

DOI:10.13296/j.1001-1609.hva.2020.09.019

基于GoogLeNet Inception-V3模型的电力设备图像识别

徐 凯¹, 梁志坚¹, 张懿议¹, 刘兴华², 郑含博¹

(1. 广西大学电气工程学院, 南宁 530004; 2. 国网山东省电力公司淄博供电公司, 山东 淄博 255000)

摘要: 随着电网智能运检的不断推进, 电力设备状态监测产生了海量图像数据, 然而目前尚无十分有效的方法对其进行智能分类识别。为解决机器学习对图像中的复杂特征提取困难和常规卷积神经网络学习能力不足带来的数据堆积和误判等问题, 提出一种基于GoogLeNet Inception-V3模型的电力设备图像识别方法。首先介绍电力设备图像识别的模型结构及实现步骤, 随后阐述该模型在特征提取中的高效性和准确性, 最后通过实验证明该方法的优点。研究表明, 提出方法对断路器、电流互感器、绝缘子、避雷器和电压互感器的平均识别准确率高达92.0%, 比浅层CNN、kNN分类算法、VGG-16、GoogLeNet Inception-V1模型分别高32.5%、24.0%、6.5%和4.0%, 具有较高的可行性和工程实用价值。

关键词: 电力设备; 卷积神经网络; 图像识别; 识别准确率

Image Recognition of Electric Equipment Based on GoogLeNet Inception-V3 Model

XU Kai¹, LIANG Zhijian¹, ZHANG Yiyi¹, LIU Xinghua², ZHENG Hanbo¹

(1. School of Electrical Engineering, Guangxi University, Nanning 530004, China; 2. Zibo Power Supply Company, State Grid Shandong Electric Power Company, Shandong Zibo 255000, China)

Abstract: With the development of intelligent operation and inspection of power grid, massive image data has been generated by condition monitoring of electric equipment, but there is currently no very effective method for intelligent classification and recognition. In order to solve the problems of data accumulation and misjudgment caused by the difficulty of extracting complex features in images and the lack of learning ability of convolutional neural networks, an image recognition method for electric equipment based on GoogLeNet Inception-V3 model is presented. Firstly, introduce the model structure and implementation steps of electric equipment image recognition, then explain the efficiency and accuracy of the model in feature extraction, and finally prove the advantages of the method through experiments. The research results show that the proposed method has an average recognition accuracy of 92% for circuit breakers, current transformers, voltage transformers, insulators and arresters, which is better than the shallow CNN, kNN, VGG-16, GoogLeNet Inception-V1 model is 32.5%, 24.0%, 6.5% and 4.0% respectively, it has the high feasibility and practical value in engineering.

Key words: electric equipment; convolution neural network; image classification; recognition accuracy

0 引言

随着电网设备智能运检的不断推进, 电力设备监测产生的数据量呈指数级增长^[1]。准确、快捷地对设备数据进行智能化分析和识别, 能够有效提升

电力系统的智能化管理水平^[2]。然而, 目前尚无十分有效的方法对巡检过程中产生的海量电力设备图像进行智能分类识别, 由于人工识别的效率较低, 传统算法识别存在智能化和准确率不足等问题^[3], 造成图像数据的堆积和误判制约着电力设备的安全运

收稿日期: 2020-04-25; 修回日期: 2020-06-29

基金项目: 国家自然科学基金(51867003; 51907034); 广西自然科学基金(2018JJB160056; 2018JJB160064; 2018JJA160176)。

Project Supported by the National Natural Science Foundation of China (51867003; 51907034), the Natural Science Foundation of Guangxi (2018JJB160056; 2018JJB160064; 2018JJA160176).

行,因此,电力设备巡检的效率亟待提高。

近些年,不少学者针对电力设备的在线监测技术和图像处理技术进行大量研究,并在设备实时监控^[4-5]、设备定位^[6]、紫外探伤^[7]、覆冰程度评估^[8-9]、模式识别^[10]等方面取得了较多成果。

在人工智能驱动下的图像识别领域,机器学习算法曾占据主导地位^[11]。但是,近年来的研究表明,神经网络分类器在手写数字数据集(MNIST)上的识别准确率已经明显超越机器学习分类器^[12-13]。随着 Alexnet 在 2012 年的 ImageNet 大规模视觉识别挑战中获得冠军^[14],深度学习在图像识别领域中发展迅猛,尤其在医学和安防等领域应用广泛^[15]。虽然传统算法在手写数字数据集识别准确率较高,但对于具有高相似度和高分辨率的电力设备图像,表现差强人意。利用深度学习结合计算机视觉技术对海量电力设备图像进行智能分类识别和分析,不仅节省人力成本,而且提升识别精度,对于电力设备运维的安全性和高效性有重要意义^[16-18]。

机器学习是通过对图像的底层特征进行提取来表达其高层语义,相关学者提出使用支持向量机等传统机器学习算法对电力设备图像进行定位和识别^[19-21],虽然取得了较好的效果,但是对于图像中的复杂特征提取困难^[16]。而深度学习在传统机器学习的基础上使用卷积神经网络(convolutional neural network, CNN)提取图像的全局特征,可以学习到训练集中不同标签的图像所包含的复杂特征。文[22]使用人工神经网络对换流变压器的局部放电图谱进行特征提取,有效实现缺陷诊断;文[23]采用深度学习算法对绝缘子红外图像进行识别,对于相同数据集,识别准确率较文[21]所用的机器学习算法提高了 4.3%,在有效性和鲁棒性上有所提升;文[24]利用 Faster-RCNN 对输电线路进行部件识别和缺陷检测,并通过改变卷积核大小和数据扩充来提升准确率;文[25]提出基于 GAN-Up-Net 的绝缘子串识别和诊断技术,通过整合图像的深层语义信息实现了绝缘子串中不同元件的分割;文[26]使用 AlexNet 模型结合随机森林分类器对绝缘子、变压器、断路器、输电线电杆和输电线铁塔的图像进行分类,准确率达 89%;文[27]利用强泛化卷积神经网络对输电线路覆冰图像进行 5 个等级的厚度识别,对不同实际场景的覆冰图像有较强的泛化能力。综上所述,近年来电力设备图像识别的研究集中在传统算法的改进和深度学习算法的可行性研究,并逐渐从机器学习向深度学习转变^[28]。

文中研究基于 GoogLeNet Inception-V3 的图像识别模型,对断路器、电流互感器、电压互感器、绝

缘子和避雷器这 5 类外观相似的电力设备进行识别分类。该模型使用 Inception 模块和批归一化对神经网络结构进行优化,降低了计算量的同时增强了模型的非线性。与机器学习算法和其他卷积神经网络模型相比,对图像特征的提取能力强,从而提高了识别准确率。为解决电网设备数量庞大与巡检效率不足的矛盾提供可靠依据。

1 面向电力设备识别的 GoogLeNet 模型

1.1 特征提取

由于人工提取特征主要依靠颜色和形状,而断路器、电流互感器、绝缘子、避雷器和电压互感器这 5 类设备外观较为相似,加上图像采集过程中的光线、背景和设备损耗等因素的影响。因此,专业知识较弱的工作人员,识别效率和准确率均较低。文中研究 GoogLeNet Inception-V3 模型进行图像数据的特征提取。电力设备图像识别流程见图 1。




图1 电力设备图像识别流程框图

Fig. 1 Flow chart of electric equipment image recognition

1.2 模型结构

GoogLeNet Inception-V3 模型深度为 48 层,在每

个卷积层后加入 Relu 激活函数来增加模型的非线性。模型中 Inception 模块的主要思想是用密集成分来近似最优的局部稀疏结构^[29], 相比于图像识别领域的其他模型, 增加了模型的深度和宽度, 在减少参数和计算量的同时减轻过拟合, 其结构见图 2, 带有罗马数字的方块为 Inception 模块, 内部结构见括号内。




图2 GoogLeNet Inception-V3模型结构

Fig. 2 Model structure of GoogLeNet Inception-V3

1.3 卷积神经网络原理

卷积神经网络是由卷积层和池化层等叠加而成, 其中卷积层和池化层是特征提取的关键步骤, 其他层起到连接和分类作用。输入卷积神经网络中的特征图可以视为由电力设备图像的像素值组成的矩阵。通过卷积层和池化层的叠加, 对图像进行遍历, 提取出抽象的高维特征。

特征图大小的计算公式为

$$O = \frac{I - F + 2P}{S} + 1 \quad (1)$$

式(1)中: O 为输出特征图边长; I 为电力设备图像的灰度值矩阵边长; F 为卷积核边长; P 为零填充的值; S 为卷积核移动步长。

1.3.1 卷积层

对于输入电力设备图像 $x_{p,q}$, $p \in [0, 4]$, $q \in [0, 4]$, 卷积核为 $w_{m,n}$, $m \in [0, 1]$, $n \in [0, 1]$, 则卷积计算公式为

$$y_{m,n} = g \left(\sum_{m=0}^1 \sum_{n=0}^1 w_{m,n} * x_{p+m, q+n} + b \right) \quad (2)$$

式(2)中: $g(\cdot)$ 为激活函数, “*” 为卷积操作; b 为卷积偏置。

卷积核中每一个参数与对应输入图像中的参

数相乘, 若输入图像有多层, 则分别与卷积核相乘后相加, 卷积核的个数决定输出特征图的层数。卷积过程见图3。




图3 卷积过程

Fig. 3 Process of convolution

1.3.2 池化层

池化层分为最大池化层和平均池化层, 过程和卷积类似, 但需要计算出过滤器(卷积中为卷积核)在特征图中所对应的区域的最大值或者平均值, 输出新的特征图。池化过程见图4。




图4 池化过程

Fig. 4 Process of pooling

1.4 激活函数

二维平面上的点集分类是简单的线性分类问题, 使用多个卷积层对图像的分类过程是多层线性分类的叠加。线性函数的可加性和齐次性使其便于实现线性分类, 而电力设备图像分类是复杂的非线性问题, 所以多层卷积的结果相当于只对输入图像进行一次线性变换, 无法实现非线性分类。神经网络在卷积层之后加入激活函数, 将上层传来的线性函数进行非线性变换, 解决非线性分类问题。

Sigmoid 和 Tanh 的激活函数表达式为:

$$\text{Sigmoid: } S(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\text{Tanh: } T(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

Sigmoid 激活函数将上层传来的线性函数进行非线性变换, 使其取值分布在 $[0, 1]$ 之间, 均值为 0.5; 而 Tanh 激活函数可以认为是 Sigmoid 的平移, 其取值范围介于 $[-1, 1]$ 之间, 数据的均值为 0, 具有数据中心化的效果。而这两种激活函数的导函数则会随着自变量增大而趋于零, 导致梯度消失, 其公式为:

$$(\text{Sigmoid})':S'(x)=\frac{e^{-x}}{(1+e^{-x})^2} \quad (5)$$

$$(\text{Tanh})':T'(x)=\frac{4}{(e^x+e^{-x})^2} \quad (6)$$

Relu激活函数虽然在 $x>0$ 时梯度为1,可以避免Sigmoid和Tanh激活函数发生梯度消失,但卷积之后的参数可能分布于 $x<0$ 的区域,损失大量有效参数,降低模型训练的精度和效率。Relu激活函数及其导数的表达式为:

$$\text{Relu}:R(x)=\begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases} \quad (7)$$

$$(\text{Relu})':R'(x)=\begin{cases} 0 & x \leq 0 \\ 1 & x > 0 \end{cases} \quad (8)$$

1.5 批归一化

Relu激活函数导致自变量变化造成的梯度消失,是由于内协变量移位导致,批归一化解决了此问题^[30]。其首次出现是在Inception模块中,为了解决梯度消失,在每层的激活函数之前引入批归一化层,将卷积之后的张量进行归一化处理,使进入激活函数的变量分布在均值为0、单位方差的梯度最大位置,再进行一次仿射变换 $y=\alpha x+\beta$,传递给激活函数。

假如一批输入变量 $x_1, x_2, \dots, x_k$,分别求其均值和方差:

$$\mu = \frac{1}{k} \sum_{i=1}^k x_i \quad (9)$$

$$\sigma = \sqrt{\frac{1}{k} \sum_{i=1}^k (x_i - \mu)^2} \quad (10)$$

然后对输入的一批 x 值进行归一化处理

$$\hat{x} = \frac{x_i - \mu}{\sqrt{\sigma^2 + \varepsilon}} \quad (11)$$

使 x_i 的分布转变为均值为0,单位方差的正态分布,把 x_i 从梯度消失的边缘矫正到梯度较大的区域,增加训练速度。其中 ε 是一个较小的值,避免方差分母为0的同时,不对计算造成影响。

$$y_i = \alpha \hat{x}_i + \beta \quad (12)$$

满足梯度要求之后,若数据自身的分布不够对称,比如数据在高梯度的范围内分布密集,则会削弱激活函数的表达能力。利用 α 、 β 这两个可以学习的变量,对归一化后的值进行放缩和移位的仿射变换,目的是为了补偿模型的非线性表达能力,降低对于特征提取良好的数据进行归一化之后,偏移量丢失导致性能下降的可能性。

在训练中使用批归一化加快了训练速度,减轻对初始化权重的依赖,一定程度上避免梯度消失和过拟合。

1.6 Inception 模块

Inception模块将CNN中较大的卷积层分解为 $1 \times 1, 3 \times 3, 5 \times 5$ 的卷积层和 3×3 的池化层并联,用不同的卷积核采集电力图像在不同感受视野下的特征。卷积层在输入图像上以“SAME”模式进行移动,保持输出特征图长宽不变,厚度为卷积层和池化层的叠加,使Inception模块输出的特征图能保留足够多的特征量。在参数优化过程中,模型可以自行选择最优的卷积核,避免了人工选择不当造成的神经网络效率过低的问题。

在实际应用中 3×3 和 5×5 的卷积层会导致计算量过大,为了降低计算成本,将 1×1 卷积核与 3×3 、 5×5 的卷积层和池化层串联使用,对输入特征图的计算进行优化,同时增强模型的非线性,见图5。




图5 加入 1×1 卷积核前、后对比

Fig. 5 Comparison before and after adding 1×1 convolution kernel

例如,对于一个 $32 \times 32 \times 256$ 的特征图,用32个 $5 \times 5 \times 256$ 的卷积核进行卷积操作,要得到输出为 $32 \times 32 \times 32$ 的特征图,则总计算量为2.1亿次,见图5中“途径①”。可理解为 5×5 的卷积核在256层的输入特征图的每一层上移动 32×32 次,卷积核为32个。而在 5×5 的卷积核前加入 $1 \times 1 \times 256$ 卷积核,该层的总计算量减少为0.17亿次,见图5中“途径②”。

从改变卷积核大小的层面上看, 5×5 的卷积核计算量是 3×3 的2.78倍。虽然 5×5 的卷积核在感受视野上优于 3×3 卷积核,但是使用两层 3×3 卷积减少大量计算,而且两层Relu激活函数使模型更加抽象,故整体效果优于 5×5 的卷积核,卷积核分解过程见图6。

由于能够捕获像素八邻域信息的最小尺寸是 3×3 卷积核,故较大的卷积核都可以分解为 3×3 卷积核,在减少参数的同时不会改变特征图的表达能力。进一步提升模型性能需要把 3×3 卷积核分解为 3×1 卷积核和 1×3 卷积核,相当于分别从 x 、 y 轴两个




图6 5×5卷积核分解为两个3×3

Fig. 6 The 5×5 convolution kernel splits into two 3×3

方向遍历3×3卷积核,计算量为使用3×3卷积核的2/3。同理,对于所有 $n \times n$ 卷积核,都可以分解为 $n \times 1$ 和 $1 \times n$ 的卷积核。

经过图2中Inception模块II之后,张量大小变成 $17 \times 17 \times 768$,在此阶段,卷积核大小为 7×7 ,与 3×3 卷积核分解同理,把 7×7 卷积核分解为 7×1 卷积核和 1×7 卷积核,会带来更大的提升。而下层大小为 $8 \times 8 \times 1280$ 和 $8 \times 8 \times 2048$ 的张量中,具有高维度和输出稀疏的特点,把Inception模块中的 $n \times 1$ 和 $1 \times n$ 卷积核串联转变为并联,使深层卷积过程增强了同一级特征结构提取不同尺度下的卷积结果,可以提取出更加多样化的电力设备特征。

2 实验结果和分析

2.1 实验结果

文中收集的1500张训练样本包括断路器、电流互感器、电压互感器、绝缘子和避雷器这5类电力设备,均来源于变电站实地拍摄,涵盖该地区变电站中的多类设备。其中训练集数据1000张,验证集数据300张,测试集数据200张,各类图像比例相同,预处理过程将图片分辨率转换为 299×299 。训练和测试过程中计算机配置为64位Windows 10操作系统,GPU为GTX960M,深度学习框架为Tensorflow,编程语言为Python。

训练过程中,设置学习率为0.005,每批训练量为16张图片,每500步测试验证集准确率,每2000步保存训练模型。损失函数在3000到12000步之间逐渐收敛,验证集准确率达到85.0%。收敛后验证集准确率稳定在95.0%左右,用保存的模型对测试集进行测试,测试集准确率稳定在92.0%,见图7。分类识别结果见图8。

2.2 结果分析

文中使用的浅层CNN为最基本的神经网络,将卷积层、池化层和全连接层简单拼接而成,虽然其反向传播过程能够从训练数据中不断选择最优的




图7 训练过程的损失和准确率

Fig. 7 Loss and accuracy of training process



图8 识别结果

Fig. 8 Results of identification

参数,但由于卷积层数量较少,特征提取能力较弱,而且全连接层占比较大,造成大量不必要的计算,故识别准确率最高仅达到59.5%。

k 最近邻(k -nearest neighbor, k NN)分类算法通过训练集图片提取特征值,并与已有标签对应,而没有训练过程,测试图片时比较测试集特征值与训练集特征值在不同距离 k 时的相似程度达到分类效果,对于类内相似度高的设备识别率较高,对外观有差异的类内设备效果较差,泛化能力弱。且 k NN没有反向传播过程,不能对训练参数进行优化调整,故识别准确率较低,只有68.0%。

文中数据集在VGG-16和GoogLeNet Inception-V1模型中准确率较高,分别为85.5%和88.0%,但较Inception-V3相比还有一定差距。这两种神经网络模型的层数分别为16和22层,GoogLeNet Inception-V1中原始Inception模块虽效果不如GoogLeNet Inception-V3中的Inception模块,但较VGG-16这种在宽度上没有拓展的模型,表现出较高的准确率。另外,GoogLeNet Inception-V1使用批归一化,降低

Dropout 的使用率,而 VGG-16 中 Dropout 比率较大,在一定程度上影响收敛速度和训练时间。

GoogLeNet Inception-V3 作为同时具有深度和宽度的神经网络,效率高于常规的神经网络模型,其 Inception 模块增大了神经网络的感受视野,运用不同类型卷积核对张量进行运算,从电力设备图像中提取大量有效的特征。并在参数更新过程中引入批归一化,减少了梯度消失对训练过程的影响,节省了大量算力,使运算效率大幅度提升。

传统算法、其他深度学习模型和文中方法对于五类设备的识别准确率和训练耗时见表 1。其中文中方法最终测试准确率稳定在 92.0%,高于其他 4 种图像识别算法,在验证集准确率达到 80% 的耗时低于 VGG-16,而略高于 GoogLeNet Inception-V1。综合评估,牺牲较少训练时间带来的准确率增益是值得的,表明该算法在电力设备识别中相比其他算法有较大提升。

表 1 各种图像识别算法的性能比较

Table 1 Performance comparison of various Image recognition algorithms

测试方法	准确率/%	验证集准确率达到 80% 耗时/min
浅层 CNN	59.5	—
kNN	68.0	—
VGG-16	85.5	247
GoogLeNet Inception-V1	88.0	131
文中方法	92.0	140

GoogLeNet Inception-V3 模型对不同设备的识别准确率见表 2。从表 2 中可以发现,文中方法在电力设备图像识别过程中的错误主要存在于绝缘子与避雷器中。由于一部分支柱绝缘子和避雷器的瓷套相似度高,见图 9(a)、(b);以及 500 kV 电容式电压互感器和 500 kV 瓷外套金属氧化物避雷器都带有均压环,且都是三段式结构,见图 9(c)、(d)。加上背景中线路、树木等因素杂乱使得神经网络难以提取出关键性特征,从而造成误判。

表 2 GoogLeNet Inception-V3 模型对不同设备的识别准确率

Table 2 Identification accuracy of GoogLeNet perception-V3 model for different devices

设备名称	断路器	电流互感器	绝缘子	避雷器	电压互感器
准确率/%	97.5	95.0	87.5	85.0	95.0




图 9 电力设备易混淆图片

Fig. 9 Confusing pictures of electric equipment

由于深度学习对训练样本要求较高,但是背景杂乱是实际拍摄中难以规避的因素,对错误识别结果的分析将促使下一步研究在增大有效数据集的同时,提升神经网络对更加细致的特征进行提取,比如将设备的接线方式和相对位置考虑在分类数据中,以进一步提升准确率。

3 结语

GoogLeNet Inception-V3 模型的宽度和深度优势表现出较强的特征提取能力,可以有效识别断路器、电流互感器、绝缘子、避雷器和电压互感器这 5 类外观相似度较高的电力设备。对于文中收集的变电站实拍数据集,识别准确率比浅层 CNN、kNN 分类算法分别高出 32.5% 和 24.0%,比 VGG-16、GoogLeNet Inception-V1 分别高出 6.5% 和 4.0%。结果表明,文中提出的方法缓解了人工识别过程中特征提取方式单一和工作繁杂的问题,弥补了现有算法在识别精度和效率的不足,解决了常规模型训练速度慢和模型臃肿的问题,为电网智能运检过程中的设备识别提供新的思路。

参考文献:

- [1] 宋亚奇,周国亮,朱永利. 智能电网大数据处理技术现状与挑战[J]. 电网技术,2013,37(4): 927-935.
SONG Yaqi, ZHOU Guoliang, ZHU Yongli. Present status and challenges of big data processing in smart grid[J]. Power System Technology, 2013, 37(4): 927-935.
- [2] 江秀臣,盛戈皞. 电力设备状态大数据分析的研究和应用[J]. 高电压技术,2018,44(4): 1041-1050.
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering, 2018, 44(4): 1041-1050.
- [3] 彭向阳,金亮,王锐,等. 变电站机器人智能巡检技术及应用效果[J]. 高压电器,2019,55(4): 223-232.
PENG Xiangyang, JIN Liang, WANG Rui, et al. Substation robot intelligent inspection technology and its application [J]. High Voltage Apparatus, 2019, 55(4): 223-232.

- [4] 孙凤杰, 崔维新, 张晋保, 等. 远程数字视频监控与图像识别技术在电力系统中的应用[J]. 电网技术, 2005, 29(5): 81-84.
SUN Fengjie, CUI Weixin, ZHANG Jinbao, et al. Application of remote digital video monitoring and image recognition technology in power system[J]. Power System Technology, 2005, 29(5): 81-84.
- [5] 盛戈崂, 江秀臣, 曾 奕, 等. 架空输电线路运行和故障综合监测评估系统[J]. 高电压技术, 2007, 33(8): 183-186.
SHENG Gehao, JIANG Xiuchen, ZENG Yi, et al. Integrated monitoring system for evaluating overhead transmission lines operation and fault state[J]. High Voltage Engineering, 2007, 33(8): 183-186.
- [6] ZHAO Z, LIU N, WANG L. Localization of multiple insulators by orientation angle detection and binary shape prior knowledge[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(6): 3421-3428.
- [7] 金立军, 陈俊佑, 张文豪, 等. 基于图像处理技术的电力设备局部放电紫外成像检测[J]. 电力系统保护与控制, 2013, 41(8): 43-48.
JIN Lijun, CHEN Junyou, ZHANG Wenhao, et al. Partial discharge detection of power equipment by ultraviolet imaging based on image processing technology[J]. Power System Protection and Control, 2013, 41(8): 4348.
- [8] 李立涅, 阳 林, 郝艳捧. 架空输电线路覆冰在线监测技术评述[J]. 电网技术, 2012, 36(2): 237-243.
LI Licheng, YANG Lin, HAO Yanpeng. Review of on-line monitoring of ice coating on overhead transmission line[J]. Power System Technology, 2012, 36(2): 237-243.
- [9] 郝艳捧, 蒋晓蓝, 阳 林, 等. 基于图像分割评估运行绝缘子自然覆冰程度[J]. 高电压技术, 2017, 43(1): 285-292.
HAO Yanpeng, JIANG Xiaolan, YANG Lin, et al. Evaluation of natural icing condition for in-service insulators based on image segmentation[J]. High Voltage Engineering, 2017, 43(1): 285-292.
- [10] 刘 兵, 郑 剑. 基于卷积神经网络的变压器局部放电模式识别[J]. 高压电器, 2017, 53(5): 70-74.
LIU Bing, ZHENG Jian. Partial discharge pattern recognition in power transformers based on convolutional neural networks[J]. High Voltage Apparatus, 2017, 53(5): 70-74.
- [11] 余 凯, 贾 磊, 陈雨强, 等. 深度学习的昨天, 今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
YU Kai, JIA Lei, CHEN Yuqiang, et al. Deep learning: yesterday, today, and tomorrow[J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804.
- [12] DENG L. The MNIST database of handwritten digit images for machine learning research[best of the web][J]. IEEE Signal Processing Magazine, 2012, 29(6): 141-142.
- [13] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [14] 黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述[J]. 计算机学报, 2014, 37(6): 1225-1240.
HUANG Kaiqi, REN Weiqiang, TAN Tieniu. A review on image object classification and detection[J]. Chinese Journal of Computers, 2014, 37(6): 1225-1240.
- [15] 鞠 平, 周孝信, 陈维江, 等. “智能电网+”研究综述[J]. 电力自动化设备, 2018, 38(5): 2-11.
JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. “Smart Grid Plus” research overview[J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.
- [16] 刘云鹏, 许自强, 李 刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348.
LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348.
- [17] 朱光磊, 樊利民, 刘红业. 应用于能源局域网的固态变压器运行研究[J]. 广东电力, 2018, 31(2): 24-31.
ZHU Guanglei, FAN Limin, LIU Hongye. Research on operation of solid state transformer in energy local network[J]. Guangdong Electric Power, 2018, 31(2): 24-31.
- [18] 王丰华, 胡徐铭, 钱 勇, 等. 变压器绕组振动监测技术研究综述[J]. 广东电力, 2018, 31(8): 52-61.
WANG Fenghua, HU Xuming, QIAN Yong, et al. Research and review on monitoring technology for transformer winding vibration[J]. Guangdong Electric Power, 2018, 31(8): 52-61.
- [19] 王斯凡. 基于机器视觉的电力设备识别与故障诊断技术研究[D]. 北京: 华北电力大学, 2018.
WANG Sifan. Research on power equipment identification and fault diagnosis based on machine vision[D]. Beijing: North China Electric Power University, 2018.
- [20] 方春华, 潘明龙, 黄 立, 等. 基于电弧面积绝缘子表面放电强度精细分类与识别方法[J]. 高压电器, 2019, 55(2): 126-132.
FANG Chunhua, PAN Minglong, HUANG Li, et al. Subtle classification and identification method of surface discharge intensity of insulators based on arc area[J]. High Voltage Apparatus, 2019, 55(2): 126-132.
- [21] ZHAO Z, XU G, QI Y. Representation of binary feature pooling for detection of insulator strings in infrared images[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2016, 23(5): 2858-2866.
- [22] 魏 振, 齐 波, 左 健, 等. 基于局部放电图像特征的换流变压器油纸绝缘缺陷诊断方法[J]. 电网技术, 2015, 39(4): 1160-1166.
WEI Zhen, QI Bo, ZUO Jian, et al. A method to diagnose defects in oil-paper insulation of converter transformer based on image feature of partial discharge[J]. Power System Technology, 2015, 39(4): 1160-1166.
- [23] ZHAO Z, FAN X, XU G, et al. Aggregating deep convolutional feature maps for insulator detection in infrared images[J]. IEEE Access, 2017(5): 21831-21839.
- [24] 汤 踊, 韩 军, 魏文力, 等. 深度学习在输电线路中部件识别与缺陷检测的研究[J]. 电子测量技术, 2018, 41(6): 60-65.
TANG Yong, HAN Jun, WEI Wenli, et al. Research on part recognition and defect detection of transmission line in deep learning[J]. Electronic Measurement Technology, 2018, 41(6): 60-65.