

DOI:10.20033/j.1003-7241.(2026)01-0058-06

基于 Faster R-CNN 的气体绝缘开关设备 X 光图像缺陷检测

高飞¹, 朱正一², 马龙华³, 赵海峰³, 邢正根³

(1. 中国电力科学研究院有限公司, 北京 100192; 2. 国网上海市电力公司, 上海 200122;

3. 南京优能特电力科技发展有限公司, 江苏 南京 210000)

摘要: 研究设计了一种基于 Faster R-CNN 的气体绝缘开关设备 X 光图像缺陷检测方法。该方法通过 X 光机获取气体绝缘开关设备 X 光图像, 然后构建 Faster R-CNN 检测模型, 并通过添加特征融合和优化激活函数的方法对原模型进行改进, 最后利用改进的 Faster R-CNN 检测模型对气体绝缘开关设备 X 光图像进行检测。结果显示, 该模型的检测精度高达 99.6%, 检测单张 X 光图的用时约为 0.0027 s, 并且运行稳定, 帧率约为 16.5 帧/s。研究方法能够实现对气体绝缘开关设备 X 光图像的高精度检测, 提高了电力设备运行过程的质量控制和效率。

关键词: 电力系统; 气体绝缘开关设备; 神经网络; 检测精度; 电气工程

中图分类号: TP183; TP391.41

文献标志码: A

文章编号: 1003-7241(2026)01-0058-06

X-ray image defect detection of gas insulated switchgear equipment based on Faster R-CNN

GAO Fei¹, ZHU Zhengyi², MA Longhua³, ZHAO Haifeng³, XING Zhenggen³

(1. China Electric Power Research Institute, Beijing 100192, China;

2. State Grid Shanghai Electric Power Company, Shanghai 200122, China;

3. Nanjing Unitech Electric Power Technology Development Co., Ltd., Nanjing 210000, Jiangsu, China)

Abstract: A defect detection method for X-ray images of gas insulated switchgear equipment based on Faster R-CNN is studied and designed. This method obtains X-ray images of gas insulated switchgear equipment through X-ray machines, constructs a Faster R-CNN detection model, and improves the original model by adding feature fusion and optimizing activation functions. Finally, the improved Faster R-CNN detection model is used to detect X-ray images of gas insulated switchgear equipment. The results show that the detection accuracy of the model is as high as 99.6%, with a detection time of about 0.0027 s for a single X-ray image, and it runs stably with a frame rate of about 16.5FPS. The research method can achieve high-precision detection of X-ray images of gas insulated switchgear equipment, improving the quality control and efficiency of the operation process of power equipment.

Keywords: power system; gas insulated switchgear; neural networks; detection accuracy; electrical engineering

电力供应是现代社会的支柱之一, 而气体绝缘开关设备作为电力系统中的关键组成部分, 其可靠性和稳定性对电网的安全运行至关重要^[1-2]。然而, 随着电力系统规模的不断扩大和运行环境的复杂化, 气体绝缘开关设备面临着日益严峻的挑战, 其中之一是设备内部可能存在的缺陷和故障^[3]。传统的气体绝缘开关设备缺陷检测方法主要依赖于人工目视检查和简单的图像处理技术。但是人工目视检查费时费力, 且主观判断容易受到主观因素的影响, 缺乏准确性和稳定性。简单的图像处理技术难以有效提取和判断微小的缺陷区域, 也无法进行定量分析和自动化处理。因此, 急需一种高效准确的气体绝缘开关设备缺

陷检测新方法来提高设备质量的监控水平以及降低维护成本。快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)是一种用于目标检测的深度学习方法, 能够准确、快速地检测图像中的物体并对其进行分类。Liu 等^[4]为对原发性肝透明细胞瘤图像进行识别, 用随机特征金字塔(RFP)结构改进 Faster RCNN 模型, 提高 Faster RCNN 模型对变电站特征图的可辨别性。结果显示, 这一改进措施能更有效地从图像中提取关键特征。朱春燕利用深度学习模型改进 Faster RCNN 算法, 并用于皮革材料缺陷检测中。结果显示该方法可以优化皮革材料缺陷机器检测, 提高检测精度^[5]。但目前的 Faster

收稿日期: 2024-07-23; 录用日期: 2024-09-20

基金项目: 国家电网公司总部科技项目(5500-202355183A-1-1-ZN)

作者简介: 高飞(1982—), 男, 教授级高级工程师, 研究方向: 电力设备智能巡视与状态评估。

引用本文: 高飞, 朱正一, 马龙华, 等. 基于 Faster R-CNN 的气体绝缘开关设备 X 光图像缺陷检测[J]. 自动化技术与应用, 2026, 45(1): 58-62, 73.

(GAO Fei, ZHU Zhengyi, MA Longhua, et al. X-ray image defect detection of gas insulated switchgear equipment based on Faster R-CNN[J]. Techniques of Automation and Applications, 2026, 45(1): 58-62, 73.)

R-CNN 模型对于气体绝缘开关设备 X 光图像缺陷的检测精度仍不能满足人们需求^[6]。因此,研究针对现有 Faster R-CNN 模型的不足,引入特征融合对其检测网络进行改进,同时优化其激活函数。提出了一种改进的 Faster R-CNN 检测模型,期待能提高模型对气体绝缘开关设备 X 光图像缺陷检测的精度和效率。研究的创新点在于,引入了特征融合和 Meta-ACON 激活函数改进了现有 Faster R-CNN 模型在气体绝缘开关设备 X 光图像缺陷检测上的不足。

1 X 光图像缺陷检测分析

1.1 图像缺陷分析及图像预处理

气体绝缘开关设备,作为电力系统中至关重要的组成部分,其运行状态直接影响到整个电网的安全性和稳定性。然而,在长期的运行过程中,由于各种复杂因素的作用,这些设备可能会出现各种缺陷。这些缺陷如果不及时发现和处理,可能会引发严重的安全事故,给电力系统带来巨大损失。研究使用青岛软控公司 X 光机对需检测的设备进行扫描,通过不同光密度差异的阴影来形成气体绝缘开关设备 X 光图像。导电部件连接不良,在 X 光图像上表现为连接部位的黑色块状阴影;绝缘材料损坏,在 X 光图像上表现为绝缘材料中的亮白状斑块;设备内部存在异物,在 X 光图像上表现为设备内部的不规则阴影或斑点;设备构件变形,在 X 光图像上表现为构件的形状异常。

如图 1 所示,对气体绝缘开关设备 X 光图像预处理




图 1 缺陷图像预处理方法

Fig. 1 Defectimage preprocessing method

1.2 Faster R-CNN 检测模型的构建及改进

研究采用 Faster R-CNN 模型对气体绝缘开关设备 X 光图像中的缺陷进行检测,该模型的检测步骤主要分为两个阶段:第一阶段为 RPN 阶段,模型将输入的 X 光图像转化为一个特征图,RPN 在特征图上滑动,每个位置生成多个尺度和比例的候选框判断其是否有气体绝缘开关设备 X 光图像中的缺陷^[7]。第二阶段为 RoI Pooling 和分类阶段。在 RPN 阶段生成的候选区域(proposals)会被投影到特征图上,然后通过 RoI Pooling 层将每个投影区域转化为固定大小的特征图^[8]。接着这些特征图会被传输到模型的全连接层进行处理,全连接层对每个 RoI 进行多分类(判断是哪一类缺陷)和边框回归(调整候选框的位置和大小,使其更准确地包围缺陷),Faster R-CNN 模型中 RPN 网络对锚框进行分类和边框位置调整采用的分类损失函数为

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \varepsilon \frac{1}{N_{cls}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

共分为四步。图像分块,先在图像的垂直方向上进行了分割,将原始图像划分为多个独立的组成部分。然后在水平方向上对每一个独立部分进行了等长度的划分,得到涵盖了不同类型的缺陷的原始图,通过这种分割方式,能够更好地捕捉到设备内部的细节信息。图像增强,研究引入了对比度受限自适应直方图均衡化技术来增强缺陷与背景灰度差异。先对每个区域独立计算灰度直方图,以捕捉局部像素的分布情况。然后设定一个裁切阈值,对直方图中超出该阈值的部分进行裁剪,防止过度增强导致图像噪声放大,并将裁剪下的像素分布均匀分配给整个灰度级范围,确保图像的整体亮度分布更加均匀。最后通过直方图均衡化算法对每个区域进行灰度拉伸和压缩,使缺陷部分在图像中更加突出。图像标注,使用 Labelimg 软件对 X 光图像中缺陷部分进行标注后,获取缺陷的类别,长短、颜色深浅等信息,并储存在特定的文件,后续构建的检测网络可以利用该文件学习不同缺陷的特征。图像扩增,为了增加图像样本数据,研究采用图像旋转和随机擦除两种方式对缺陷图像进行扩增。图像旋转的角度为 10°、30°、60°、80°。随机擦除是在大小为 $W \times H$ 的 X 光图像上擦除一个面积为 $A \times B$ 的方形区域,再用 $[0, 255]$ 中随机数顶替被擦除区域的灰度值。通过这种方式,可以模拟出实际检测过程中可能出现的遮挡、噪声等干扰因素,提高检测网络的鲁棒性。同时,扩增后的图像样本可为检测网络提供更多的训练数据。

式中, N_{cls} 为样本个数; N_{reg} 为锚框位置的数量; ε 为参数; L_{cls} 和 L_{reg} 分别为交叉熵损失和边界框位置回归损失函数,计算公式为^[9]

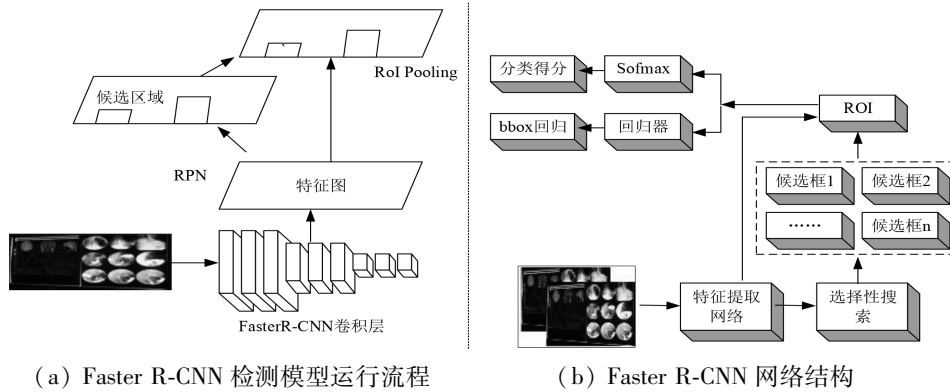
$$\begin{cases} L_{cls}(p_i, p_i^*) = - [p_i^* \log(p_i) + (1 - p_i^*) \log(1 - p_i)] \\ L_{reg}(t_i, t_i^*) = \sum_i \text{Smooth}_{L_1}(t_i - t_i^*) \\ \text{Smooth}_{L_1}(x) = \begin{cases} 0.5x, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \end{cases} \quad (2)$$

式中, p_i 为模型对第 i 个锚框的目标预测概率; p_i^* 为当前锚框是否含有正样本的函数; t_i 为模型对第 i 个锚框的预测框和候选框之间的偏移量; t_i^* 为第 i 个锚框的目标标注框边界位置的回归参数。整个过程见图 2(a)。

图 2(b)中 Faster R-CNN 提取特征向量 N 检测模型的主体网络为 VGG-16, X 光图像经过 VGG-16 深度网络的卷积层提取特征向量^[10]。然后将特征向量送到 RPN,并利用分类得分和非极大值抑制算法筛选出候选框。再将选择出的候选框射到特征向量上,从而计算出相应的特征

矩阵,接着利用池化层和激活函数 ReLU 对带有 anchors 的特征图进行处理,判断出前景和背景 anchors,并通过边界框回归对目标进行定位。接着,使用感兴趣区域池化层下采样的方式将特征图调整为固定大小 7×7 ,以便输入全连接层进行进一步判断。最后,通过全连接分类层和全连接回归层输出结果,确定目标的类别^[11-12]。Faster R-CNN

检测模型在对气体绝缘开关设备 X 光图像中的缺陷进行检测的过程中,如果检测的缺陷目标深层特征包含更多语义信息,就会因为抽象度高,从而丢失缺陷的细节和纹理信息。为此,研究对原有的 Faster R-CNN 的检测模型进行改进。首先采用相邻特征融合的方式对原有的网络模型进行改进,改进后的网络模型见图 3。



(a) Faster R-CNN 检测模型运行流程

(b) Faster R-CNN 网络结构

图 2 Faster R-CNN 检测模型的运行流程及网络结构

Fig. 2 Operation process and network structure of Faster R-CNN detection model

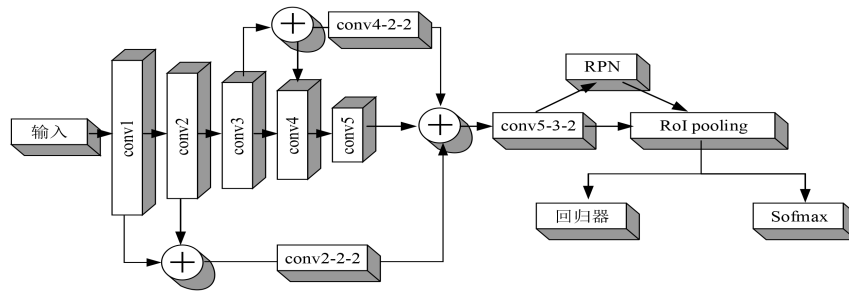


图 3 特征融合的 Faster R-CNN 网络模型图

Fig. 3 Faster R-CNN network model for feature fusion

如图 3 所示,改进后的 Faster R-CNN 网络模型先使用合成少数类过采样技术对数据进行预处理。合成少数类过采样算法为

$$c = a + \text{rand}(0,1) \times |a - b| \quad (3)$$

式中, c 为新生成的少数类样本; a 和 b 均为数据中存在的少数类样本。该处理使得模型在训练时更加关注少数类缺陷,从而增强模型对少数类缺陷的识别能力。接着改进的 Faster R-CNN 网络将 conv1 和 conv2 特征融合为 conv2-2-2,将 conv3 和 conv4 特征融合为 conv4-2-2,以最大化相邻特征图之间的相关性。然后将融合后的特征图与第五卷积层(conv5)的特征图再次融合,进一步丰富了特征图的语义信息,提高网络对图像缺陷的分类识别能力。此外,改进后 Faster R-CNN 网络的特征图与原 Faster R-CNN 中对应模块的特征图大小相同,所以在后续的 RPN 和 RoI Pooling 操作,不需要再进行尺寸调整,可以减少模型运行时间。

气体绝缘开关设备 X 光图像中,各类缺陷的有不同的灰度和纹理特征。原有模型采用的激活函数 ReLU 根据输入样本特征的不同,无法自适应地判断是否激活当前

神经元。因为研究采用 Meta-ACON 函数代替 ReLU 函数作为模型的激活函数。Meta-ACON 函数中,对 $\max(x_1, \dots, x_n)$ 平滑可微近似为

$$S_{\beta}(x_1, \dots, x_n) = \frac{\sum_{i=1}^n x_i e^{\beta x_i}}{\sum_{i=1}^n e^{\beta x_i}} \quad (4)$$

式中 x_i 为函数内的变量; n 为变量的总个数; e 为自然常数; β 为学习不同 X 图像缺陷特征的激活因子, β 趋于无穷大则激活函数为线性, β 趋于无穷小则激活函数为非线性, β 通过控制激活函数的线性程度来控制神经元激活程度。Meta-ACON 函数设计了 3 种 β 的生成方式来学习不同的 X 图像缺陷样本特征。第 1 种为通道级生成方式

$$\beta_1 = \delta Q_1 Q_2 \sum_{h=1}^H \sum_{w=1}^W A_{c,h,w} \quad (5)$$

式中, A 为缺陷特征图, $A \in R^{C \times H \times W}$; Q_1 和 Q_2 为卷积操作; r 为卷积过程中的缩减因子; δ 为 Sigmoid 函数。该方法第 2 种为层级生成方式

$$\beta_2 = \delta Q_1 Q_2 \sum_{h=1}^H \sum_{k=1}^H \sum_{w=1}^W A_{c,h,w} \quad (6)$$

第3种为像素级生成方式

$$\beta_3 = \delta A_{c,h,w} \quad (7)$$

以上3种方式中的 β 均由X图像缺陷样本特征决定,每个缺陷样本会对应不同 β 的分布,所以可以自适应地更改模型中神经元激活状态。

2 结果分析

为了验证改进Faster R-CNN模型对气体绝缘开关设备X光图像缺陷检测的有效性,研究从某电力公司的气体绝缘开关设备中拍摄X光图像1369张,经过预处理后得到包含导电部件连接不良、绝缘材料损坏、设备内部存在异物、设备构件变形4种缺陷的X光图像4365张,按照1:4的比例分为测试集和训练集,供模型进行训练。实验的硬件环境及模型参数设置见表1。

表1 实验的硬件环境及模型参数设置

Tab.1 Hardware environment and model parameter settings for the experiment

项目	参数	项目	参数
操作系统	Windows 10	深度学习框架	Pytorch 框架
CUP	GTX1080Ti	网络预训练模型	VGG-16
内存	GDDR6X	动量	0.9
磁盘	Samsung 980 PRO	权重衰减	0.0005
编程语言	python	学习率	0.001
开发工具	pycharm	批量大小	128

构建完数据集和实验环境后,进行消融实验,利用模糊矩阵对改进Faster R-CNN模型的检测网络的缺陷分类准确性进行评估,结果见图4。

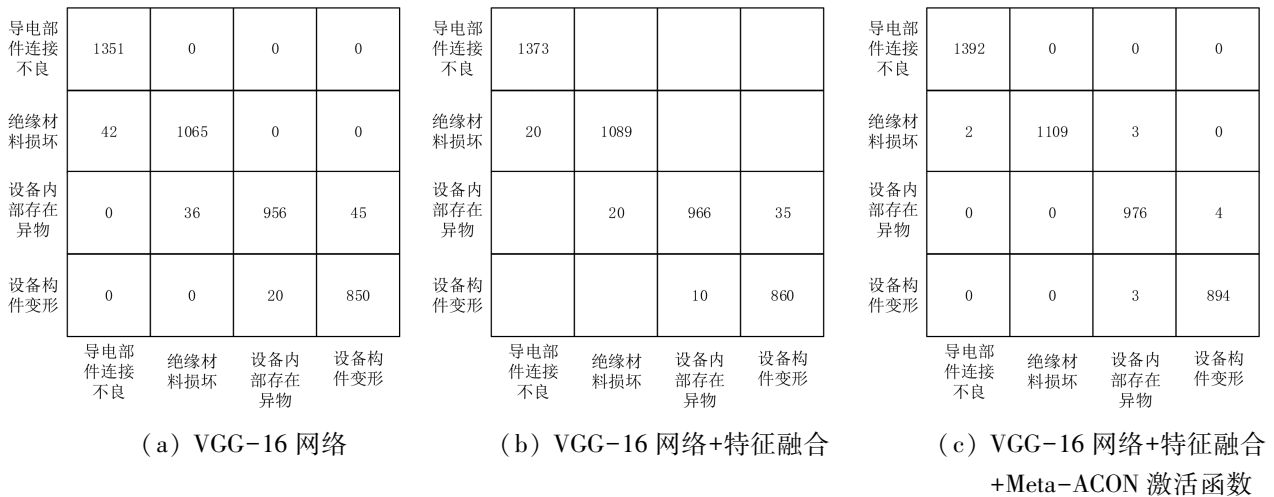


图4 不同检测网络准确性评估结果

Fig.4 Accuracy evaluation results of different detection networks

如图4(a)所示,原始的Faster R-CNN模型中的VGG-16网络的对气体绝缘开关设备X光图像缺陷不高,4365张X光图像中有143处缺陷分类错误,分类精度为96.7%。而添加特征网络融合后,模型的分类精度提升至98.1%。同时添加特征网络融合和改进激活函数后,模型的分类精度提升至99.6%。说明了研究对Faster R-CNN检测模型改进的有效性,同时改进的Faster R-CNN检测模型也符合人们对人们气体绝缘开关设备X光图像缺陷检测需要。为进一步说明改进Faster R-CNN检测模型的优越性,研究设置对比实验,选取现研究阶段的一些经典检测模型在所构建的气体绝缘开关设备X光图像缺陷数据集中进行实验,并与研究模型的进行对比。选取的算法有文献[13]中的基于预训练语言算法模型、文献[14]中的改进轻量化VTG-YOLOv7-tiny模型、文献[15]中基于GoogLeNet深度迁移学习模型。先使用ROC曲线检测各模型的精确度,结果见图5。

由图5的ROC曲线可知,文献[13]、文献[14]、文献[15]中的模型与该研究模型对气体绝缘开关设备X光图

像缺陷数据集的检测精度分别为81.6%、85.6%、93.6%和99.6%。这是因为基于预训练语言算法模型的设计初衷与图像检测任务不完全匹配,导致检测精度有限。改进轻量化VTG-YOLOv7-tiny模型通过轻量化设计提高了检测速度,但在精度上也有所欠缺。基于GoogLeNet深度迁移学习模型可能因为数据特性和任务差异而导致精度有限。再测试各模型的图像检测时间和运行帧率,结果见图6。




图5 不同模型ROC曲线

Fig.5 ROC curves of different models

