




DOI: 10.12086/oe.2021.200072

基于VGGNet算法的绝缘子无损检测

马立新*, 豆晨飞, 宋晨灿, 杨天笑

上海理工大学机械工程学院, 上海 200093



摘要: 针对电力系统中存在的难以检测运营中的绝缘子劣化问题, 本文在深入分析卷积神经网络模型的原理和结构的基础上, 运用卷积神经网络算法对绝缘子劣化程度进行评估。通过绝缘子工频闪络试验使其产生无放电、弱放电、强放电三种状态, 并使用紫外成像仪采集不同放电状态下的绝缘子紫外图像构建紫外图像样本库。利用VGGNet框架神经网络算法对样本进行分类训练和状态预测评估, 最终达到判断绝缘子是否劣化的目的。由实验结果可知, 该算法准确率高达98.4%, 在绝缘子劣化检测上有广泛的应用前景, 并为其他电力设备的可靠性检测提供了思路。

关键词: 卷积神经网络; 紫外放电; 无损检测; 绝缘子

中图分类号: TP391; TB866

文献标志码: A

马立新, 豆晨飞, 宋晨灿, 等. 基于VGGNet算法的绝缘子无损检测[J]. 光电工程, 2021, 48(1): 200072

Ma L X, Dou C F, Song C C, et al. Insulator nondestructive testing based on VGGNet algorithm[J]. *Opto-Electron Eng*, 2021, 48(1): 200072

Insulator nondestructive testing based on VGGNet algorithm

Ma Lixin*, Dou Chenfei, Song Chencan, Yang Tianxiao

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: In the power system, it is difficult to detect the insulator's deterioration in operation. Aiming at this problem, this thesis applies the convolution neural network algorithm to evaluate the insulator's deterioration degree based on the deep analysis of the principle and structure of the convolution neural network model. Firstly, the power frequency flashover test was conducted on the insulator to produce three states as follows: no discharge, weak discharge, and strong discharge. Moreover, the Ultraviolet imager was applied to collect the insulator's ultraviolet images in different discharge state to establish the ultraviolet images sample library. Subsequently, the VGGNet framework neural network algorithm was applied to perform the classification training and the state-prediction evaluation on the samples so as to eventually achieve the purpose of judging whether the insulator is degraded. From the experimental results, it can be seen that the accuracy rate of the algorithm is as high as 98.4%, which has broad application prospects in the insulator's degradation detection. Furthermore, it provides a mentality for the reliability detection of other power equipments.

Keywords: CNN; ultraviolet discharge; nondestructive testing; insulator

收稿日期: 2020-03-06; 收到修改稿日期: 2020-05-19

基金项目: 国家自然科学基金资助项目(61205076)

作者简介: 马立新(1960-), 男, 博士, 教授, 主要从事电气系统故障诊断与模式识别等的研究。E-mail: ma_eeepsi@163.com

版权所有©2021 中国科学院光电技术研究所

1 引言

我国是一个电力大国,电力系统结构复杂,而电力系统的供电可靠性关系到国计民生,为了维持电力系统的稳定性以及可靠性,需要拥有各种可靠稳定的设备,绝缘子就是其中一种。绝缘子是安装在不同电位的导体或导体与接地构件之间的能够耐受电压和机械应力作用的器件,其主要功能是实现电气绝缘和机械固定,是电力系统中的重要设备^[1]。绝缘子绝缘性能的完好与否,影响整条线路的使用寿命和安全运行。因此,如何准确快速的检测运营中的绝缘子劣化程度,是一个重要的研究方向。

近年来,各种各样的绝缘子检测算法层出不穷,如文献[2]提出的基于红外成像法的检测算法,文献[3]提出的基于彩色可见光的绝缘子缺陷检测方法等。但基于红外成像的方法容易受到外界环境的影响,如在雨雪等条件下,红外辐射较低,难以检测。而基于视觉的绝缘子缺陷检测方法,由于存在背景因素干扰,如在强光或弱光等情况下,很难进行闪络点的精确定位和分析。

由于运营中的绝缘子在绝缘劣化时,往往会产生放电闪络(下文简称闪络)现象。闪络是指固体绝缘子周围的气体或液体电介质被击穿时,沿固体绝缘子表面放电的现象,也被称为沿表面放电闪络^[3]。闪络过程一般分为以下四个阶段:在第一阶段,会以放电端为中心,间歇性显示出一个范围较小、亮度微弱的圆形光斑,其放电程度相对较弱;在第二个阶段,放电中产生的光的光斑分布更均匀,并产生轻微的树枝放电火花;在第三阶段,树枝放电火花长度大大增加,放电增强,日光下可清晰看到放电火花;第四阶段则是发生击穿现象,绝缘层彻底击穿^[4]。发生闪络时,会伴随有紫外光的产生,其光谱在可见光(400 nm~700 nm)之外即“日盲”区(240 nm~280 nm)内,可采用紫外检测设备采集其紫外图像。与红外检测、视觉检测等方法相比,紫外图像不受户外温度,湿度以及光线强弱的影响,可准确识别放电状态,故分析紫外放电图像成为理想的绝缘子劣化状态检测手段^[5]。

随着深度学习技术的发展,基于深度学习的绝缘子检测方法也引起了许多学者的关注^[6-8]。2012年,多伦多大学的 Alex Krizhevsky 等人提出了一个基于深度学习的卷积神经网络(convolutional neural networks, CNN)模型框架,称作 AlexNet。并在当年的 ILSNRC 赢得冠军。AlexNet 展示了 CNN 模型在图像识别领域

的巨大优势。与传统机器学习算法相比,其无需对输入图像进行预处理,且由于其采用局部连接、权值共享、下采样等方式,大大降低了模型所需要训练的参数数量,更快地实现模型训练和测试^[9-10]。文献[9]即采用 AlexNet 框架的 CNN 算法(下文简称 AlexNet 进行绝缘子劣化状态检测。

随着人们对 CNN 研究的不断深入,2014年,牛津大学 Visual Geometry Group 和 Google DeepMind 公司的研究员共同提出了 VGGNet 框架,它探索了卷积神经网络的深度和其性能之间的关系,通过反复的堆叠 3×3 的小型卷积核和 2×2 的最大池化层,成功构建了 16~19 层深的卷积神经网络^[7]。相比于 AlexNet 框架,VGGNet 框架可通过多次非线性变换提高卷积核对特征的抽取,参数量更少,方便计算和储存,进一步提高识别的正确率。本文所做的工作,即在对绝缘子放电特性和不同闪络等级的分类进行了研究的基础上,运用 VGGNet 框架的 CNN 算法(下文简称 VGGNet)检测绝缘子的劣化程度并与其他算法进行对比分析。

2 紫外放电样本库的构建

CNN 模型具有复杂的结构和大量的参数,这意味着需要大量的紫外图像作为训练样本。因此需要进行大量的闪络实验,将其不同放电阶段的紫外图像进行分类,生成不同放电阶段的紫外图像样本库,此样本库用于 CNN 模型的培训和测试。构建的样本库在很大程度上决定了网络的收敛性、泛化能力以及其他特征。本节将介绍样本库的生成方法。

2.1 闪络试验平台构建

为了获得不同闪络阶段绝缘子的紫外图像,对绝缘子进行闪络试验:选择一个绝缘子,以一台 150 kV/220 mA 带高压保护电阻的工频试验变压器为加压电源,首次将样本的功率提高到发生闪络估计电压的 75%,并对其进行分析。然后每秒提高 2%电压,直到最后发生闪络。其原理图如图 1 所示。

2.2 闪络实验样本库构建

在对绝缘子施加电压的过程中,利用 FILIN-6 紫外成像仪记录其闪络过程,提取出每一帧视频。由于闪络击穿时间较短,与无放电、电晕放电、火花放电(共三类)相比,产生的闪络击穿样品较少。如果将其分为一类,对训练得到的神经网络模型的稳定性产生更为严重的影响,且由于闪络击穿状态是指绝缘子电绝缘的瞬间损耗,其预警意义不大^[11-13]。因此只选择将样

品库分为无放电、弱电晕放电和强放电三种类型。其中，无放电表示绝缘子绝缘性能良好无劣化，可安全稳定运行；弱电晕放电表示绝缘子绝缘劣化程度较低，仍可正常运行，需保持高度关注；强放电表示绝缘子绝缘劣化程度严重，需及时更换，以免发生运行故障。

在瓷绝缘子闪络试验中，所有的实验共获得 4377 帧紫外图像：将其中的 3800 帧图像组成训练集，577 帧组成测试集(测试集是一组用于验证训练模型准确率的图像集合，与训练集相互独立)。在 3800 帧的训练集中，无放电类型有 376 帧，弱放电类型有 1939 帧，强放电类型有 1485 帧。在 577 帧的测试集中，无放电类型有 87 帧，弱放电类型有 337 帧，强放电类型有 153 帧。

用于训练的样本如图 2 所示：(a)为强放电组：可以在绝缘体表面观察到许多强放电通道；(b)为弱电晕放电组：可见于导线高压侧、绝缘子钢脚、双伞间的电晕裂纹；(c)为无放电组：无放电时，无放电发光现象。

3 基于深度学习的绝缘子无损检测模型

3.1 模型结构及参数

VGGNet 的结构及参数如图 3 和表 1 所示。其输入为 224×224 的图像，经过 5 段卷积层处理，每段都把多个卷积网络串联在一起，每个卷积层后均跟有




图 1 闪络试验原理图

Fig. 1 Principle diagram of the flashover test

ReLU 激活函数(表 1 默认在卷积层)，使得模型对特征学习能力更强。在每段卷积层后为池化层，其采用 max pooling，共有 5 层。卷积层之后是三个全连接层，前两个全连接层均有 4096 个通道，第三个全连接层有 1000 个通道，所有全连接层配置相同。全连接层后是输出层，采用 Softmax 函数进行分类。该模型不使用局部响应标准化，这种标准化并不能再提升性能，反而会导致更多的内存消耗和计算时间。下面介绍这些结构层的具体实现。

3.1.1 卷积层

卷积层是一个抽象的特征提取层，由若干卷积核组成。卷积运算的目的是提取输入的不同特征，低层卷积网络可能只能提取一些低级的特征如边缘、线条和角等，而多层的网络能从低级特征中迭代提取更复杂的特征^[14]。

卷积层的正向传播计算如下式：

$$a_j^i = \sigma(\sum_{i \in M_j^i} a_i^{(l-1)} \times k_{ij}^l + b_j^l) \quad (1)$$

式(1)表示卷积计算前后特征图的变化。其中 M_j^i 表示所选输入的卷积特征图，对所选输入的特征图，用若干个卷积核 k_{ij}^l 对输入图进行卷积处理，经过卷积计算后，再加一个偏移量 b_j^l 来完成卷积层的计算。在卷积操作中，每个卷积核都相当于一种滤波器，负责提取不同种类的特征。其中，浅层卷积核提取的特征，具有较强的位置性，深层卷积核提取的特征则具有较强的语义性。




图 2 紫外放电样本图。(a) 强放电；(b) 弱放电；(c) 无放电

Fig. 2 Ultraviolet discharge sample diagram.

(a) Strong discharge; (b) Weak discharge; (c) No discharge




图 3 VGGNet 模型结构

Fig. 3 VGGNet model structure

表 1 VGGNet 模型参数
Table 1 VGGNet model parameters

层数	层名	卷积核参数			输出参数		
		数量	尺寸	步长	长度	宽度	深度
0	输入层	-	-	-	224	224	3
1	卷积层	64	3	1	224	224	64
2	卷积层	64	3	1	224	224	64
3	池化层	-	2	2	112	112	64
4	卷积层	128	3	1	112	112	128
5	卷积层	128	3	1	112	112	128
6	池化层	-	2	2	56	56	128
7	卷积层	256	3	1	56	56	256
8	卷积层	256	3	1	56	56	256
9	卷积层	256	3	1	56	56	256
10	池化层	-	2	2	28	28	256
11	卷积层	512	3	1	28	28	512
12	卷积层	512	3	1	28	28	512
13	卷积层	512	3	1	28	28	512
14	池化层	-	2	2	14	14	512
15	卷积层	512	3	1	14	14	512
16	卷积层	512	3	1	14	14	512
17	卷积层	512	3	1	14	14	512
18	池化层	-	2	2	7	7	512
19	全连接层	-	-	-	1	1	4096
20	全连接层	-	-	-	1	1	4096
21	全连接层	-	-	-	1	1	1000
22	输出层	-	-	-	1	1	3

3.1.2 激活函数

卷积操作的输出均为上层函数的线性输出。若模型中只存在卷积层，则无论其深度有多少，其输出均是基于权重和偏移量做线性变换，缺乏对复杂任务的处理能力，因此需要使用激活函数来引入非线性因素，使其模型可以任意逼近任何非线性结构，从而具有处理复杂数据的能力。在 CNN 网络中，ReLU(rectified linear unit)函数较为常用，其公式为

$$f(x) = \max(0, x) \quad (2)$$

该函数输入小于 0 时，其输出为 0，输入大于 0 时，输出等于输入。与传统神经网络常用的 sigmoid 函数相比，ReLU 函数图像具有单侧不对称结构，不会导致梯度消失，且功能简单，计算速度快。

3.1.3 池化层

经过卷积操作后得到的特征图，具有大量的特征参数，为了防止模型过拟合，需要减少其中非必要特征参数，只保留主要特征，基于此引入池化操作。

池化操作主要对特征图进行空间压缩，从而提高

特征图的感受野，降低其参数数量。池化操作与卷积操作相比，其操作改变原特征图维度，并不改变原特征图深度^[14]。本文中采用池化方式为最大池化(max pooling)。其公式为

$$x_j^l = f(\beta_j^l s_{\text{down}}(x_j^{l-1}) + b_j^l) \quad (3)$$

式中： s_{down} 表示一个下采样函数， β_j^l 表示比例偏差， b_j^l 表示水平偏差。

3.1.4 全连接层

全连接层在整个卷积神经网络中起到“分类器”的作用。卷积层、池化层和激活函数层等操作是将原始数据映射到隐层特征空间，其后全连接层将其学到的“分布式特征表示”映射到样本标记空间^[15]。其公式为

$$y_j^l = \beta_i^j x_i^{l-1} \quad (4)$$

式中： x_i^{l-1} 表示第 $l-1$ 层第 i 个单元， β_i^j 表示第 i 个单元到下层 j 单元的权重。

3.1.5 Soft-max 分类函数

在该网络中，最终目的是识别绝缘子放电层度，

故在该网络最后一层中。利用 Soft-max 分类函数得到分类概率, 从而将其分为概率最高的一类。公式如下:

$$f_{\text{soft-max}} = -\sum_i^I \sum_j^J c_{ij} \log(p_{ij}), \quad (5)$$

式中: I 表示样本数, J 表示类别数, c_{ij} 表示样本 i 对应的类别 j 的标签编码, p_{ij} 表示样本 i 预测为类别 j 的概率。

3.2 模型训练过程

CNN 可以理解为输入与输出之间的一种黑箱映射: 它们通过学习大量的数据样本建立更精确的映射关系, 而不需要传统的模式识别来手工确定参数的特征。在 CNN 训练初始化阶段, 需要对所有连接权值进行随机初始化, 以确保训练过程不会由于网络模型训练中权值过大而导致不收敛和失败的状态^[6]。在模型训练过程中, CNN 采用反向传播算法训练前馈网络。反向传播算法主要包括前向传播和反向传导。

在模型训练之前, 将无放电、弱电晕放电和强火花放电图像标记为 0、1 或 2, 以表示这三种放电类型。

步骤一: 前向传播

将样本库中的紫外图像作为输入, 在 CNN 模型中经过一系列卷积等计算, 如图 3 所示, 得到并输出训练结果。

步骤二: 反向传导

在反向传导步骤中, 根据输入的紫外图像的实际值(0、1 或 2)和前向传播得到的输出值, 得到训练误差 E , 并将训练误差在网络参数中的导数反向。训练误差 E 对于偏差 b 的偏导公式为

$$\frac{\partial E}{\partial b} = \frac{\partial E}{\partial u} \frac{\partial u}{\partial b} = \frac{\partial E}{\partial u} = \delta \quad (6)$$

当 $\partial u / \partial b = 1$ 时, 式(6)中变量 δ 可表示训练误差 E 相对于偏差 b 变化的变化灵敏程度。对于输出层, δ 为: $\delta^{n-1} = \sigma'(u^{n-1}) \cdot (y^n - t^n)$ 。对于中间层 l

($1 < l < n_l - 1$), δ 为: $\delta^l = (W^{l+1})^T \delta^{l+1} \cdot \sigma'(u^l)$ 。根据各层变化的 δ , 可得到其训练误差与层级连接权重 W 的偏导数为: $\partial E / \partial W^l = \alpha^{l-1} (\delta^l)^T$ 。以该偏导数乘以负学习率即可得到对应层的神经元权值的更新值: $\Delta W^l = -\eta (\partial E / \partial W^l)$ 。

CNN 模型训练开始时, 对权重进行随机初始化, 并从训练样本库中提取输入样本数据, 重复前向传播和反向传导过程。经过多次迭代, 最终收敛完成模型训练过程。

4 结果分析

4.1 正确率分析

为了达到最佳训练效果, 设置训练率参数, 实现优化的训练模型。在训练过程中, 使用的训练率为 0.01、0.005、0.001、0.0005 和 0.0001, 其部分正确率对比如表 2 所示。

从表 2 中可得其正确率与训练次数基本上呈正相关, 但模型最终正确率与也训练率的选择有关。一般来说, 合适的模型训练率对于 CNN 模型的最终正确率至关重要, 偏高或偏低的训练率会导致其难以达到最高正确率。如图 4 所示, 当训练率为 0.001 时, 模型可实现快速收敛, 正确率高达 98.4%。而随着训练率的增加, 如 0.01 和 0.005 时, 模型正确率反而会降低, 正确率仅为 66.1%和 60.2%, 这是由于训练率过高时会导致待优化的参数在最优值附近波动, 无法调整到最优值。而随着训练率的降低, 如 0.0005 和 0.0001 时, 最终准确率分别为 97.3%和 80.5%, 这是由于训练率过低, 导致待优化参数收敛过慢, 未能达到最优值。

为了衡量模型在训练过程中的收敛速度和训练精度。这里使用标准差函数作为模型的损失函数:

表 2 不同训练率下正确率对比
Table 2 Comparison of correctness rates under different training rates

训练次数	训练率				
	0.01	0.005	0.001	0.0005	0.0001
1000	0.488	0.843	0.883	0.855	0.765
2000	0.517	0.876	0.913	0.864	0.773
3000	0.503	0.635	0.935	0.883	0.812
4000	0.537	0.724	0.947	0.621	0.873
5000	0.661	0.602	0.984	0.973	0.905




图 4 不同训练率下 CNN 正确率趋势图

Fig. 4 Trend chart of CNN correctness rate under different training rates

$$E_{total} = \sum \frac{1}{2} (T_{target} - M_{output})^2, \quad (7)$$

其中： T_{target} 表示训练样本的实际值， M_{output} 表示模型前向传播输出的实际值，其部分结果如表 3 和图 5 所示。

表 3 和图 5 表明，随着训练次数的增加，不同训练率下的标准差均呈现下降趋势，且标准差在训练率为 0.001 和 0.005 时，收敛较快，标准差较低；在训练率高达 0.01 或者训练率低至 0.0001 时，标准差波动范围大，模型不能有效收敛。

综上对比分析可得，选择训练率为 0.001 时，模型具有较高的正确率和较快的收敛速度。

4.2 方法对比分析

与文献[3]所使用的 BP 算法和文献[9]所使用的 AlexNet 算法两种神经网络模型算法进行对比，分别设置训练率为 0.01、0.005、0.001、0.0005 和 0.0001，正确率对比结果如图 6 所示，其标准差对比结果如图 7 所示。

从图 6 可以看出，VGGNet 算法和 AlexNet 算法在训练率为 0.001 时，BP 算法在训练率为 0.005 时，

达到最高正确率。但 VGGNet 算法的最高正确率为 98.4%，比 AlexNet 算法的最高正确率 96.8% 高 1.6%，比 BP 算法高 6.1%。从图 7 可以看出，VGGNet 算法和 AlexNet 算法收敛效果类似，均强于 BP 算法。这是由于 AlexNet 算法和 VGGNet 算法具有多层卷积结构，具有更好的收敛精度，而 VGGNet 算法相比 AlexNet 算法具有更深卷积层次，对特征提取效果更好，具有更好的分类效果。

为了体现 VGGNet 算法模型的优越性，将其与传统分类算法：BOA-SVM 算法^[16]，和两种深度学习算法——径向基神经网络(RBFNN)、深度信念网络(DBN)进行对比，对比结果如表 4 所示。表中准确率表示各算法在参数最优情况下的最高准确率，训练耗时表示进行一次参数寻优所需时间，测试耗时即为进行一次分类任务所需要的时间。从表 4 可知，VGG 算法在准确率以及耗时上均具有优势。

5 总结与展望

1) 简要介绍了当前常用的绝缘子劣化检测方法以及绝缘劣化时发生的闪络现象。通过绝缘子工频闪

表 3 不同训练率和训练次数下的标准差

Table 3 Mean square deviation at different training rates and numbers

训练次数	训练率				
	0.01	0.005	0.001	0.0005	0.0001
1000	1.2521	0.3132	0.2080	0.8203	0.5301
2000	1.3352	0.1335	0.1389	0.1384	1.0306
3000	0.7846	0.6437	0.1241	0.1618	0.5220
4000	0.6768	0.6461	0.0875	0.1061	0.4010
5000	0.5355	0.5675	0.0712	0.1131	0.3699




图 6 神经网络算法正确率对比
Fig. 6 Algorithm accuracy comparison of the neural network




图 5 不同训练率和训练次数下的标准差趋势图
Fig. 5 Mean square deviation at different training rates and numbers




图 7 神经网络算法标准差对比
Fig. 7 Algorithm standard deviation comparison of the neural network

表 4 算法对比

Table 4 Algorithm comparison

算法	准确率/%	训练耗时/s	测试耗时/s
VGGNet	98.4	274.37	0.0013
BOA-SVM	94.0	883.79	0.1174
RBFNN	92.5	2104.51	0.0169
DBN	97.1	1863.94	0.0471

络试验,建立了绝缘子放电状态类型库。采用深度学习卷积神经网络的方法,对绝缘子的紫外放电图像进行识别分类。

2) 详细介绍了 VGGNet 算法模型的结构及参数,展示了 VGGNet 模型的优点:通过反复堆叠使用感受野为 3×3 的卷积核,提高了模型的非线性,使其具有更强的特征学习能力,对于绝缘子紫外放电图像这种特征差异较小的图像数据,具有较好的识别效果;其次,与采用大尺寸卷积核相比,有效降低了参数数量,使其具有较高的训练效率。

3) 与同为神经网络的 AlexNet 算法、BP 神经网络算法、传统的 BOA-SVM 算法以及两种深度学习算法——径向基神经网络(RBFNN)和深度信念网络(DBN)进行对比,结果表明本文采用的 VGGNet 算法具有准确率更高、训练时间短、模型泛化性能好等优势,可用于电力系统故障诊断领域,为电力设备无损检测提供了新思路。

4) 随着无人机技术与通信技术的发展,具有高机动性、高可控性等特点的无人机成为理想的电力巡检平台,5G 技术的出现,使实时传输高质量图像成为可能。以无人机平台为载体,搭载紫外成像仪,通过 5G 技术实时传输紫外图像,采用无损检测算法进行故障点检测将成为可能。因此,本文所做研究具有广阔的应用前景,未来将在此基础上进一步探索。

参考文献

[1] Lv Z N. A survey of common faults analysis and detection methods for transmission line[J]. *Autom Instrum*, 2020(1): 161–164, 168.
吕志宁. 输电线路常见故障分析与检测方法综述[J]. *自动化与仪器仪表*, 2020(1): 161–164, 168.

[2] Huang Y C, Zheng Y H, Xu P P. Degradation state of composite insulator evaluated by infrared detection technology[J]. *Electrotech Electr*, 2019(6): 48–52.
黄云程, 郑云海, 许萍萍. 应用红外检测技术评估复合绝缘子劣化状态[J]. *电工电气*, 2019(6): 48–52.

[3] Tian Z R, Jin L J. Detection of insulator contamination grades

based on digital image processing[J]. *Adv Technol Electr Eng Energy*, 2015, **34**(9): 70–74.

田治仁, 金立军. 基于彩色可见光图像的绝缘子污秽等级判别[J]. *电工电能新技术*, 2015, **34**(9): 70–74.

[4] Ma L X, Zhou X B, Zhu R, et al. The quantitative classification of corona discharge intensity of UV detection[J]. *Opto-Electron Eng*, 2016, **43**(1): 1–5.
马立新, 周小波, 朱润, 等. 紫外检测电晕放电强度量化分级[J]. *光电工程*, 2016, **43**(1): 1–5.

[5] Asimakopoulou G E, Kontargyri V T, Tsekouras G J, et al. Artificial neural network optimisation methodology for the estimation of the critical flashover voltage on insulators[J]. *IET Sci Meas Technol*, 2009, **3**(1): 90–104.

[6] Pei S T. Analysis and evaluation of insulator operation status based on infrared and ultraviolet imaging detection technology[D]. Beijing: North China Electric Power University (Beijing), 2019.
裴少通. 基于红外紫外成像检测技术的绝缘子运行状态分析与评估[D]. 北京: 华北电力大学(北京), 2019.

[7] Zuo G Y, Ma L, Xu C F, et al. Insulator detection method based on cross-connected convolutional neural network[J]. *Autom Electr Power Syst*, 2019, **43**(4): 101–106.
左国玉, 马蕾, 徐长福, 等. 基于跨连接卷积神经网络的绝缘子检测方法[J]. *电力系统自动化*, 2019, **43**(4): 101–106.

[8] Woon W L, El-Hag A, Harbaji M. Machine learning techniques for robust classification of partial discharges in oil–paper insulation systems[J]. *IET Sci Meas Technol*, 2016, **10**(3): 221–227.

[9] Pei S T, Liu Y P, Ji X X, et al. UV-flashover evaluation of porcelain insulators based on deep learning[J]. *IET Sci Meas Technol*, 2018, **12**(6): 770–776.

[10] Czajka A, Bowyer K W, Krumbick M, et al. Recognition of image-orientation-based iris spoofing[J]. *IEEE Trans Inf For Secur*, 2017, **12**(9): 2184–2196.

[11] Chen Y, Xu Y. Detection and localization of untwisted strands in transmission lines using cascaded shape filtering and color filtering[C]//2015 IEEE Workshop on Signal Processing Systems (SIPS), 2015: 1–6.

[12] Zhang Z J, Zhang W, Zhang D D, et al. Comparison of different characteristic parameters acquired by UV imager in detecting corona discharge[J]. *IEEE Trans Dielectr Electr Insul*, 2016, **23**(3): 1597–1604.

[13] Wang S H, Lv F C, Liu Y P. Estimation of discharge magnitude of composite insulator surface corona discharge based on ultraviolet imaging method[J]. *IEEE Trans Dielectr Electr Insul*, 2014, **21**(4): 1697–1704.

[14] Lin J F. Research on semantic segmentation of remote sensing image based on deep learning[D]. Guangzhou: Guangdong University of Technology, 2019.
林锦发. 基于深度学习的遥感图像语义分割方法研究[D]. 广州: 广东工业大学, 2019.


[15] Pei F. Research on image style migration system based on deep convolutional neural network[D]. Yinchuan: Ningxia University, 2019.
裴斐. 基于深度卷积神经网络的图像风格迁移系统研究[D]. 银川: 宁夏大学, 2019.

[16] Pei S T, Liu Y P, Chen T F, et al. Infrared spectrum diagnosis method of deteriorated insulators based on BOA-SVM[J]. *Electr Meas Instrum*, 2018, **55**(24): 11–16.
裴少通, 刘云鹏, 陈同凡, 等. 基于 BOA-SVM 的劣化绝缘子红外图谱诊断方法[J]. *电测与仪表*, 2018, **55**(24): 11–16.

Insulator nondestructive testing based on VGGNet algorithm

Ma Lixin*, Dou Chenfei, Song Chencan, Yang Tianxiao

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China



VGGNet model structure

Overview: The electricity system structure of our country is very complicated. To maintain the stability and the reliability of the electricity system, we need to have all kinds of reliable and stable equipments, and the insulator is one of them. Insulators are devices which are installed between the conductors of different potentials or conductors and the grounding components. They can also tolerate the effect of voltage and mechanical stress. The main function of the insulators is to realize electrical insulation and mechanical fastening. They are important devices of the electricity system. Whether the insulation function of the insulator is in good condition will influence the lifespan and safely running of the whole circuit. Therefore, how to test the deterioration level of the working insulator is a substantial research topic. What this paper works on is using UV image camera to collect ultraviolet images of the insulators under different discharging states and building an ultraviolet images sample bank. This paper uses the VGGNET framework neural network algorithm to classify the training and statement, and forecast assess the sample in order to estimate whether insulators are deteriorated, and contrast and analysis to other algorithms. VGGNET model: by repeatedly stacking the convolution kernel whose receptive field is 3×3 , the non-linearity of the model is improved, so that it has stronger feature learning ability and better recognition effect for the image data with small feature difference of insulator UV discharge images. In addition, it is better than using the large-scale coil. Compared with the product kernel, it effectively reduces the number of parameters and makes it have higher training efficiency. According to the results of experiment, the accuracy of this algorithm is high up to 98.4%. It has the advantages such as high accuracy, short training time, and the generalization of the model is good. It will have broad using prospects in the deterioration test of the insulators, and it also provides a new way to the reliability testing of other electrical devices. With the development of UAV and communication technology, the UAV with high mobility, high control ability, and other characteristics has become an ideal power inspection platform. The emergence of the 5G technology makes it possible to transmit high-quality images in real time. Taking UAV platform as carrier, equipped with UV imager, transmitting UV image in real time through 5G technology, and using non-destructive detection algorithm to detect the fault points will become possible. Therefore, the research in this paper has broad application prospects, and we will explore further in the future.

Ma L X, Dou C F, Song C C, *et al.* Insulator nondestructive testing based on VGGNet algorithm[J]. *Opto-Electron Eng*, 2021, **48**(1): 200072; DOI: 10.12086/oe.2021.200072

Foundation item: National Natural Science Foundation of China (61205076)

* E-mail: ma_eeepsi@163.com