

DOI: 10. 19650/j.cnki.cjsi.J1905573

基于三级级联架构的接触网定位管开口销缺陷检测^{*}

王昕钰,王 倩,程敦诚,吴福庆

(西南交通大学电气工程学院 成都 610031)

摘 要:针对高铁接触网定位管开口销在列车长期运行振动中容易松脱并且松脱样本数量匮乏的问题,本文提出一种基于深度卷积生成对抗网络(DCGAN),扩充缺陷样本集后,再训练卷积神经网络(CNN)检测开口销缺陷的三级级联架构。该架构首先采用中心点法提取训练需要的相同规格开口销图像。然后通过改进的 DCGAN 生成模拟缺陷样本,并搭建轻量级 CNN 网络对生成的模拟缺陷样本进行筛选。最后将添加了模拟缺陷样本的扩充缺陷样本集与正样本集输入优化后的 VGG16 卷积神经网络中,以训练分类模型,检测开口销缺陷。实验结果表明,本文所提方法检测接触网定位管开口销缺陷的准确率高达 99%。

关键词: 接触网检测;深度卷积生成对抗网络;开口销缺陷;图像生成;卷积神经网络

中图分类号: TP391.4 U226.5 TH131.6 **文献标识码:** A **国家标准学科分类代码:** 510.20

Detection of split pins defect in catenary positioning tube based on three-level cascade architecture

Wang Xinyu, Wang Qian, Cheng Duncheng, Wu Fuqing

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

Abstract: The split pins of high-speed railway catenary positioning tube are easy to be loosed in the long-term running vibration of the train. However, the number of loose samples is scarce. To solve these problems, this study proposes a three-level cascade architecture expand the defect samples based on deep convolutional generative adversarial network (DCGAN). Then, the convolutional neural network (CNN) is trained to detect split pins defect. Firstly, according to the central point method, the same size image of split pins for training is extracted. Then, DCGAN is used to generate simulated defect samples and a lightweight CNN network is formulated to screen the generated samples. Finally, the extended defect sample set and the positive sample set are utilized to train the detection model on the adjusted VGG16 convolutional neural network. In this way, the defective pins defect state detection can be realized. Experimental results show that the proposed method can achieve 99% accuracy in split pin defect detection of catenary positioning tube.

Keywords: catenary detection; deep convolutional generative adversarial network; split pins defect; image generation; convolutional neural network

0 引 言

电气化铁路接触网作为向高铁动车组、电力机车提供可靠、不间断电能的关键基础设施,其工作状态的安全稳定直接影响铁路的安全运输^[1]。接触网定位管开口销是接触网腕臂结构中重要的紧固件,户外的恶劣环境和列车长期运行中产生的振动可能会导致其脱落,造成腕臂结构松动,影响列车安全运行,需要及时检测其状态排

除安全隐患^[2-3]。

随着 JX300 型高铁接触网检测车(4C)投入使用^[4],非接触式检测成为可能,当前工作人员主要通过 4C 检测车采集到的高清图像人工判别零部件缺陷,该方法效率较低且不能及时指导检修。为提高检测效率,目前已开展基于图像处理技术检测接触网的相关研究:文献[5]采用双目立体视觉测量技术得到接触网定位器坡度。文献[6]通过三维点云连续线性体特征实现非接触式接触网几何参数的计算。文献[7]依据 Hough 直线检测斜腕

收稿日期:2019-09-04 Received Date:2019-09-04

^{*} 基金项目:中国铁路总公司智能牵引供电系统大数据应用技术项目(2016J010-E)资助

臂及连接处的斜率定位开口销,再判断边缘处理后开口销的圆环内连通域个数实现不良状态检测。上述依靠人工设计特征定位检测开口销状态的方法取得了一定成效,但对于不同拍摄角度和曝光强度的图片,其辨识的准确率仍需要提升。

与此同时,随着深度学习的应用愈加广泛,基于深度学习的目标检测方法凭借良好的特征表达能力及优良的目标检测精度,成为主流的目标定位方法。而卷积神经网络因其能从大量图片中自动提取到丰富特征也在列车运行安全隐患排查中得到应用^[8],文献[9]训练卷积神经网络(convolutional neural network, CNN)分类模型识别轨道表面有缺陷的图像,文献[10]基于 CNN 提取的图像特征实现等电位线图像区域的快速分割。文献[11]采用 SSD 和 YOLO 目标检测框架由粗到精定位接触网紧固件,并训练小样本集的 CNN 分类模型鉴别故障。文献[12]使用 LabelIMG 标注采集图像定位零部件,之后通过图像增强技术扩充样本训练 CNN 识别绝缘子和吊弦缺陷。训练一个高性能的 CNN 网络需要大量标注样本和长时间的参数调优过程,而本文要检测的接触网设备多数投入使用年限短,零部件较新,4C 检测车采集到的接触网图像中正常图片占比 95% 以上,缺陷样本数量极少,属于类别数量不均衡样本。这样的数据在 CNN 训练时容易对数量较多的类别“过度学习”,并且神经网络很难从少量样本中学习到全面的特征,最终导致模型泛化性差且容易发生过拟合^[13],无法实现想要辨识故障的预期目标。因此如何使用类别数量不均的零部件样本训练出高鲁棒性的模型是突破深度学习在接触网零部件缺陷检测中应用的难点之一。

生成对抗网络(generative adversarial networks, GAN)的应用^[14]有望破解这一难题。GAN 可用于生成与训练图片相似又不完全相同的图像,近两年也逐渐出现了用其生成的模拟样本提高分类模型性能的相关研究。文献[15]采用 WGAN 重建电力系统缺失数据。文献[16]提出了利用无监督的生成对抗网络提升有监督学习准确率的想法。文献[17]将 GAN 引入半监督学习,在判别器后添加 Softmax 层预测类别概率。文献[18]在 MNIST 数据集上证明了加入深度卷积生成对抗网络(deep convolutional generative adversarial network, DCGAN)生成的样本可提升分类模型性能。

本文在上述工作的基础上,提出一种基于大量正常图片和少量异常图片检测定位管开口销缺陷的三级级联架构。在第 1 级进行开口销定位提取,根据图像目标检测得到的可扩展标记语言(extensible markup language, XML)文件信息,使用中心点法提取得到相同尺度的开口销,使其可以被单独分析。在第 2 级实现开口销缺陷样本集扩充,通过改进后的 DCGAN 生成开口销脱落模拟

样本,并搭建轻量级的 CNN 网络对生成的模拟缺陷样本进行筛选,缩小正负样本间数量差距使类别样本数量均衡。在第 3 级完成开口销缺陷检测,使用添加了模拟缺陷样本的扩充缺陷样本集与等量的正样本在优化 VGG16 网络上训练分类模型,识别开口销不良状态。测试结果表明,相比于只添加图像增强技术扩充样本的 CNN 模型,本文提出的三级级联架构检测缺陷的准确率更高,鲁棒性更好。

1 相关理论分析

为了快速准确的定位接触网图片中的开口销,本文将采用 Faster R-CNN 目标检测算法,同时为提升对类别数量不均衡样本检测的准确度,本文通过改进的 DCGAN 平衡样本并训练优化后的 VGG16 网络作为缺陷检测模型。下面对所用到的相关基本理论做简要分析。

1.1 Faster R-CNN 目标检测算法

Faster R-CNN^[19]是一种基于候选区域的目标检测方法,它将区域提名,图形特征提取、分类,候选区域位置修正集为一体,可准确定位识别图像中的多个目标,并给出其边界框和所属类别。在实际应用中,针对待检测目标进行有针对性地训练可以有效提高对指定目标的定位检测精度。

1.2 深度卷积生成对抗网络

生成对抗网络^[20]是一种无监督学习模型,它的主体包括一个生成器和一个判别器,生成器提取样本数据的分布,指导随机噪声 z 生成模拟样本 $G(z)$,以期骗过判别器;而判别器输入真实样本 x 和模拟样本 $G(z)$,给出生成的模拟样本属于真实样本的概率,并将这一结果反馈给生成器,经过生成器与判别器的交替迭代,生成器学习到样本特征,生成与真实样本相似的模拟样本。GAN 的目标函数如下:

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_{\text{data}}(z)} [\log(1 - D(G(z)))] \quad (1)$$

它表明 GAN 生成样本的实质是最小化真实样本和生成样本分布之间的差异。DCGAN^[21]沿用了 GAN 的目标函数,将卷积结构引入生成器和判别器,并对训练进行了一些优化,比如用卷积层取代了池化层;加入批标准化(batch normalization, BN)帮助模型收敛;生成器输出层用 Tanh 激活函数,其余用 ReLU,而判别器全部用 Leaky relu 激活函数等,经过优化后的模型收敛更快,在图像生成上表现更好。然而在真实训练中,判别器表现优于生成器造成的生成器梯度消失问题仍然没有得到解决。据此,本文将通过调整判别器结构进行改进。

1.3 VGG16 卷积神经网络

VGG16^[22]是一个高性能的图像特征提取网络,其模

型结构如图 1 所示。它由 13 个卷积层、5 个最大池化层和 3 个全连接层构成,卷积核大小全部为 3×3 ,步长为 1。前两层经过两个卷积层后进行步长为 2 的最大池化减小特征图尺寸,后两层经过 3 个卷积层再池化,最后将提取到的图像特征转为一维向量,通过全连接层转化为 Softmax 概率输出。VGG16 输入的图像为 224×224 pixels,若迁移到不同尺度的图像应用,需调整全连接层结构使模型效果更佳。




图 1 VGG16 的网络结构

Fig.1 Network structure of VGG16

2 缺陷检测的三级级联架构

本文提出的三级级联架构由开口销定位提取,开口销缺陷样本集扩充及开口销缺陷检测 3 个环节构成。其中第 1 级通过中心点法提取由 Faster R-CNN 目标检测模型定位的开口销,第 2 级利用改进 DCGAN 生成的模拟缺陷样本扩充缺陷样本集,第 3 级借鉴有强大图像特征提取能力的 VGG16 网络训练分类模型检测开口销缺陷,三级级联架构如图 2 所示。

2.1 开口销的定位提取

由于 4C 检测车采集到的原始图像分辨率较高且背景灰度与开口销相近,直接用于训练会占用过多计算资源。考虑到检测效率和铁路部门以接触网单支柱为管理对象的“一杆一档”储存管理模式,零部件检测应并行处理,因此有必要将定位管开口销提取出来,做单独分析。定位管开口销的位置如图 3 所示。

1) 基于 Faster R-CNN 的开口销定位

Faster R-CNN 具有良好的可移植性和较高的定位精度,因此本文采用针对接触网零部件训练后的 Faster R-CNN 目标检测模型^[23]对采集图像中的零部件进行精确定位。为减少目标检测中的计算资源占用,首先对像素为 $6\,600\times 4\,400$ pixels 的中间局部图像缩放 4 倍至 $1\,650\times 1\,100$ pixels,而后将目标检测模型定位到的开口销坐标信息写入 XML 文件中保存,图 4 所示为 XML 文件中开

口销的位置信息。




图 2 三级级联的开口销缺陷检测架构

Fig.2 Three-level cascade pins defect detection architecture




图 3 定位管支撑上端套筒开口销

Fig.3 Positioning tube supports upper sleeve split pin

```
- <object>
  <name>DW-DWGZC-SDTT-KKX</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <bndbox>
    <xmin>744</xmin>
    <ymin>674</ymin>
    <xmax>757</xmax>
    <ymax>688</ymax>
  </bndbox>
</object>
```

图 4 XML 文件中记录的开口销位置信息

Fig.4 Position information of split pin recorded in XML file

2) 基于中心点法的开口销提取

Faster R-CNN 模型中提名的目标候选框 (Anchor) 有 9 种, 尺寸比例各不同, 直接用目标检测定位坐标提取到的开口销样本如图 5 所示。




图 5 Anchor 和目标检测定位到的开口销样本

Fig.5 Anchor and the sample of split pins located by target detection

由于后续工作需要尺度相同的开口销图像, 为避免对坐标截取的图像归一化操作造成的图形失真。本文采用中心点法提取开口销, 首先围绕目标检测定位图像的中心点重新定义边界框范围, 而后加入窗口随机晃动改变开口销在图像中的位置进行图像增强, 步骤如下:

Step1 由于目标检测时对图像缩放放了 4 倍, 在提取开口销时需要对 XML 文件中定位的坐标 $X_{\min}, X_{\max}, Y_{\min}, Y_{\max}$ 放大 4 倍, 计算得到的开口销中心点坐标为 $(X_{\text{center}}, Y_{\text{center}})$ 。

$$\begin{cases} X_{\text{center}} = 2X_{\min} + 2X_{\max} \\ Y_{\text{center}} = 2Y_{\min} + 2Y_{\max} \end{cases} \quad (2)$$

Step2 根据统计数据, 目标检测后的开口销尺寸多在 56 到 78 之间, 考虑图像特征完整程度选择 75×75 pixels 的边界框 (bounding box) 截取开口销, 边界框范围定义为 $X_{\text{box}}, Y_{\text{box}}$ 。

$$\begin{cases} X_{\text{box}} = 2X_{\min} + 2X_{\max} \pm 37.5 \\ Y_{\text{box}} = 2Y_{\min} + 2Y_{\max} \pm 37.5 \end{cases} \quad (3)$$

Step3 用 random 函数生成 $(-8, 8)$ 的随机数作为偏移量加在中心点坐标上, 使边界框在开口销上晃动, 实现从一个开口销得到多个样本图像。

图 6 展示了中心点法提取开口销的过程, 图 6(b) 中实线框为 Step2 中定义的边界框, 虚线框为中心点偏

移后的窗口。




图 6 中心点法提取开口销过程

Fig.6 Process of the center point method for split pins extraction

2.2 开口销缺陷样本集扩充

本文提出的开口销缺陷样本集扩充方法由两个环节组成, 先用改进后的 DCGAN 生成开口销缺陷模拟样本, 再搭建轻量级的 CNN 网络判断模拟缺陷样本与真实缺陷样本相像的概率并据此剔除生成质量不佳的模拟缺陷样本。

1) 基于改进 DCGAN 的模拟缺陷样本生成

DCGAN 模型对于特征简单的图像具有快速收敛的特性和较为稳定的生成效果, 因此本文在 DCGAN 网络基础上进行改良使其更适合开口销缺陷样本的生成。基于改进 DCGAN 网络生成缺陷开口销样本的模型如图 7 所示, 首先扩展原模型输入为 75×75 pixels; 针对 DCGAN 实际训练过程中判别器表现优于生成器造成的生成器梯度消失问题, 对 DCGAN 进行改进: 为了平衡两者的对抗关系, 将判别器的 4 层卷积核数量均缩小为原来的一半以削弱其特征提取能力, 生成器中 4 层卷积核个数保持原文设定分别为 64, 128, 256, 512, 判别器中 4 层卷积核个数分别设定为 32, 64, 128, 256; 使用 5×5 的卷积核, 步长 $\text{stride} = 2$ 以加快模型收敛速度。改进后的 DCGAN 经过的稳定对抗期更长, 每训练 100 次就在 8×8 的画布上生成 64 个和真实缺陷样本分布相近的模拟缺陷样本 $G(z)$, 生成的样本更具多样性。




图 7 基于改进的 DCGAN 网络生成模拟缺陷样本

Fig.7 Generation of defect simulation samples based on the improved DCGAN network

2) 基于轻量级 CNN 的模拟缺陷样本筛选

训练后的 DCGAN 理论上可以生成无数个开口销缺陷模拟样本,但是骗过判别器的图片不是全能达到扩充缺陷样本集的精度要求,需要筛选剔除部分不良样本。在此阶段使用特征提取能力强的网络很容易将生成的模拟缺陷样本判断为缺陷样本类并给出 100% 的置信度,这样的评估结果缺少说服力,需要搭建一个对图像特征差异敏感的轻量级 CNN 网络实现对模拟缺陷样本的验证筛选。

本文的筛选网络采用 LeNet-5^[24] 一层卷积一层池化的基础结构,结合后续 AlexNet, VGG16 的训练技巧,通过




图 8 验证筛选模拟缺陷样本的轻量级 CNN 网络结构

Fig.8 Verification and screen lightweight CNN network structures for simulating defect samples

调整前后网络训练的准确率和损失曲线如图 9 所示,其中红线和紫线为训练集曲线,灰线和蓝线为验证集曲线,可以看到调整后的网络收敛速度更快且准确率更高。

2.3 基于优化 VGG16 的开口销缺陷检测模型

缺陷检测阶段的目标是将开口销图像按照销钉是否脱落进行分类。由于图像具有“静态性”的属性,在一个图像区域有用的特征在另一个图像区域基本也同样适用。VGG16 网络提供在 ImageNet 数据集上训练后的模型参数,迁移其参数可在样本数量和计算资源有限时最大程度的提升训练速度和模型准确率。

本节对 VGG16 网络进行优化后作为开口销正负样本分类模型,保留其卷积层结构和在 ImageNet 数据集上预训练的参数,根据输入图像尺度与原网络不同,重新设计了 VGG16 的全连接层结构。全连接层的作用类似于多项式拟合数据分布,一个全连接层相当于一个多项式,需根据分类问题的复杂程度选择全连接层数量。由于开口销样本经过卷积层扁平化后的特征维度为 2 048,并且为较易拟合的二分类模型,故选用单层全连接层结构;同时根据实验时训练的收敛速度和模型准确率采用 256 个神经元并加入概率为 0.5 的 Dropout 防止过拟合。优化

分析对比实验中的损失曲线和实际预测效果选取适合的网络参数,最终搭建的轻量级 CNN 网络结构如图 8 所示,做出的调整如下:

(1) 由于训练图像比 LeNet-5 原网络输入更大,增加一层卷积层和全连接层,在提高特征提取能力的同时防止经过扁平层后丢失过多信息。

(2) 更换激活函数为 ReLU 提高训练速度。

(3) 卷积核大小从 5×5 调整为 3×3,在感知野相同的条件下,加深网络从而减少计算参数;卷积核个数从 2 的次方中选取,三层卷积核数分别设为 8,16,32。

(4) 修改全连接层为单层,并取节点数为 256。

后的 VGG16 网络结构和每层输出尺寸见表 1。

表 1 优化后的 VGG16 网络结构和输出尺寸
Table 1 Optimized VGG16 network structure and output size

层	网络参数	输出尺寸
输入层	-	(75,75,3)
卷积层 1	3×3×64×2	(75,75,64)
最大池化 1	2×2	(37,37,64)
卷积层 2	3×3×128×2	(37,37,128)
最大池化 2	2×2	(18,18,128)
卷积层 3	3×3×256×3	(18,18,256)
最大池化 3	2×2	(9,9,256)
卷积层 4	3×3×512×3	(9,9,512)
最大池化 4	2×2	(4,4,512)
卷积层 5	3×3×512×3	(4,4,512)
最大池化 5	2×2	(2,2,512)
扁平层	-	2 048
全连接层	256	256




图 9 调整前后网络的训练效果对比

Fig.9 Comparison of training effect of network before and after adjustment

3 实验结果与分析

本文实验环境为 NVIDIA GeForce RTX2060 显卡, 16 GB运行内存, Inter(R) Core(TM) i5-9400F CPU @ 2.9 GHz 处理器, Windows10 操作系统。实验程序在版本为 1.13.0 的 TensorFlow 深度学习开源框架平台编写。

3.1 开口销样本集搭建

实验选取 JX300 型接触网检测车夜间在西成客专线上拍摄到的 1 000 张接触网腕臂结构中间局部图像, 包括在隧道内和站内等不同环境, 以保证样本多样性。检测车及顶部相机分布如图 10 所示。




图 10 接触网高清图像数据采集装置

Fig.10 Catenary high-definition image data acquisition device

开口销是微小零部件, 为实现其单独分析, 本节采用 2.1 节中的方法将目标检测定位的开口销提取出来。由于目标检测定位结果存在一定的偏差, 为保证样本准确度, 对提取到的开口销图像进行清洗, 去除定位错误和截取不完全的样本。

针对缺陷样本数量有限的问题, 对现有的缺陷样本进行顺逆时针旋转, 调节对比度, 亮度和色阶曲线等使样本集更丰富。图像增强效果如图 11 所示。提取到的正常开口销样本按照 5:1:2 的比例划分为训练集、验证集和测试集, 图像增强处理后的缺陷开口销样本全部用于改进 DCGAN 训练。




图 11 缺陷样本图像增强效果

Fig.11 The effect of defect sample image enhancement

3.2 开口销缺陷样本集的扩充实验

1) 改进 DCGAN 生成模拟缺陷样本的训练过程

适当的参数配置可有效提升训练效率。本文对 2.2 中的改进 DCGAN 判别器输入缺陷开口销样本, 生成器输入高斯随机噪声, 将模型权重初始化为均值为 0 方差为 0.02 的正态分布^[21], 通过小批量随机梯度下降法进行训练, 使用 Adam 优化器对超参数调优, 根据训练稳定性表现设置学习率为 0.000 2, 动量为 0.5。此外, 由于样本数量少, 训练时每批次读入 32 个样本, 迭代 300 轮。图 12 所示展示了模拟缺陷样本的生成过程。在第一个 Epoch 时输入的噪声刚刚演变出样本的轮廓, 随着迭代次数增多, 样本逐渐清晰特征也变得明朗, 在画布中同一位置的图像每经历一个 Epoch 都会有一些新的变化, 这样就可以得到多张与真实缺陷样本相似的模拟缺陷样本。

由于真实缺陷样本数量过少, 改进 DCGAN 生成的模拟缺陷样本在接近其数据分布的范围内变化, 丰富度也很有限。因此本文模型将生成的模拟缺陷样本经过轻

量级网络的筛选后作为下一次改进 DCGAN 的输入,经过多次循环使生成的模拟缺陷样本更多样化。




图 12 改进 DCGAN 生成模拟缺陷样本训练过程
Fig.12 The training process of generation simulated defect sample with the improved DCGAN

2) 轻量级 CNN 的训练及筛选效果

改进 DCGAN 生成的模拟缺陷样本质量参差不齐,为提高扩充质量,将开口销背面作为无关变量,使用等比例的开口销背面,正样本和真实负样本各 280 张训练筛选 CNN 三分类模型,训练样本如图 13 所示,Label 分别为 0,1,2。




图 13 验证筛选网络训练样本

Fig.13 Training samples of verification and screen network

训练 2 000 次后保存模型并用其预测模拟缺陷样本被判别为负样本类的概率,测试效果如图 14 所示。为保证样本质量,预测标签错误和置信度低于 80% 以下的模拟缺陷样本不能用于缺陷样本集扩充。




图 14 验证筛选网络筛选结果

Fig.14 Results of verification and screen network

3.3 优化 VGG16 缺陷检测模型的训练

将筛选出的模拟缺陷样本与经过图像增强处理的缺陷样本合并得到拥有 1 500 张图片的扩充缺陷样本集,与 1 500 个正常开口销样本一起作为训练集 1 在优化后的 VGG16 模型上训练 1 000 次,图 15 所示为模型训练过程的准确率和损失曲线,可以看到由于迁移的 VGG16 网络有很强的特征提取能力,模型收敛速度非常快,训练集和验证集准确率都很高。




图 15 缺陷检测模型训练情况
Fig.15 Training situation of defect detection model

3.4 三级级联缺陷检测模型的评估

为验证添加模拟缺陷样本对于模型缺陷检测效果的提升作用,将只经过图像增强处理的缺陷样本与同等数量的开口销正样本作为训练集 2,在优化 VGG16 网络上训练 1 000 次得到未扩充训练集缺陷检测模型。同样样本在两个模型上的测试结果对比如图 16 所示,可以看到,本文模型因为添加了模拟缺陷样本,学到更多特征,对于不同拍摄角度和曝光强度的图片样本预测的置信度更高,起到了稳定缺陷检测结果的作用。

为论证本文三级级联架构合理性。将 1 500 张未经筛选的模拟缺陷样本和同等数量的开口销正样本作为训练集 3,在优化后的 VGG16 上训练新网络,验证筛选生成模拟缺陷样本环节的必要性。为证明迁移 VGG16 卷积结构对于缺陷检测准确率的提升作用,采用筛选 CNN 网




图 16 相同样本在两个模型上的测试结果对比
Fig.16 Comparison of test results of the same sample on two models

络在训练集 1 上训练 1 000 轮得到对比模型。实验对比结果如表 2 所示,可以看出相较于人工设计特征的文 献[7]及分别缺少三级级联架构各环节的模型,本文模型在缺陷检测精度上更有优势。

表 2 不同方法检测开口销缺陷的准确率比较
Table 2 Comparison of the accuracy of different methods for detecting split pin defects

方法	训练集	准确率/%
文献[7]	—	85.00
优化 VGG16	训练集 2	91.67
改进 DCGAN+优化 VGG16	训练集 3	95.33
改进 DCGAN+轻量级 CNN	训练集 1	92.67
改进 DCGAN+轻量级 CNN+优化 VGG16	训练集 1	99.33

为更好的对比缺陷检测模型效果,本文绘制接受者操作特性 (receiver operating characteristic, ROC) 曲线表征模型的分类性能。ROC 曲线能较好的反映不同分类器对 TN 的表现,符合我们想要检测缺陷的要求。曲线刻画真正类率 TPR 和假正类率 FPR 之间的关系,TPR 表示正样本被正确预测的概率,FPR 表示负样本被错误预测的比例,计算公式如下:

$$TPR = \frac{TP}{TP + FN}$$
 (4)

$$FPR = \frac{FP}{FP + TN}$$
 (5)

其中真阳性 TP,真阴性 TN,假阳性 FP,假阴性 FN 的指代如表 3 所示。

表 3 列联表
Table 3 Contingency table

预测值	真实值	
	1	0
1	FP	TP
0	TN	FN

实验从正、负样本测试集中分别选取 150 个样本,用表 2 中的 4 个模型分别进行测试,根据测试结果属于正样本的置信度绘制 ROC 曲线,对比效果如图 17 所示。AUC 值为曲线下包围的面积,该值介于 (0,1) 范围内,越接近 1 表示分类效果越好。本文缺陷检测模型的 AUC 值达到了 0.99,说明本文提出的三级级联架构在定位管开口销缺陷检测上必要且高效。




图 17 不同模型的 ROC 曲线对比
Fig.17 Comparison of ROC curves of different models

4 结 论

针对接触网开口销缺陷检测中缺陷样本数量较少的问题,本文提出一种涵盖开口销定位提取,缺陷样本集扩充和缺陷检测的三级级联架构,将改进 DCGAN 生成的模拟缺陷样本经过轻量级 CNN 的筛选后,用于优化 VGG16 缺陷检测模型的训练,从而实现了基于类别数量不均衡样本的接触网定位管开口销缺陷检测。实验结果表明,本文提出的方法检测缺陷的准确率高达 99%,证明在样本数量受限的情况下,添加改进 DCGAN 生成的模拟样本可以有效提升模型性能。这一方法为其他接触网零部件的缺陷智能检测提供了参考。

参考文献

[1] 钱清泉,高仕斌,何正友,等.中国高速铁路牵引供电关键技术[J].中国工程科学,2015,17(4):9-20.
QIAN Q Q, GAO SH B, HE ZH Y, et al. Study of China

- high-speed railway traction power supply key technology [J]. Engineering Sciences, 2015, 17 (4): 9-20.
- [2] 高速铁路供电安全检测监测系统(6C 系统)总体技术规范[S]. 北京:中华人民共和国铁道部,2012.
- [3] 韩志伟,刘志刚,张桂南,等.非接触式弓网图像检测技术研究综述[J]. 铁道学报,2013,35(6):40-47.
HAN ZH W, LIU ZH G, ZHANG G N, et al. Overview of non-contact image detection technology for pantograph-catenary monitoring [J]. Journal of the China Railway Society, 2013, 35(6): 40-47.
- [4] GAO S B, LIU Z G, YU L. Detection and monitoring system of the pantograph-catenary in high-speed railway (6C) [C]. International Conference on Power Electronics Systems and Applications-Smart Mobility, Power Transfer & Security (PESA), IEEE, 2017.
- [5] 占栋,景德炎,吴命利,等.电气化铁路接触网定位器坡度动态视觉测量方法研究[J]. 电子测量与仪器学报, 2018, 32(8): 50-58.
ZHAN D, JING D Y, WU M L, et al. Study on dynamic vision measurement for locator slope gradient of electrified railway overhead catenary [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(8): 50-58.
- [6] 周靖松,韩志伟,杨长江.基于三维点云的接触网几何参数检测方法[J]. 仪器仪表学报, 2018, 39(4): 239-246.
ZHOU J S, HAN ZH W, YANG CH J. Catenary geometric parameters detection method based on 3D point cloud[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 239-246.
- [7] 钟俊平,刘志刚,陈隽文,等.高速铁路接触网悬挂装置开口销不良状态检测方法研究[J]. 铁道学报, 2018, 40(6): 51-59.
ZHONG J P, LIU ZH G, CHEN J W, et al. Defective condition detection of split pins in catenary suspension device of high-speed railway [J]. Journal of the China Railway Society, 2018, 40(6): 51-59.
- [8] LIU Z G, SONG Y, HAN Y, et al. Advances of research on high-speed railway catenary [J]. Journal of Modern Transportation, 2018, 26(1): 1-23.
- [9] FAGHIH ROOHI S, HAJIZADEH S, NUNEZVICEN CIO A, et al. Deep convolutional neural networks for detection of rail surface defects [C]. International Joint Conference on Neural Networks, IEEE, 2016.
- [10] LIU Z G, WANG L Y, YANG C, et al. A high-precision Loose strands diagnosis approach for isoelectric line in high-speed railway [J]. IEEE Transactions on Industrial Informatics, 2018, 14(3): 1067-1077.
- [11] CHEN J W, LIU Z G, WANG H R, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(2): 257-269.
- [12] 王聪.基于卷积神经网络的铁路图像智能识别算法研究[D]. 北京:北京交通大学, 2018.
WANG C. Research on intelligent recognition algorithm of railway images based on convolutional neural network [D]. Beijing: Beijing Jiaotong University, 2018.
- [13] BUDA M, MAKI A, MAZUROWSKIM A. A systematic study of the class imbalance problem in convolutional neural networks [J]. Neural Networks, 2018, 106: 249-259.
- [14] 王坤峰, 苟超, 段艳杰, 等.生成式对抗网络 GAN 的研究进展与展望[J]. 自动化学报, 2017, 43(3): 321-332.
WANG K F, GOU CH, DUAN Y J, et al. Generative adversarial networks: the state of the art and beyond [J]. Acta Automatica Sinic, 2017, 43(3): 321-332.
- [15] 王守相, 陈海文, 潘志新, 等.采用改进生成式对抗网络的电力系统量测缺失数据重建方法[J]. 中国电机工程学报, 2019, 39(1): 56-64.
WANG S X, CHEN H W, PAN ZH X, et al. A reconstruction method for missing data in power system measurement using an improved generative adversarial network [J]. Proceedings of the CSEE, 2019, 39(1): 56-64.
- [16] PEREZ L, WANG J. The effectiveness of data augmentation in image classification using deep learning [J]. arXiv preprint arXiv: 1712.04621, 2017.
- [17] ODENA A. Semi-supervised learning with generative adversarial networks [J]. arXiv preprint arXiv: 1606.01583, 2016.
- [18] FANG W, ZHANG F, S. SHENG V, et al. A method for improving CNN-based image recognition using DCGAN [J]. Computers, Materials & Continua. 2018, 57(1): 167-178.
- [19] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis &

- Machine Intelligence, 2015, 39(6): 1137-1149.
- [20] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [21] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. arXiv preprint arXiv: 1511.06434, 2015.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv:1409.1556, 2014.
- [23] 狄亚柳. 基于深度学习的高铁接触网悬挂目标检测图像处理研究[D]. 成都:西南交通大学, 2018.
- DI Y L. Research of the high-speed railway catenary suspension object detection based on deep leaning image processing [D]. Chengdu: Southwest Jiaotong University, 2018.
- [24] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-232.

作者简介



王昕钰, 2017 年于大连交通大学获得学士学位, 现为西南交通大学硕士研究生, 主要研究方向为接触网零部件缺陷检测。

E-mail: swjtu_wxy@163.com

Wang Xinyu received her B. Sc. degree from Dalian Jiaotong University in 2017. She is currently a M. Sc. candidate at Southwest Jiaotong University. Her main research interests include fault detection of catenary parts.



王倩(通信作者), 1984 年和 1989 年于西南交通大学获得学士学位和硕士学位。现任西南交通大学教授, 主要研究方向为电力系统调度自动化。

E-mail: qian.wang@home.swjtu.edu.cn

Wang Qian (Corresponding author) received her B. Sc. and M. Sc. degrees both from Southwest Jiaotong University in 1984 and 1989, respectively. She is currently a professor at Southwest Jiaotong University. Her main research interests include electric power system dispatch automation.