。通过 CBAM 生成注意力的过程表示如下:

$$F' = M_C(F) \otimes F \tag{6}$$

$$F'' = M_S(F') \otimes F' \tag{7}$$

式中: $F \in \mathbf{R}^{C \times H \times W}$ 为主网络输出的特征图, C 、 H 、 W 分别为特征图的通道数、高度、宽度; $M_C \in \mathbf{R}^{C \times 1 \times 1}$ 为一维通道注意力; $M_S \in \mathbf{R}^{1 \times H \times W}$ 为二维空间注意力。

3 实验结果与分析

3.1 实验环境

本文实验环境使用的操作系统为 Ubuntu-16.04, 搭配 CPU 为 Intel Xeon E5-2620 v4, GPU 为 TITAN Xp, 编程语言使用 Python3.6, 深度学习框架为 Pytorch1.6, CUDA 为 10.1。

3.2 实验数据和评价指标

3.2.1 实验数据

在基于深度学习的电力巡检领域中,数据集尚未公开,本文构建了输电线路螺栓缺陷检测数据集 V1, 包含 1 984 张图像, 含有 2 186 个缺销螺栓和 1 363 个正常螺栓。本文以 8:2 的比例将数据集随机划分为训练集和测试集, 其中, 训练集 1 587 张图像, 测试集 397 张图像。输电线路螺栓缺陷检测数据集 V1 如表 1 所示。

本文在数据集 V1 的基础上继续做更精细的类别划分, 将缺销螺栓划分为可见销子缺失和不可见

表 1 螺栓缺陷检测数据集 V1

Table 1 Dataset V1 for pin-missing bolt detection

类别	训练集图像数量	测试集图像数量
正常螺栓	1 089	274
缺销螺栓	1 736	450


销子缺失, 构建了螺栓缺陷检测数据集 V2, 含有 827 个可见销子缺失螺栓、1 359 个不可见销子缺失螺栓和 1 363 个正常螺栓, 同样以 8:2 的比例将数据集随机划分为训练集和测试集。输电线路螺栓缺陷检测数据集 V2 如表 2 所示。

图像级和目标级标注区别如图 3 所示。因为本文探究的是输电线路缺销螺栓弱监督检测方法, 仅使用图像级标注, 所以在模型训练时依据 json 文件只提取了图像类别信息作为输入监督数据, 以向量形式表示每张图像的图像级标签。以数据集 V1 为例, 如 {1,1} 表示图像中有正常螺栓和缺销螺栓 2 类目标。

表 2 螺栓缺陷检测数据集 V2

Table 2 Dataset V2 for pin-missing bolt detection

类别	训练集图像数量	测试集图像数量
正常螺栓	1 089	274
可见销子缺失螺栓	657	170
不可见销子缺失螺栓	1 079	280



(a) 图像级标注 (b) 目标级标注

图 3 图像级和目标级标注示例

Fig. 3 Example of image-level and target-level annotation

3.2.2 评价指标

本文以每个类别平均精确率 (average precision, AP)、所有类别 mAP 和 ADPD 作为评价指标, 在测试集上对模型进行检验。

3.3 自适应加权损失函数实验

本文在数据集 V1 上进行了 SAW 实验, 不同 β 取值在测试集上 mAP 和 ADPD 值的对比如表 3 所示。可得, β 取值会对 mAP 和 ADPD 产生影响, 是因为当 β 取不同值时, 自适应损失值调节因子对样本损失值的调整程度也会不同。当 β 为 1 时, mAP 值最高, ADPD 值最低, 模型对正常螺栓和缺销螺栓的检测精度也最相当, 后续实验中将 β 取值为 1。

β 为 1 时, SAW-PCL 模型与 PCL 模型、使用加权损失函数的 PCL 模型在数据集 V1 测试集上 mAP 和 ADPD 值对比如表 4 所示。通过观察表 4 数据发现, SAW-PCL 弱监督模型在数据集 V1 上对缺销螺栓的检测精度比使用加权损失函数的 PCL 模型提升了 8.1%, 是 PCL 模型的 4 倍多。这是因为 SAW

表 3 不同 β 取值在测试集上 mAP 和 ADPD 对比

Table 3 Comparison of mAP and ADPD on test set with different β values

β	AP/%		mAP/%	ADPD
	正常螺栓	缺销螺栓		
5	37.8	11.2	24.5	26.6
4	40.1	11.2	25.7	28.9
3	31.5	10.1	20.8	21.4
2	20.8	9.0	14.9	11.8
1	34.3	24.2	29.2	10.1

表 4 不同损失函数在测试集上 mAP 和 ADPD 对比

Table 4 Comparison of mAP and ADPD of different loss functions on test set

方法	AP/%		mAP/%	ADPD
	正常螺栓	缺销螺栓		
PCL模型	33.3	6.0	19.6	27.3
PCL模型+ 加权损失函数	49.2	16.1	32.7	33.1
SAW-PCL模型	34.3	24.2	29.2	10.1

大幅降低了较易识别的正常螺栓的损失值,把更多的学习注意力放在缺销螺栓上,保持缺销螺栓损失值,提高了缺销螺栓在总损失值中的占比,使模型把更多的学习注意力转移到缺销螺栓。但是,此时正常螺栓相比于使用加权损失函数模型却是降低的,这是因为正常螺栓相较于缺销螺栓更容易识别,自适应损失值调节因子过分降低了正常螺栓的损失值,使模型减弱了对正常螺栓的学习能力。

通过观察不同方法下 mAP 值和 ADPD 值,发现使用自适应加权损失函数后,ADPD 值远低于 PCL 模型和使用加权损失函数的 PCL 模型,说明 SAW 在螺栓数据集 V1 上对正常螺栓和缺销螺栓的检测能力有一定的均衡能力。

再结合 mAP 值作进一步讨论,当使用加权损失函数时,mAP 值最高,正常螺栓检测精度为 49.2%,缺销螺栓的检测精度仅有 16.1%,模型对缺销螺栓的检测能力远低于正常螺栓。可见,当 mAP 值作为唯一评价指标时,其局限性很大,并不能充分说明模型对缺销螺栓的检测能力。当使用 SAW 时,mAP 值为 29.2%,比使用加权损失函数时降低了 3.5%,但其 ADPD 值却远低于使用加权损失函数时的 ADPD 值,仅为 10.1,在所有方法中处于最低值,此时的缺销螺栓检测精度达 24.2%,在所有方法中处于最高值。因此,当综合考虑 mAP 和 ADPD 指标时,SAW-PCL 模型在数据集 V1 上对缺销螺栓的检测能力最强。说明 ADPD 和 mAP 双重指标下的 PCL 模型在数据集 V1 上表现出更好的螺栓缺

陷检测能力,也更符合电力视觉部件缺陷检测的需求。

使用 β 为 1 时的 SAW-PCL 模型与 PCL 模型在数据集 V2 上进行测试,mAP 值和 ADPD 值对比如表 5 所示。通过观察数据集 V2 上不同方法的 mAP 值和 ADPD 值的测试结果发现,使用 SAW 后,正常螺栓 AP 值为 35.8%,比 PCL 模型高了 11.5%,可见销子缺失螺栓 AP 值为 28.2%,比 PCL 模型高了 21.9%,不可见销子缺失螺栓 AP 值为 21.6%,比 PCL 模型高了 3.4%,整体 mAP 值为 28.5%,比 PCL 模型高了 12.2%,ADPD 值比 PCL 模型低了 2.5,整体性能有了大幅提升,说明 SAW 可以提升螺栓的检测精度,对正常螺栓和缺销螺栓的检测精度也有一定的均衡能力,进一步验证了本文方法的鲁棒性。

在模型上添加 CBAM^[24] 模块后,在数据集 V1 测试集上 mAP 和 ADPD 值的对比如表 6 所示。在 CBAM 的基础上结合 SAW 对 PCL 模型进行训练,结果显示,正常螺栓的检测精度提升了 2.2%,达到了 42.0%,缺销螺栓的检测精度有大幅提升,提升了 28.7%,达到了 36.5%,ADPD 值降低了 26.5,仅为 5.5,同时,与基线模型相比,mAP 提升了 19.7%,ADPD 降低了 21.8,进一步说明通过 CBAM 模块产生的增强特征图对螺栓目标相关区域关联性更强,能进一步抑制背景信息的干扰,突出螺栓目标特征,提升缺销螺栓的检测精度,平衡模型对不同类别的检测精度。

表 5 在数据集 V2 上 mAP 和 ADPD 对比

Table 5 Comparison of mAP and ADPD on dataset V2

方法	AP/%			mAP/%	ADPD
	正常螺栓	可见销子 缺失螺栓	不可见销子 缺失螺栓		
PCL模型	24.3	6.3	18.2	16.3	12.0
SAW-PCL模型	35.8	28.2	21.6	28.5	9.5

表 6 在模型上添加 CBAM 模块进行的实验结果对比

Table 6 Comparison of experimental results by adding CBAM to model

方法	AP/%		mAP/%	ADPD
	正常螺栓	缺销螺栓		
PCL模型+CBAM	39.8	7.8	23.8	32.0
SAW-PCL模型+CBAM	42.0	36.5	39.3	5.5

使用 PCL 模型的分类损失曲线如图 4 所示。当迭代次数到达 33 000 次时,模型达到收敛。

使用添加加权损失函数的 PCL 模型分类损失曲线如图 5 所示。当迭代次数到达 28 000 次时,模

型达到收敛,相比于 PCL 模型提前了 5 000 次,加快了模型的收敛速度。

使用 β 为 1 时的 SAW-PCL 模型分类损失曲线如图 6 所示。当迭代次数到达 19 500 次时,模型达到了收敛,相比于添加加权损失函数的 PCL 模型提前了 8 500 次,相比于 PCL 模型提前了 13 500 次,说明 SAW 不仅能提高缺销螺栓的检测精度,平衡类别间的检测精度,还能加快模型的收敛速度。




图 4 PCL 模型的分​​类损失曲线

Fig. 4 Classification loss curve of PCL model




图 5 使用加权损失函数的分类损失曲线

Fig. 5 Classification loss curve using weighted loss function




图 6 SAW-PCL 模型的分​​类损失曲线

Fig. 6 Classification loss curve of SAW-PCL model

图 7 为本文方法与基线模型 PCL 在数据集 V1 测试集上的检测效果对比,绿色框表示正常螺栓,红色框表示缺销螺栓。通过观察发现,第 1 组和第 4 组中基线模型有明显的漏检情况,本文方法得到的检测框虽然不是非常精准,但检测出了基线模型中被漏检螺栓,缓解了漏检的情况;从第 2 组和第 3 组可以看出,本文方法得到的检测框贴合度更好,精确度更高。




图 7 本文方法与 PCL 模型的螺栓图像检测效果对比
Fig. 7 Comparison of bolt image detection effects based on the proposed method and PCL model

4 结 论

- 1) 针对螺栓目标较小、标注难度大的问题,提出了一种基于 SAW-PCL 的弱监督检测方法,通过图像级标注信息即可定位到螺栓目标。通过分析模型在数据集 V1 上的检测结果发现,模型存在正常螺栓 AP 值远高于缺销螺栓,对正常螺栓和缺销螺栓的检测能力表现出很严重的不平衡性。本文定义了 ADPD 来评价这种不平衡性,提出一种 SAW,自适应调节样本的损失值,平衡模型对不同类别样本的学习程度。
- 2) 对缺销螺栓进一步划分为可见销子缺失螺栓和不可见销子缺失螺栓,构建数据集 V2,在数据集上的实验结果进一步验证了本文方法的鲁棒性。
- 3) 在数据集 V1 上的实验结果表明,构建的 SAW 可以提升缺销螺栓的弱监督检测能力,对正常螺栓和缺销螺栓的检测精度有一定的均衡能力,添加的 CBAM 模块有助于提高螺栓的检测精度,改进后方法的 mAP 提高了 19.7%,ADPD 值降低了 21.8。

参考文献 (References)

[1] 雷朝煜,郝良收,戴甲水,等. 高压直流输电线路故障定位研究综述[J]. 电力系统保护与控制, 2022, 50(11): 178-187.

LEI Z Y, HAO L S, DAI J S, et al. A review of fault location methods in HVDC transmission lines[J]. *Power System Protection and Control*, 2022, 50(11): 178-187(in Chinese).

[2] 刘传洋, 吴一全. 基于深度学习的输电线路视觉检测方法研究进展[J]. *中国电机工程学报*, 2023, 43(19): 7423-7445.

LIU C Y, WU Y Q. Research progress of vision detection methods based on deep learning for transmission lines[J]. *Proceedings of the CSEE*, 2023, 43(19): 7423-7445(in Chinese).

[3] 蒲良, 张学军. 基于深度学习的无人机视觉目标检测与跟踪[J]. *北京航空航天大学学报*, 2022, 48(5): 872-880.

PU L, ZHANG X J. Deep learning based UAV vision object detection and tracking[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(5): 872-880(in Chinese).

[4] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.

[5] 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*. Piscataway: IEEE Press, 2016: 779-788.

[6] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2017: 6517-6525.

[7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]//*Proceedings of the European Conference on Computer Vision*. Berlin: Springer, 2016: 21-37.

[8] TA Q, HUYNH T, QUANG Q, et al. Corrosion and bolt-loosening monitoring using image-based deep learning and Hough transform [C]//*Proceedings of the 2020 World Congress on Advances in Civil, Environmental, and Materials Research and the 2020 Structures Congress*. Seoul: IASEM, 2020.

[9] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(1): 142-158.

[10] 薛阳, 吴海东, 张宁, 等. 基于改进 Faster R-CNN 输电线路穿刺线夹及螺栓的检测[J]. *激光与光电子学进展*, 2020, 57(8): 081008.

XUE Y, WU H D, ZHANG N, et al. Detection of insulation piercing connectors and bolts on the transmission line using improved Faster R-CNN[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081008(in Chinese).

[11] 罗隆福, 叶威, 王健. 基于深度学习的高铁接触网顶紧螺栓的缺陷检测[J]. *铁道科学与工程学报*, 2021, 18(3): 605-614.

LUO L F, YE W, WANG J. Defect detection of the puller bolt in high-speed railway catenary based on deep learning[J]. *Journal of Railway Science and Engineering*, 2021, 18(3): 605-614(in Chinese).

[12] WANG L M, TONG Z, JI B, et al. TDN: Temporal difference networks for efficient action recognition[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2021: 1895-1904.

[13] 赵振兵, 金超熊, 戚银城, 等. 基于动态监督知识蒸馏的输电线路螺栓缺陷图像分类[J]. *高电压技术*, 2021, 47(2): 406-414.

ZHAO Z B, JIN C X, QI Y C, et al. Image classification of transmission line bolt defects based on dynamic supervision knowledge distillation[J]. *High Voltage Engineering*, 2021, 47(2): 406-414(in Chinese).

[14] XIAO L, WU B, HU Y M. Missing small fastener detection using deep learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 3502209.

[15] KIM Y. Convolutional neural networks for sentence classification [C]//*Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Stroudsburg: ACL, 2014: 1746-1751.

[16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 770-778.

[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: 6080-6091.

[18] 李雪峰, 刘海莹, 刘国华, 等. 基于深度学习的输电线路销钉缺陷检测[J]. *电网技术*, 2021, 45(8): 2988-2995.

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): 2988-2995(in Chinese).

[19] SHEN Y H, JI R R, WANG Y, et al. Enabling deep residual networks for weakly supervised object detection[C]//*Proceedings of the European Conference on Computer Vision*. Berlin: Springer, 2020: 118-136.

[20] BILEN H, VEDALDI A. Weakly supervised deep detection networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2016: 2846-2854.

[21] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.

[22] TANG P, WANG X G, BAI X, et al. Multiple instance detection network with online instance classifier refinement[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE Press, 2017: 3059-3067.

[23] TANG P, WANG X G, BAI S, et al. PCL: Proposal cluster learning for weakly supervised object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(1): 176-191.

[24] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision*. Berlin: Springer, 2018: 3-19.

Weak supervision detection method for pin-missing bolts of transmission lines based on SAW-PCL

ZHAO Zhenbing^{1, 2, 3, *}, MA Diya¹, DING Jietao⁴, ZHAI Yongjie^{3, 5}, ZHAO Wenqing^{3, 5}, ZHANG Ke^{1, 2}

- (1. Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China;
- 2. Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China;
- 3. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, North China Electric Power University, Baoding 071003, China;
- 4. Hebei Far East Communication System Engineering Co., Ltd., Shijiazhuang 050200, China;
- 5. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Bolt is an indispensable fastener in the transmission line, and a pin-missing bolt will inevitably cause major safety hazards. Since the bolt target is small, and the annotation is difficult, a weak supervision detection method for pin-missing bolts of transmission lines based on SAW-PCL was proposed, and the bolt target could be located through image-level annotation information. The convolutional block attention module (CBAM) was introduced into the main network to suppress useless background features, extract fine features of bolts, and improve the detection capability of bolts. In view of the imbalance problem that the detection accuracy of the pin-missing bolt was far lower than that of the normal bolt in the weak supervision detection, an self-adaptation weighted loss function (SAW) was proposed to dynamically adjust the learning degree of the model for different categories of samples, balance the detection accuracy between different categories, and focus on the problem of pin-missing bolts. Moreover, the average detection precision difference among classes (ADPD) was defined to evaluate this imbalance. The constructed SAW could improve the detection accuracy of pin-missing bolts and had a certain ability to balance the detection accuracy of normal bolts and pin-missing bolts. The defined average detection precision difference among classes could be used to evaluate the balance of the detection performance of the model. The experimental results on the self-built dataset V1 show that the mean average precision (mAP) of the improved algorithm is increased by 19.7%, and the ADPD value is reduced by 21.8. The model under the evaluation of indexes mAP and ADPD shows better detection ability of pin-missing bolts.

Keywords: pin-missing bolt detection; weak supervision; average detection precision difference among classes; self-adaptation weighted loss function; deep learning

Received: 2022-10-04; Accepted: 2023-01-17; Published Online: 2023-02-06 15:00
URL: link.cnki.net/urlid/11.2625.V.20230206.1146.001
Foundation items: National Natural Science Foundation of China (61871182,U21A20486); Natural Science Foundation of Hebei Province (F2020502009, F2021502008,F2021502013)
* Corresponding author. E-mail: zhaozhenbing@ncepu.edu.cn