

# 利用改进RCNN卷积核的复合绝缘子缺陷识别方法

李新海, 罗其锋, 曾庆祝, 曾新雄, 闫超

(广东电网有限责任公司中山供电局, 广东 中山 528401)

**摘要:**变电站复合绝缘子缺陷的检测仍然依赖于运行人员的巡检, 巡检工作量大, 易因视觉疲劳导致漏检。为减少计算资源消耗和缩短训练时间, 通过重新组织卷积核改进了区域卷积神经网络(RCNN), 提出了一种针对绝缘子裂纹形状特征的检测方法。该方法满足在训练样本数据不足的前提下, 也能得到较好的卷积神经网络(CNN)训练效果, 最终实现准确的裂纹识别。训练阶段采用RGB三通道分解方法, 扩充训练数据集; 利用中值滤波方法去除噪声; 采用改进后的卷积核训练CNN。试验阶段将图片进行RGB三通道分解, 并输入CNN得到确切的裂纹中心坐标、长度; 采用非极大值抑制(NMS)算法去重, 得到最终的裂纹识别结果。通过实例分析表明, 在训练样本不足前提下, 所提方法依然能达到较好的识别准确率, 并能准确识别出裂纹的具体位置。

**关键词:**绝缘子裂纹检测; 卷积核; 图像处理; 区域卷积神经网络; RGB三通道滤波

**中图分类号:**TP183 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed24478

## Composite Insulator Defect Identification Method Using Improved RCNN Convolution Kernel

LI Xinhai, LUO Qifeng, ZENG Qingzhu, ZENG Xinxiong, YAN Chao

(Zhongshan Power Supply Bureau of Guangdong Power Grid Co., Ltd.,  
Zhongshan 528401, Guangdong, China)

**Abstract:** The detection of composite insulator defects in substations still relies on inspection by operators, which is a heavy workload and prone to leakage due to visual fatigue. To reduce the computational resource consumption and shorten the training time, the region convolutional neural networks (RCNN) was improved by reorganizing the convolution kernel, and a detection method was proposed for insulator crack shape features. The method can meet the premise of insufficient training sample data, but also can get better convolutional neural networks (CNN) training effect, and finally achieve accurate crack recognition. In the training phase, the RGB three-channel decomposition method was used to expand the training data set, the median filtering method was used to remove the noise, the improved convolutional kernel was used to train the CNN. In the test phase, the images were decomposed by RGB three-channel decomposition and input to CNN to get the exact crack center coordinates and length. The non-maximum suppression (NMS) algorithm was used to de-weight the images to get the final crack recognition results. The example analysis shows that the propose method can still achieve good recognition accuracy, and accurately identify the specific location of cracks under the premise of insufficient training samples.

**Key words:** insulator defect identification; convolutional kernel; image processing; region convolutional neural networks (RCNN); RGB three-channel filtering

在变电站日常运行中, 由于制造质量不良、外部气候环境恶劣以及承受电磁应力长期过大等原因, 复合绝缘子容易产生绝缘外套开裂。这种缺

陷如不能被及时发现并做出处理, 可能导致绝缘子损坏、爆裂, 进而导致保护跳闸, 甚至引发供电区域大面积停电等严重事故, 对电力系统以及国民

**基金项目:**广东电网有限责任公司科技项目(GDKJXM20190154 (032000KK52190001))

**作者简介:**李新海(1971—), 男, 本科, 高级工程师, 主要研究方向为新技术在电力系统中的应用、人工智能、变电设备运行、检修管理及研究, Email: zslxinhai@163.com

经济造成严重的损失<sup>[1-3]</sup>。因此,对绝缘子进行定期巡视,及时发现并消除绝缘子裂纹缺陷,对变电站的安全稳定运行具有非常重要的意义。

传统的绝缘子裂缝缺陷检测的方法主要包括直接观察法配合设备定期抽查、红外测量法等<sup>[4]</sup>。复合绝缘子是数量非常大的室外变电设备,图1为变电站复合绝缘子裂纹的相对位置。传统方法依赖于人工,但人工检测的方法效率低、工作强度大,也很难分辨是否存在裂纹,长时间专注观察极容易引起视觉疲劳,进而导致漏检。同时,红外测温检测法也存在稳定性和可靠性差、测温精度较低、抗干扰能力差且测量参数极易漂移等缺点。

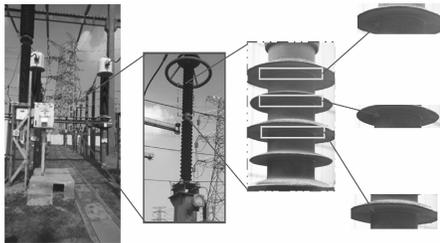


图1 变电站复合绝缘子裂纹的相对位置  
Fig.1 Relative position of cracks in composite insulators in substations

近年来,随着深度学习智能算法的逐渐成熟和广泛应用<sup>[5-7]</sup>,使用图像识别方法对绝缘子裂纹缺陷特征进行自动检测已成为可能。采用区域卷积神经网络(RCNN)、单次检测器算法(single shot multi-box detector, SSD)、只需要浏览一次就可以识别出图中的物体的类别和位置的微型算法(you only look once, YOLO)等图像识别方法,可以提升变电站运行的自动化、智能化水平<sup>[6-8]</sup>,大大降低绝缘子裂纹检测对人工的依赖,提高输电环节的安全性、稳定性。

RCNN是常用的图像的目标识别网络,常用的RCNN网络训练需要大量的CPU和图形处理器(graphics processing unit, GPU)资源,并且训练时间比较长。为减少训练所需资源和时间,本文立足于绝缘子裂纹图像信息采集的实际,改进卷积神经网络(CNN)卷积核,设计了一套RCNN的复合绝缘子裂缝特征检测方法。首先,根据裂纹在图像中的形状特征,改进CNN卷积核;再针对普遍存在的训练样本不足问题,通过图像预处理、RGB三通滤波等计算机图像增强技术扩充绝缘子裂纹图像样本集;随后利用样本集训练得到RCNN。在进行绝缘子裂纹缺陷检测时,先将

图像分解为单通道图像进行预处理操作后输入RCNN,随后采用非极大值抑制(non-maximum suppression, NMS)算法<sup>[9]</sup>合并3个通道的输出结果,最后完成对绝缘子图像裂纹的分割提取以及裂纹长度、宽度的检测。

实验证明,卷积核改进后的RCNN的绝缘子裂纹缺陷检测方法能够在图像样本数据量不大的情况下,对裂缝检测的准确率达99.6%。这有助于绝缘子裂缝缺陷的非接触、在线监测的实现,并为变压器运行绝缘子的故障诊断、无人值守变电站以及机器人智能识别绝缘子开裂提供新的思路。

## 1 方法概述与卷积核的改进

### 1.1 方法概述

RCNN模型训练以及绝缘子裂纹图像识别流程如图2所示。

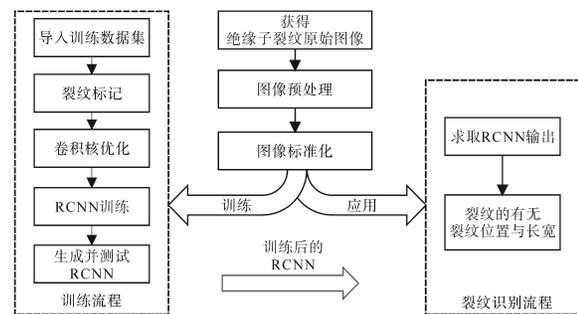


图2 RCNN模型训练以及绝缘子裂纹图像识别流程图

Fig.2 RCNN model training and flow chart of insulator cracking image recognition

为了达成准确识别裂纹的目标,所设计的方法包括以下4个步骤:

1) 图像分解。将采集到的彩色绝缘子图像分解为R, G, B 3个单通道绝缘子图像。

2) 滤波去噪。采用中值滤波去除该图像在采集和传输过程中掺杂的噪声。

3) 标准化、训练与预测。将处理后的三通图片作标准化,以生成满足RCNN要求的输入数据;在训练阶段,对输入进行标记并训练RCNN;在预测阶段,将数据输入训练好的RCNN中进行预测。

4) 目标识别。得到R, G, B各个分量符合阈值要求的像素集以及全连接(full connected, FC)层输出的分类标签和置信度;根据算法设定的阈值判断是否存在裂纹特征,并使用NMS算法对各个通道分量的结果进行去重;若均置信度超过了算法设定的阈值,则可以通过Mask网络获取裂纹

的位置、长度以及宽度等特征信息。

### 1.2 针对绝缘子裂纹的卷积核改进

通用的RCNN卷积运算存在没必要的重复扫描运算。如果采用通用的RCNN,则需要消耗计算资源,而特别是在卷积核设计不合理导致核矩阵中的参数不能被完全利用时,会导致大量没必要的重复运算而浪费计算资源。

利用目标位置和形状的确性等图像特征作为先验知识,可减少卷积核的重复扫描。变电站巡检“机器人”采集到的绝缘子图片文件的像素是确定的,而绝缘子在图片中的相对大小也是比较固定的,裂纹的相对大小(像素点和长宽)也是基本确定的。根据裂纹图像的确定性特点,可以通过指定卷积核的行数和列数设计卷积核,如图3所示,降低裂纹识别对计算资源的需求,提升CNN的训练速度和识别准确度。改进内容如下:

1)挑选  $n$  张裂纹的典型图片,并在图中框选裂纹。

2)获得所框选裂纹的长宽像素点  $r_k \times c_k$ , 构造出长宽集,如下式所示:

$$\begin{cases} R = \{r_1, r_2, \dots, r_n\} \\ C = \{c_1, c_2, \dots, c_n\} \end{cases} \quad (1)$$

3)考虑到待识别的裂纹的  $r$  比较固定,为减少卷积核参数的数量,设定所设计的卷积核的长、宽像素,如下式所示:

$$\begin{cases} r_{\text{kernel}} = \min(R) \\ c_{\text{kernel}} = \min(C) \end{cases} \quad (2)$$

例如图3中的裂纹,选取  $7 \times 17$  的卷积核即可覆盖最短的裂纹。

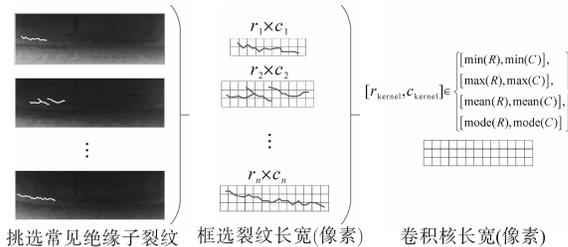


图3 针对绝缘子裂纹的卷积核设计

Fig.3 Convolution kernel design for insulator cracks

## 2 绝缘子图像预处理

在训练集样本数较少时,RCNN存在过拟合问题。为了在绝缘子样本数目较少时依然取得较好的预测效果,在图像预处理前,将单张绝缘子彩图分解为R,G,B三通道图片,通过旋转、平

移等图像处理算法对图片进行处理,以扩充样本集。

绝缘子图像存在较多噪声。摄像镜头制作工艺以及光线环境等外部因素会导致拍摄获得的绝缘子图像数据中包含很多噪声,这些噪声容易影响到RCNN模型在训练以及预测时的准确度,严重时可能会造成误判。因此采集到的原始绝缘子图像数据需要经过滤波处理以消除图像中的噪声并增强图片对比度。常用的滤波方法包括高斯滤波、中值滤波、递归滤波等<sup>[10-17]</sup>。

针对以上两个问题及RCNN对输入数据的要求,对于原始绝缘子图像预处理的流程如图4所示。具体过程叙述如下:

1)图像数量扩充。将拍摄采集到的彩色绝缘子图像分解为R,G,B 3张单通道图像。

2)图像噪声滤除。采用中值滤波去除该图像在采集和传输过程中掺杂的噪声,并将滤波后的图片进行标准化以获取未标注的图像训练集。

3)图像标准化。将输入图片的矩阵转换为统一大小,并将统一大小后的图片进行正则化处理,以满足RCNN对输入数据的要求。

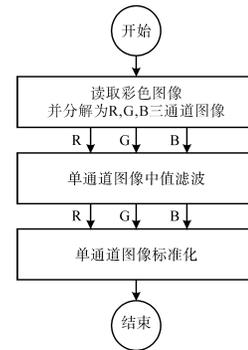


图4 绝缘子图像预处理流程图

Fig.4 Flow chart of insulator image preprocessing

### 2.1 图像数据扩充

为了减少算法后期图像数据处理量,同时提高训练集样本数据量,可将采集到的彩色绝缘子图像分解为R,G,B 3张单通道图像,然后分别对3个单通道进行后续图像处理与特征提取。

工业摄像机都采用RGB颜色标准。其中,彩色图片所包括的R,G和B 3种颜色通道各包含256级亮度,每种颜色都可以用这3个通道的不同亮度组合表示。以实际采集到的绝缘子图像为例,在进行RGB三通道分解后所得绝缘子R通道图像如图5所示。

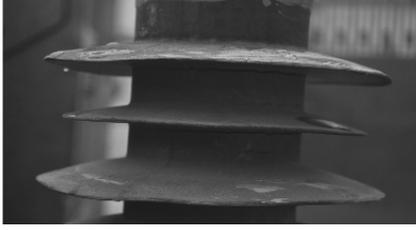


图5 R通道分解图像

Fig.5 Decomposed image of the R channel

从图5所示的绝缘子裂纹可知,在进行绝缘子原始数据图像RGB三通道分解后,分解后图像中的绝缘子的裂纹特征被保留,而分解后的3张图像大小缩减为原彩色图像的1/3。同时,经过图像RGB三通道分解后,原绝缘子图像数据集扩大近3倍,在一定程度上避免了由于样本数据集不足而需要增加RCNN迭代次数最终造成的过拟合问题。

## 2.2 图像噪声的滤除

摄像镜头以及光线环境等外部因素会导致经过三通道分解获得的图像有很多噪音。为凸显裂纹特征,需要通过图像滤波增强技术来消除图像噪声并增强图片对比度。相比于高斯滤波和递归滤波,中值滤波作为一种非线性滤波在消除图像或信号噪声时被广泛采用<sup>[17]</sup>。

中值滤波的原理。对于一个数字信号序列 $x_j(-\infty < j < \infty)$ ,在使用中值滤波算法进行滤波处理时,需要定义一个奇数长度的固定区间窗口 $L$ ,即 $L=2N+1$ , $N$ 为正整数。假设在滤波某一时刻区间窗口内像素点取值为 $x(i-N), \dots, x(i), \dots, x(i+N)$ , ( $x(i)$ 为奇数滤波窗口中心点处的像素点取值),随后对 $L$ 个像素点取值进行大小排序,选取像素点取值为中心处的像素值,即为该时刻下中值滤波算法的输出。在进行绝缘子图像滤波预处理时,二维中值滤波输出如下式:

$$g(x,y) = \text{med}[f(x-k,y-l)] \quad k,l \in W \quad (3)$$

式中: $\text{med}$ 函数用于求取当前二维滑动窗口中的像素中值; $f(x,y), g(x,y)$ 分别为原始绝缘子图像和经过中值滤波处理后图像在 $(x,y)$ 像素点处的取值; $W$ 为二维中值滤波模板层,可选取 $3 \times 3$ 或 $5 \times 5$ 区域。

本小节分别使用高斯滤波、递归滤波以及中值滤波算法对图5中经过三通道分解后的绝缘子R通道图像进行滤波操作。相比于高斯滤波以及递归滤波而言,中值滤波能够更好地凸显图像中的裂纹的边缘处,这更有利于构建神经网络

训练集以及提升网络整体的训练精度。因此,本文选用中值滤波算法对变电设备绝缘子图像进行滤波处理。

## 2.3 图像标准化处理

为满足RCNN对输入数据的要求,经过中值滤波后的单通道图片还需要进行标准化处理<sup>[18]</sup>。

标准化将输入图片的矩阵转换为统一大小,并将统一大小后的图片进行正则化处理<sup>[19]</sup>,本文使用最常见的最大最小值归一化方法,如下式所示:

$$\text{norm} = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (4)$$

式中: $x_i$ 为单通道图像像素点值; $\min(x), \max(x)$ 分别为图像像素的最大与最小值; $\text{norm}$ 为单个像素点正则化之后的值。

经过标准化处理后的单通道图像,大小一致,并且单个像素点的取值范围从0~255已经转化为0~1了,这对于后续神经网络的处理和收敛速度有很大的提升<sup>[20]</sup>。

## 3 RCNN设计与训练

### 3.1 RCNN设计

所采集到的绝缘子裂纹图片均为 $512 \times 512 \times 3$ (长512像素、宽512像素、3个颜色通道的彩色图片),RCNN需要完成两项判断任务:某一张图片上是否有裂纹;如果某一张图片上有裂纹,那么裂纹的位置和长宽是多少。因此,网络的训练可以看作是双目标优化问题,目标函数如下式:

$$\min: L(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_{i=1}^{N_{\text{cls}}} L_{\text{cls}}(\{p_i\}, \{p_i^*\}) + \frac{1}{N_{\text{reg}}} \sum_{i=1}^{N_{\text{reg}}} L_{\text{reg}}(\{t_i\}, \{t_i^*\}) \quad (5)$$

其中

$$\begin{cases} L_{\text{cls}}(\{p_i\}, \{p_i^*\}) = p_i \log(p_i^*) \\ L_{\text{reg}}(\{t_i\}, \{t_i^*\}) = \begin{cases} 0.5(t_i - t_i^*) & |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5 & \text{其他} \end{cases} \end{cases} \quad (6)$$

式中: $\{p_i\}, \{p_i^*\}$ 分别为网络输出分类、期望的网络输出分类; $\{t_i\}, \{t_i^*\}$ 分别为网络输出的裂纹位置、期望的网络输出的裂纹位置; $N_{\text{cls}}$ 为类别的数量; $N_{\text{reg}}$ 为输出的像素点数; $L_{\text{cls}}(\cdot)$ 为用于分类的交叉熵函数; $L_{\text{reg}}(\cdot)$ 为用于回归的平滑函数。

所设计的CNN网络参数如表1所示,共设计

4个卷积层和7个全连接层,其中,FC3-Classifier以SoftMax产生的结果作为输入图片在裂纹上的得分,FC3-Regressor以 bounding box 的中心及长宽作为裂纹定位的得分。其中,第1层卷积的卷积核为最小绝缘子裂纹的尺寸7×17×3,并配置24

个卷积核。各层卷积核滑窗间隔设置情况:第一层卷积核的滑窗间隔为3,第2层卷积核滑窗间隔为2,第3、第4层卷积核的滑窗间隔为1。神经元激活函数采用ReLU。按卷积运算,可得各层卷积的参数,见表1。

表1 RCNN结构与参数设计

Tab.1 RCNN structure and parameter design

输入	卷积层	内核大小	内核数量	滑动步长	填充像素	输出	参数量/K	占内存大小/Kb
512×512×3	CONV1	7×17×3	24	3	0	169×166×24	8.37	768.00
169×166×24	MAX POOL1	3×3		2	0	84×83×24		658.81
84×83×24	NORM1							162.74
84×83×24	CONV2	5×5×24	72	1	2	84×83×72	42.19	162.74
84×83×72	MAX POOL2	3×3		2	0	42×41×72		488.23
42×41×72	NORM1							119.15
42×41×72	CONV3	3×3×72	96	1	1	42×41×96	60.75	119.15
42×41×96	CONV4	3×3×96	96	1	1	42×41×96	81.00	158.86
42×41×96	MAX POOL3	3×3		2	0	20×20×96		158.86
20×20×96	FC1					1 024	38 717	37.81
1 024	FC2					1 024	1 024	1 024.00
1 024	FC3-Classifier					1	1	1.00
1 024	FC3-Regressor					512×512×1	262.14	512.00

### 3.2 模型训练

整个网络的训练过程分为4个步骤,如下:

- 1) 预处理原绝缘子开裂图片并手工标注标签,以生成原始训练数据集和标签集;
- 2) 将原始训练数据集标准化并分为训练集、测试集以及验证集3个部分;
- 3) 创建网络并进行训练;
- 4) 等待训练结果并获取训练模型。

由于所面对的问题是判断绝缘子裂纹的有无和定位,所以在标注数据集时只需单个标签。

## 4 实验算例分析

### 4.1 数据集

实验中,通过高精度工业摄像机等设备,进行512×512分辨率的绝缘子图像采集,并将信息通过通信网络传输到后台系统。后台系统的服务器硬件设备CPU为Intel corei5-6400,GPU为GTX1080。在后台系统中采用Python实现绝缘子裂纹检测算法。绝缘子裂纹图像识别的原始数据集如图6所示。

### 4.2 单张裂纹图片识别效果

将准备好的待预测图片预处理,并标准化后输入至训练好的CNN中,取得相应的裂纹位置以及FC层输出值后还原至原输入图像中,获取处理后的结果图。最终,获取处理后的R,G,B各通道结果图如图7所示。

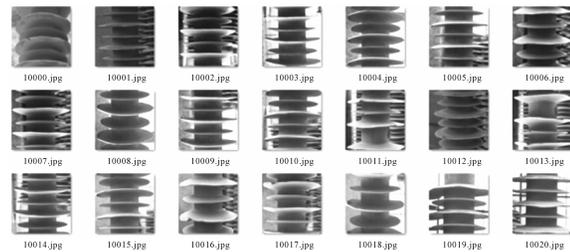


图6 部分绝缘子开裂图像识别原始数据集

Fig.6 Partial insulator cracking image recognition raw data set

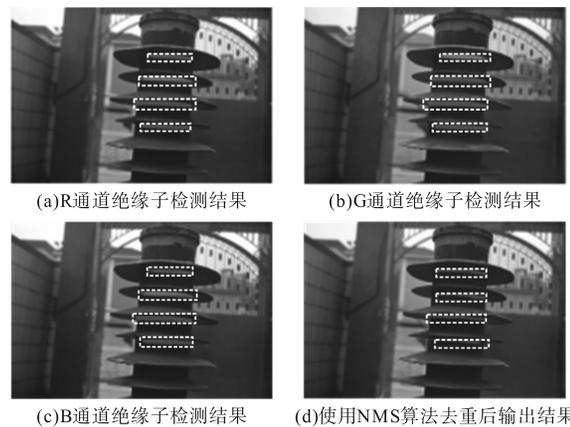


图7 网络检测输出结果图

Fig.7 Effect diagrams of actual crack identification

分析图7a~图7c可知,R,G,B各个通道的分量均对绝缘子的裂纹缺陷部位进行了准确的识别,但由于各个通道色彩以及通道分量数据的差别,导致网络在阈值为0.5的条件下的识别在R通道和B通道的检测结果中出现了重复的输出。

以图片左上角为原点,在忽略输出像素点

pixel信息的条件下,在阈值为0.5条件下,网络输出坐标中心、检测框长宽以及R,G,B 3通道输出缺陷置信度数据。通过NMS算法进行检测框去重后,对应输出坐标中心 $(x,y)$ 、检测框长宽 $(w,h)$ 以及各缺陷检测置信度数据,如表2所示。

表2 经过去重后的网络检测输出结果

输出列表	坐标中心 ( $x,y$ )	检测框长宽 ( $w,h$ )	输出置信度 ( $\geq 50.00\%$ )/%	输出来源
i.crack	(1 703,901)	(759,107)	67.99	G通道
ii.crack	(1 822,615)	(645,93)	66.43	R通道
iii.crack	(1 571,1 206)	(854,118)	64.78	B通道
iv.crack	(1 744,1 535)	(650,77)	57.65	G通道

最后,使用Soft-NMS算法去除掉输出检测框重叠区域获得的数据在缺陷检测原图绘制结果,并获得图像分割检测结果,如图7d中虚线框中所示。

从图7中可以看出,使用RCNN网络成功检测到了R,G,B 3个单通道的绝缘子裂纹缺陷,并在原绝缘子开裂图片中还原出了裂纹区域,并且在原图中标记。同时,由于网络最终的输出来自于各个通道经过NMS算法去重后的结果,因此相比于传统单张彩色通道图像进行预测,使用RGB 3个单通道进行绝缘子裂纹缺陷检测,可以提高裂纹检测精度。

#### 4.3 100张裂纹图片的识别效果

构造一个包含100张绝缘子图片的测试集,其中95张图片中的绝缘子带有裂纹,5张图片中的绝缘子不带裂纹。对训练好的网络进行测试,测试结果如表3、表4所示。

表3 原RCNN测试结果

Tab.3 Original RCNN test results

图片集	图片总数	实际裂纹数量	RCNN输出	裂纹识别准确率/%	误判裂纹数
全集	100	242	227	93.80	-17
带裂纹集	95	242	226	93.39	-16
无裂纹集	5	0	1	—	+1

表4 改进卷积核RCNN测试结果

Tab.4 Improved convolutional kernel RCNN test results

图片集	图片总数	实际裂纹数量	RCNN输出	裂纹识别准确率/%	误判裂纹数
全集	100	242	241	99.59	-1
带裂纹集	95	242	240	99.17	-2
无裂纹集	5	0	0	—	0

从表3和表4可以知道,经过改进卷积核的RCNN的识别准确率大于99%,比原RCNN上升

了5.8%,证明本文的卷积核改进对裂纹检测的准确性有一定的提升。

## 5 结论

由于绝缘子结构不紧密、多晶体共存、玻璃液分配不均匀等原因,难免有细微的空隙布满瓷件内,长期的机械负荷作用下会导致瓷件内微孔逐渐渗透而扩展成小裂纹,进而逐渐发展为大裂缝甚至破损。人为破坏也会导致绝缘子裂纹或大面积断裂,极易产生电击穿事故,最终造成机械强度和绝缘性下降,直至变成零值。因此,一旦检测发现绝缘子存在裂纹或破损,应立即更换,以免发生事故。

本文立足于绝缘子裂纹图像信息采集的实际,改进了CNN卷积核,设计了一套RCNN的复合绝缘子裂缝特征检测方法。根据裂纹在图像中的形状规律,改进CNN卷积核;再针对训练样本不足的问题,通过RGB三通道滤波等技术扩充绝缘子裂纹图像样本集;随后利用样本集训练得到RCNN。在进行绝缘子裂纹缺陷检测时,先将图像分解为单通道图像进行预处理操作后输入RCNN,随后采用NMS算法合并3个通道的输出结果,最后完成对绝缘子图像裂纹的分割提取以及裂纹长度、宽度的检测。实验证明,卷积核改进后的RCNN的绝缘子裂纹缺陷检测方法能够在图像样本数据量不大的情况下,实现准确率高达99.6%的裂缝检测。这有助于绝缘子裂缝缺陷的非接触、在线监测的实现,并为变压器运行绝缘子的故障诊断、无人值守变电站以及机器人智能识别绝缘子开裂提供新的思路。

## 参考文献

- [1] 黄新波,陈贵荣,王孝敬,等. 输电线路在线监测与故障诊断[M]. 第2版. 北京:中国电力出版社,2014:206-232.  
HUANG Xinbo, CHEN Guirong, WANG Xiaojing, et al. Shu dian xian lu zai xian jian ce yu gu zhang zhen duan[M]. 2nd Edition. Beijing:China Electric Power Press,2014:206-232.
- [2] 唐捷,俸波. 一起220 kV复合绝缘子断裂故障分析[J]. 广东电力,2017,30(9):122-124.  
TANG Jie, FENG Bo. Analysis on one fracture fault of 220 kV composite insulator[J]. Guangdong Electric Power,2017,30(9):122-124.
- [3] 苏国磊,陈欢,韩玉康,等. 运行20年以上500 kV输电线路绝缘子运行及抽检分析[J]. 广东电力,2015,28(5):103-108.

- SU Guolei, CHEN Huan, HAN Yukang, et al. Analysis on operation and spot check on insulators on 500 kV power transmission lines running for 20 years[J]. *Guangdong Electric Power*, 2015, 28(5): 103-108.
- [4] 邱志斌, 阮江军, 黄道春, 等. 输电线路悬式瓷绝缘子老化形式分析与试验研究[J]. *高电压技术*, 2016, 42(4): 1259-1267.
- QIU Zhibin, RUAN Jiangjun, HUANG Daochun, et al. Study on aging modes and test of transmission line porcelain suspension insulators[J]. *High Voltage Technology*, 2016, 42(4): 1259-1267.
- [5] 康俊霞, 夏文忠. 图像识别在电力信息化中的应用[J]. *电气传动*, 2019, 49(12): 121-121.
- KANG Junxia, XIA Wenzhong. Application of image recognition in electric power informatization[J]. *Electric Drive*, 2019, 49(12): 121-121.
- [6] 李新海, 徐宝军, 范德和, 等. 变电站设备状态智能识别系统技术研究[J]. *电气传动*, 2021, 51(24): 33-39.
- LI Xinhai, XU Baojun, FAN Dehe, et al. Research on intelligent identification system technology of substation equipment status[J]. *Electric Drive*, 2021, 51(24): 33-39.
- [7] 马敏. 基于图像处理的绝缘子破损识别[D]. 石家庄: 石家庄铁道大学, 2019.
- MA Min. Identification of insulator damage based on image processing[D]. Shijiazhuang: Shijiazhuang Tiedao University, 2019.
- [8] 单成, 吴洪潭, 石成龙, 等. 图像处理中的绝缘子缺陷检测方法[J]. *中国计量学院学报*, 2010, 21(4): 297-300, 304.
- SHAN Cheng, WU Hongtan, SHI Chenglong, et al. Defect detection method on insulators by image processing[J]. *Journal of China University of Metrology*, 2010, 21(4): 297-300, 304.
- [9] 侯志强, 刘晓义, 余旺盛, 等. 基于双阈值-非极大值抑制的Faster R-CNN改进算法[J]. *光电工程*, 2019, 46(12): 82-92.
- HOU Zhiqiang, LIU Xiaoyi, YU Wangsheng, et al. Improved algorithm of Faster R-CNN based on double threshold-non-maximum suppression[J]. *Opto-Electronic Engineering*, 2019, 46(12): 82-92.
- [10] 高国荣, 李文敏, 潘琼. 基于边缘检测与归一化相关矩的图像融合方法[J]. *计算机工程与应用*, 2008, 44(27): 194-196.
- GAO Guorong, LI Wenmin, PAN Qiong. Image fusion based on wavelet edge detection and normalized correlation moment[J]. *Computer Engineering and Applications*, 2008, 44(27): 194-196.
- [11] 王鑫, 宁晨, 罗斌. 一种基于归一化割的图像分割算法[J]. *计算机应用研究*, 2007(2): 165-166.
- WANG Xin, NING Chen, LUO Bin. Method of image segmentation based on normalized cuts[J]. *Application Research of Computers*, 2007(2): 165-166.
- [12] 孙晖. 一种基于去均值归一化约束的图像复原算法[D]. 哈尔滨: 哈尔滨工业大学, 2015.
- SUN Heng. An image restoration algorithm based on mean subtracted contrast normalized constraint[D]. Harbin: Harbin Institute of Technology University, 2015.
- [13] 王梦. 基于绝缘子图像的缺陷检测方法研究[D]. 武汉: 华中科技大学, 2019.
- WANG Meng. Study on the method of fault detection based on insulator images[D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [14] KOSTKOVÁ Jitka, FLUSSER Jan, MATĚJ Léb, et al. Handling gaussian blur without deconvolution[J]. *Pattern Recognition*, 2020, 103: 107264.
- [15] NETO N, STEFENON S F, MEYER L, et al. A study of multi-layer perceptron networks applied to classification of ceramic insulators using ultrasound[J]. *Applied Sciences*, 2021, 11(4): 1592.
- [16] 王孝余, 韩冰, 李丹丹, 等. 基于视觉的绝缘子缺陷检测方法[J]. *计算机工程与设计*, 2019, 40(12): 3582-3587.
- WANG Xiaoyu, HAN Bing, LI Dandan, et al. Vision based insulator defect detection method[J]. *Computer Engineering and Design*, 2019, 40(12): 3582-3587.
- [17] CHANG C C, HSIAO J Y, HSIEH C P. An adaptive median filter for image denoising[C]//The 2008 Second International Symposium on Intelligent Information Technology Application (IITA), IEEE Conference Publications, 2008, 2: 346-350.
- [18] 崔克彬. 基于图像的绝缘子缺陷检测中若干关键技术研究[D]. 北京: 华北电力大学(北京), 2016.
- CUI Kebin. Research on the key technologies in insulator defect detection based on image[D]. Beijing: North China Electric Power University, 2016.
- [19] 罗建军, 刘振声, 龚翔, 等. 基于无人机图像与迁移学习的线路绝缘子状态评价方法[J]. *电力工程技术*, 2019, 38(5): 30-36.
- LUO Jianjun, LIU Zhensheng, GONG Xiang, et al. Insulator state evaluation method based on UAV image and migration learning[J]. *Electric Power Engineering Technology*, 2019, 38(5): 30-36.
- [20] 陈文浩, 姚利娜, 李丰哲. 无人机电网巡检中的绝缘子缺陷检测与定位[J]. *计算机应用*, 2019, 39(S1): 210-214.
- CHEN Wenhao, YAO Lina, LI Fengzhe. Insulator defect detection and location in UAV grid inspection[J]. *Journal of Computer Applications*, 2019, 39(S1): 210-214.

收稿日期: 2022-07-11

修改稿日期: 2022-09-06