

基于复合神经网络的GIS局放故障类型识别

袁文海¹, 刘彪¹, 徐浩¹, 王喆¹, 董小顺¹,
汪飒², 钟理鹏², 司羽飞², 夏鑫²

(1. 国网新疆电力有限公司乌鲁木齐供电公司, 新疆维吾尔自治区 乌鲁木齐 830011;
2. 湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘要: 气体绝缘金属封闭开关设备(GIS)局部放电故障类型识别是故障预警和制定检修计划的重要基础, 对维护电力设备的安全稳定运行意义重大。在此背景下, 首先分析常见的几种GIS故障类型; 然后, 在超高频传感器采集到的图谱信号处理和分类上, 由于卷积神经网络(CNN)和深度置信网络(DBN)融合而成的复合神经网络模型可以快速实现有效特征信号的提取和故障类型准确分类, 因此该文融合CNN和DBN, 建立复合神经网络的主体结构, 并利用该网络进行GIS局部放电故障类型识别; 最后进行实验验证。结果表明该复合神经网络模型识别故障的准确性最高可达99%。

关键词: GIS设备; 特征图像; 卷积神经网络; 深度置信网络; 模型训练

DOI:10.19781/j.issn.1673-9140.2021.04.020 中图分类号:TM863 文章编号:1673-9140(2021)04-0157-08

Partial discharge fault type identification of GIS based on composite neural network

YUAN Wenhai¹, LIU Biao¹, XU Hao¹, WANG Zhe¹, DONG Xiaoshun¹,
WANG Feng², ZHONG Lipeng², SI Yufei², XIA Xin²

(1. Urumqi Power Supply Company, State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830011, China;
2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Gas insulated switchgear (GIS) partial discharge fault type identification is an important basis for fault warning and maintenance planning, and is of great significance for maintaining the safe and stable operation of power equipment. This paper firstly analyzes several common types of GIS faults. Then, in the processing and classification of the spectral envelop signal collected by the UHF sensor, the composite neural network model formed by the fusion of the convolutional neural network (CNN) and the deep belief network (DBN) can quickly realize the extraction of effective feature signals and accurate classification of fault types. Therefore this paper integrates CNN and DBN, establishes the main structure of the composite neural network, and uses this network to identify GIS partial discharge fault types. Finally, the method is verified in simulation experiments. Results show that the accuracy of the composite neural network model to identify faults can reach up to 99%.

Key words: GIS; characteristic image; convolution neural network(CNN); deep belief network(DBN); model training

收稿日期:2020-01-03; 修回日期:2020-10-01

基金项目:国网新疆电力有限公司科技项目(SGXJWL00YJJS1901002)

通信作者:董小顺(1989-),女,硕士,中级工程师,主要从事带电检测及高压试验研究;E-mail:1061545589@qq.com

气体绝缘金属封闭开关设备(gas insulated switchgear, GIS)将变电站等输变电环节中的断路器、隔离开关、互感器等众多高压设备集成在一起,全部封闭在金属接地的外壳中,并在其内部充满SF₆。绝缘气体^[1],具有体积小、环境影响小、维护周期长且运行可靠性高等传统变电站无可比拟的优势^[2]。但集成式结构也存在故障发生后难以查找故障源、运维困难等缺陷,因此,通过局部放电检测技术来发现不同类型缺陷所造成的局部放电,对于故障预警和安排检修计划具有重要意义,必须提升GIS运行维护水平,使其故障率降到最低^[3-5]。

现有的故障类型识别主要分为3个环节:采集局部放电图谱信号、提取特征参数、分类器模式识别^[6-8]。3个环节依次进行,局部放电信号常用超高频法采集,局部放电产生的超高频信号在SF₆气体中衰减速度慢且传播速度快^[1],能实时反映设备绝缘状况,提取到的超高频信号进行对数检波后取其包络信号进行特征值提取。传统特征参数提取方法集中在对频域和时域波形的分析上,如:分形特征参数法、数字图像矩特征参数法、小波特征参数法等^[9-15]。此外,基于时域放电信号,文献[16]采用相位分布模式建立了多周期的不同类型相位分辨局部放电(phase resolved partial discharge, PRPD)谱图,对油纸绝缘局部放电模式识别展开研究;文献[17]引入混沌理论改进特征提取算法,弥补了传统特征提取方法过程中对不同PD脉冲之间关联信息以及相互影响的忽视;文献[18]综合了总体经验模态分解(ensemble empirical mode decomposition, EEMD)^[19]与二维Gabor变换^[20]的优势,显著提高了模式识别的准确率。

关于分类器的研究主要是神经网络算法的不断优化,但也有关于支持向量机(support vector machine, SVM)算法的实践,文献[21]通过试验验证了SVM算法的识别效果优于反向传播(back propagation, BP)神经网络算法。简单的人工神经网络(artificial neural network, ANN)一般会存在过拟合、收敛速度慢、易发散、易陷入局部极值等问题^[22-23],能够克服这些缺陷的SVM算法则由于使用了在 $x=0$ 时无定义的符号函数 $\text{sgn}(x)$ 作为分类函数而存在模式漏分问题^[24],无法识别 $x=0$ 对应

的放电样本。文献[25]采用基于支持向量数据描述算法解决了漏分问题。神经网络的其他算法还有基于自适应神经模糊算法^[26]、基于自谐振理论(adaptive resonance theory, ART)神经网络算法^[27]、径向基神经网络^[28]等。此外,文献[29]使用仿生模式识别算法对经过主成分分析法降维处理后的参数进行辨识,提出了改变连通方向的方法。

鉴于泛在电力物联网发展背景下传感器设备的广泛使用和电网设备的复杂化,对复杂时间序列数据建立精确且通用的数理统计模型并提取有效特征参数变得越来越困难^[30],过度复杂的分类方法也大大增加了算法复杂度,增加了辨识时延。深度学习作为一种多层次神经网络学习算法,能够自主学习如何抓取数据的特征,在数据量较大的情况下,能有效避免特征信息的丢失。

该文使用深度学习算法中适合处理图像数据问题的卷积神经网络^[31-32](convolutional neural network, CNN)和适合处理单维时间问题的深度置信网络(deep belief network, DBN)^[33]一体化实现对局放图谱信号的特征值提取和模式识别。首先,对几种常见GIS故障类型的PRPD模式进行特征分析;然后,基于PRPD图谱识别对CNN和DBN的融合过程进行详细阐释,建立复合神经网络模型,并使用预先标注过的图谱数据集对神经网络进行训练;最后,使用验证集数据对模型进行测试,并将测试结果与已有方法进行对比,验证模型的识别准确率。

1 PRPD模式分析

在基于超高频法的GIS故障类型识别方法中,分析不同GIS故障类型的PRPD图谱特征是最为常用的手段。PRPD图谱将一段时间(多个放电周期)内的局部放电脉冲信号按照相位序列显示在同一坐标内,不再有时间信息标识,也即描述局部放电脉冲所对应的工频相位 $\phi(0^\circ\sim 360^\circ)$ 、放电量 q (由于用UHF法检测时无法标准标定放电量,则 q 表示脉冲幅值)和放电次数 n (或放电率)之间的关系^[34],与相位分辨的脉冲序列(phase-resolved

pulse-sequence, PRPS)模式相比,属于一段时间内的 PRPS 信号的叠加。

在 CNN 识别图像信号的过程中,图像的大小直接影响了模型训练和识别过程的计算时间,而 PRPD 图谱尺寸不随时间变化且放电信息随时间累积的特性非常适于 CNN 的特征提取,因此,该文选择 PRPD 图谱信号作为复合神经网络的输入信号。

实际生产中较为典型的几种 GIS 故障类型的放电 PRPD 图谱如图 1 所示。由图 1 脉冲幅值分布可知,典型的 4 种故障类型 PRPD 图谱具有明显的相位相关性。其中,尖端放电脉冲集中在 270° 相位附近,金属自由颗粒放电脉冲刚好相反,在 270° 和 90° 相位附近几乎没有分布;悬浮电位的脉冲幅值不仅有相位相关性,还有明显的悬空特性。CNN 的特征参数提取过程将对这些特征进行精确、多角度的分析。

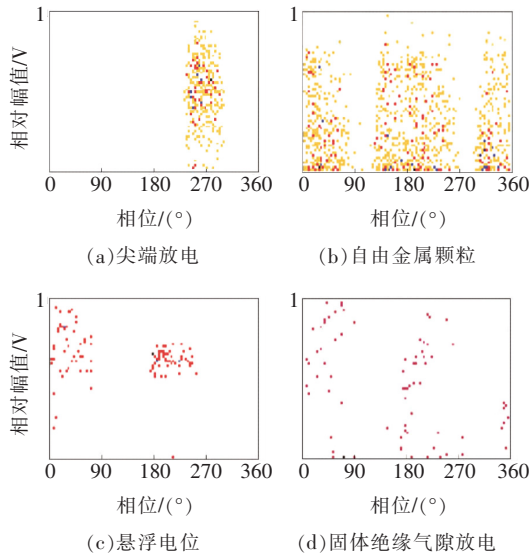


图 1 GIS 典型故障类型的 PRPD 图谱

Figure 1 PRPD map of typical faults in GIS

2 复合神经网络建模

图谱信号经过降噪预处理后如图 2 所示。首先,使用 CNN 进行图谱特征值提取和降维操作;然后,使用 DBN 模型中的受限玻尔兹曼机(restricted boltzmann machine, RBM)层代替 CNN 中的全连接层,以此提高模型的学习速率和判别准确性;最后,使用 softmax 函数作为输出层得到各分类结果的概率。




图 2 复合神经网络模型结构

Figure 2 Structure of composite neural network model

2.1 CNN 建模

CNN 原理如图 3 所示,完整的 CNN 模型由多个卷积层、池化层和全连接层组合而成。在特征提取与高维提纯环节,卷积层先通过过滤器对原始图像进行卷积运算,提取特征值形成新的特征图像;然后,池化层再对得到的特征图像进行特征提纯实现矩阵尺寸压缩,从而大大减少神经网络参数,提高运算速度。一般而言,单次仅能提取图像的低层次特征,可以根据识别目标图像的复杂程度,选择进行多次重复卷积池化操作,最终提取出高层次的特征。在概率分类环节,使用 Flatten 函数将提取到的高信息含量特征图像变换为一维特征参数数组,作为输入参数由全连接层完成概率分类。




图 3 卷积神经网络模型

Figure 3 Schematic diagram of convolutional neural network model

为提高特征提取的准确度,该文先对需识别的PRPD图谱信号进行图像去噪预处理和添加辅助特征图像操作。去噪环节将图像处理为灰度图像后滤除明显不符合局部放电特征的噪声数据。然后,添加观测效果可等价于PRPD图谱信号的脉冲次数分布曲线 $H_n(\phi)$ 和平均放电量分布曲线 $H_m(\phi)$ ^[34]。最后将3幅图像作为神经网络的输入量。

为便于说明,该文使用较为简单的 $25\text{ px} \times 25\text{ px}$ 数据量的PRPD图谱进行说明,同样,辅助观测特征图像也为 $25\text{ px} \times 25\text{ px}$ 数据量。输入层数据量为 $25\text{ px} \times 25\text{ px} \times 3$,卷积层 C_1 和 C_2 均使用尺寸大小为 $5\text{ px} \times 5\text{ px} \times 3$ 的过滤器进行特征提取,特征平面数量分别为32、64个,过滤器的移动步长为 1 px ;池化层 P_1 和 P_2 以全0边缘填充的方式进行移动步长为 2 px 的最大池化操作,降低特征图像的维度,进而加快运算速度且避免过拟合;Flatten函数将 P_2 输出的特征图像数据转变为包含3 136个参数的一维数组,作为全连接层的输入,3层全连接层的神经元数目分别为1 024、256和4个。

2.2 DBN 建模

对于分类器存在的计算量大、易陷入局部最小值以及过拟合等问题,BP算法可以通过结合以多层RBM为主体的DBN模型来优化。模型将无监督逐层RBM预训练和有监督BP算法参数调整过程相结合,保证了参数训练的快速性和准确性^[30]。

RBM模型如图4所示,包括所有可见单元 h 组成的可见层和所有隐含单元 v 组成的隐含层。其作用是①在最大程度保持输入数据分布特性的前提下进行降维,然后再进行分类,提高分类效率;②使用无监督逐层RBM预训练得到的参数作为有监督BP算法参数调整的初始值,避免BP算法在初始值不恰当时陷入局部极小值。




图4 RBM模型

Figure 4 Schematic diagram of restricted boltzmann machines

假设有 n 个可见单元和 m 个隐含单元,用 v_i 表示第 i 个可见单元, h_j 表示第 j 个隐含单元,则RBM的参数包括权重矩阵 $\mathbf{W}_{n \times m}$ 、可见层偏置阈值向量 \mathbf{C} 、隐含层偏置阈值向量 \mathbf{B} ,其中,权重矩阵 $\mathbf{W}_{n \times m}$ 的矩阵元素 w_{ij} 表示第 i 个可见单元和第 j 个隐单元之间的权值, c_i 表示第 i 个可见单元的偏置阈值, b_j 表示第 j 个隐含单元的偏置阈值。可见单元 v_i 与隐含单元 h_j 之间的能量函数为

$$E = - \sum_{i=1}^n c_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (1)$$

无监督逐层RBM预训练的目标就是不断优化参数,使得模型的能量函数 E 达到最低,能量函数降低的过程就是对输入数据进行不断拟合的过程。

该文使用3层RBM来代替CNN模型中的3层全连接层,实质上是在有监督的BP算法训练参数之前增加一个无监督的RBM训练过程。因此,参数调整过程如图5所示,DBN模型使用未标注的图像数据开始无监督的RBM训练过程,首先训练第1层RBM得到合适的隐层,将隐层单元的激活概率作为第2层RBM的显层输入,后2层RBM的训练与此类似;完成无监督RBM预训练后,再使用带标注的图像数据和BP算法对模型参数进行局部调整。

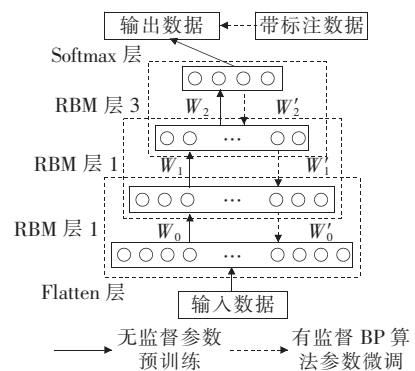


图5 DBN参数训练过程

Figure 5 Training process for DBN parameter

2.3 复合神经网络模型参数训练

复合神经网络模型的参数训练3个阶段与建模过程相对应,有监督CNN参数训练、无监督逐层RBM预训练、有监督DBN参数调整。其中,有监督CNN参数训练过程对应于先建立的CNN模型参数训练,包括前向和反向传播过程。当替换

CNN 的全连接层为 DBN 模型后,无监督逐层 RBM 预训练与有监督 CNN 参数训练得到的卷积池化层参数组合得到复合神经网络模型的先验参数,再由基于 BP 算法的有监督 DBN 参数调整过程对先验参数进行最后修正。

该文使用非线性 Relu 函数作为 CNN 模型各层神经元的激活函数,用 f 表示;使用平方误差作为整体代价函数,用 J 表示。在 4 类 m 个学习数据集的前提下,以 X_i 表示带标注的输入数据集, W_{ij} 表示各类权重矩阵(包括卷积层过滤器、池化层权重和全连接层权重), a_i 表示各偏置阈值矩阵, Y'_i 表示实际输出, Y_i 表示输入数据集 X_i 的初始标注。前向传播的计算过程和模型代价函数分别为

$$Y'_i = f(W_{ij}X_i + a_i) \quad (2)$$

$$J(w_{ij}, a_i, X_i, Y_i) = \frac{1}{2} \sum_{i=1}^m (Y'_i - Y_i)^2 \quad (3)$$

反向传播的计算过程是依据批量梯度下降原则对各层的权重和偏置阈值依次修正,修正目标是使模型代价函数达到最小,参数修正过程为

$$\begin{cases} W_{ij}^{(l+1)} = W_{ij}^{(l)} - \eta \frac{\partial J}{\partial W_{ij}} \\ a_i^{(l+1)} = a_i^{(l)} - \eta \frac{\partial J}{\partial a_i} \end{cases} \quad (4)$$

其中, η 为预先设定的学习速率。

DBN 模型的前向传播过程除 softmax 层外与 CNN 相同,但选用的代价函数 Q 为交叉熵函数,训练目标也是使代价函数达到最小值,softmax 层的计算过程和代价函数分别为

$$S_i = \frac{e^{y'_i}}{\sum e^{y'_i}} \quad (5)$$

$$Q = - \sum_i y_i \ln S_i \quad (6)$$

3 算例分析

如图 6 所示,该文在高压实验室模拟尖端放电、自由金属颗粒、悬浮电位和固体绝缘气隙放电 4 种缺陷,使用逐步升压法采集共计 100 组试验图谱数据。选用其中每种缺陷 3 组数据作为验证集,其他每种缺陷 22 组数据作为训练集。复合神经网络模型的输出节点有 4 个,相应缺陷类型对应的期望输

出值如表 1 所示。

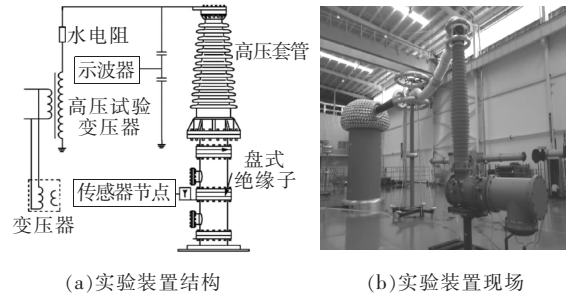


图 6 模拟缺陷局放数据采集装置

Figure 6 Data acquisition device for simulated partial discharge

表 1 不同缺陷类型对应期望输出值

Table 1 Expected output value for different defect types

缺陷类型	期望输出			
尖端放电	1	0	0	0
自由金属颗粒	0	1	0	0
悬浮电位	0	0	1	0
固体绝缘气隙放电	0	0	0	1

按照文 2 中的训练流程开始进行学习,在训练过程进行的同时适当调整学习速率 η 。如图 7 所示,随着迭代训练次数的增加,CNN 和复合模型的代价函数都逐渐下降,识别准确率逐步上升,且训练完成时复合模型的识别准确率接近于 99%,优于 CNN 模型的 94%;从曲线的变化趋势看,复合模型的训练速度和稳定性也要优于 CNN。

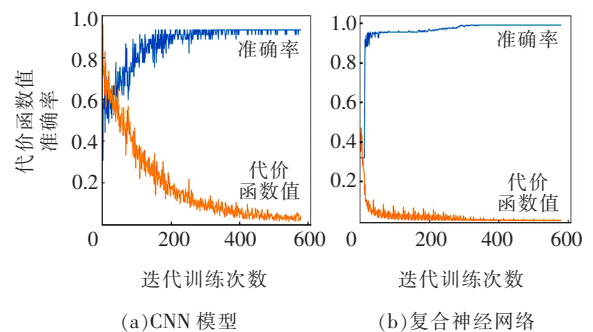


图 7 训练过程准确率变化趋势

Figure 7 Trend of accuracy rate during training

选取电压等级分别为 70、80、90 kV 试验环境下的 4 种缺陷 PRPD 图谱数据各一组,输入训练好的神经网络模型后得到的输出结果,如表 2 所示,可知验证集的识别结果准确度非常高,这体现了复合神经网络模型的实用性。

表 2 验证集识别输出结果

Table 2 Recognition output results of validation set

缺陷类型	不同电压(kV)等级下的识别输出结果											
	70				80				90			
尖端放电	0.999 984	0.000 001	0.000 027	0.000 013	0.999 892	0.000 037	0.000 049	0.000 038	0.999 875	0.000 001	0.000 225	0.000 098
自由金属颗粒	0.000 001	1.000 000	0.000 001	0.000 001	0.000 006	1.000 000	0.000 008	0.000 017	0.000 026	1.000 000	0.000 029	0.000 034
悬浮电位	0.000 007	0.000 075	0.990 252	0.000 052	0.000 058	0.000 045	0.998 552	0.000 036	0.000 154	0.000 129	0.987 379	0.000 286
固体绝缘 气隙放电	0.000 018	0.000 002	0.000 005	0.999 989	0.000 088	0.000 082	0.000 096	0.999 937	0.000 124	0.000 275	0.000 396	0.999 329

4 结语

该文分析了 4 种常见 GIS 缺陷类型的 PRPD 图谱信号,建立了适合提取图谱信号特征的神经网络模型,结合 CNN 和 DBN 的优势,详细阐释了复合神经网络建立和参数训练的过程,得到了特征提取过程简单、识别准确率高的神经网络模型。该模型有效避免了常规算法过度复杂的数理特征提取过程,且减少了有效特征的丢失,试验结果验证了其具有工程实用性。在实际的检测过程中,其识别能力还将随着测试样本的增多进一步增强,有较强的泛化能力。

该文所提复合神经网络的应用领域有较大的拓展空间,不同参数优化算法对该模型训练速度和识别准确率的影响也有待进一步研究,这些课题将在下一阶段的研究中逐步开展。

参考文献:

- [1] 唐志国,蒋佟佟,叶会生,等. 变电站局放检测中的电磁干扰统计特性[J]. 高电压技术, 2017, 43(9): 2998-3006.
TANG Zhiguo, JIANG Tongtong, YE Huisheng, et al. Statistical characteristics of electromagnetic interferences for partial discharge detection in substation[J]. High Voltage Engineering, 2017, 43(9): 2998-3006.
- [2] 邱鹏锋. 基于特高频检测的 GIS 局部放电类型识别研究[D]. 重庆:重庆大学, 2017.
- [3] 张晓星,唐俊忠,唐炬,等. GIS 中典型局放缺陷的 UHF 信号与放电量的相关分析[J]. 高电压技术, 2012, 38(1): 59-65.
ZHANG Xiaoxing, TANG Junzhong, TANG Ju, et al. Relationship between UHF signals and discharge mag-

nitude from typical partial discharge defects in GIS[J]. High Voltage Engineering, 2012, 38(1): 59-65.

- [4] 李沐,冯新岩,蔺晓琨. 基于 TDOA 和 TS-PSO 的变压器特高频局部放电空间定位方法[J]. 中国电机工程学报, 2019, 39(6): 1834-1842+1879.
LI Mu, FENG Xinyan, LI Xiaokun, et al. A transformer partial discharge UHF localization method based on TDOA and TS-PSO[J]. Proceedings of the CSEE, 2019, 39(6): 1834-1842+1879.
- [5] 牛勃,马飞越,丁培,等. GIS 局部放电智能巡检定位技术及应用[J]. 高压电器, 2020, 56(1): 188-196.
NIU Bo, MA Feiyue, DING Pei, et al. Intelligent inspection and location technology of GIS partial discharge and its application[J]. High Voltage Apparatus, 2020, 56(1): 188-196.
- [6] 刘佳翰,陈克绪,马建,等. 基于卷积神经网络和随机森林的三相电压暂降分类[J]. 电力系统保护与控制, 2019, 47(20): 112-118.
LIU Jiahao, CHEN Kexu, MA Jian, et al. Classification of three-phase voltage dips based on CNN and random forest[J]. Power System Protection and Control, 2019, 47(20): 112-118.
- [7] 黎学春,高宇男,李磊,等. 基于自适应神经网络系统聚类的特殊负荷分类研究[J]. 电网与清洁能源, 2019, 35(1): 8-15.
LI Xuechun, GAO Yunan, LI Lei, et al. Research on special load classification based on self-adaptive neural network hierarchical cluster[J]. Power System and Clean Energy, 2019, 35(1): 8-15.
- [8] 周步祥,邓苏娟,张百甫. 基于 RBF 神经网络和无迹变换法的三相概率潮流计算[J]. 电测与仪表, 2018, 55(11): 7-11+18.
ZHOU Buxiang, DENG Sujuan, ZHANG Baifu, et al. Three-phase probabilistic power flow calculation based on RBF neural network and unscented transformation

- algorithm[J]. *Electrical Measurement & Instrumentation*, 2018, 55(11): 7-11+18.
- [9] Zhang Y, Fan Q, Bao F, et al. Single-image super-resolution based on rational fractal interpolation [J]. *IEEE Transactions on Image Processing*, 2018, 27(8): 3782-3797.
- [10] Chen M, Urano K, Kon D, et al. PD measurement technique for after-laying test of large-scale 110-500 kV cable circuit[C]//*IEEE Conference on Electrical Insulation and Dielectric Phenomena (CEIDP)*, Toronto, ON, Canada, 2016.
- [11] 张周胜, 马爱清, 盛戈峰, 等. 高压交联聚乙烯电缆局部放电脉冲的时频特性识别方法[J]. *高电压技术*, 2011, 37(8): 1997-2003.
- ZHANG Zhousheng, MA Aiqing, SHENG Gehao, et al. Time-frequency characteristic based partial discharge pulses identification technique for the high voltage XLPE power cables[J]. *High Voltage Engineering*, 2011, 37(8): 1997-2003.
- [12] 司文荣, 李军浩, 袁鹏, 等. 基于波形非线性映射的多局部放电脉冲群快速分类[J]. *电工技术学报*, 2009, 24(3): 216-221+228.
- SI Wenrong, LI Junhao, YUAN Peng, et al. The fast grouping technique of PD sequence based on the nonlinear mapping of pulse shapes[J]. *Transactions of China Electrotechnical Society*, 2009, 24(3): 216-221+228.
- [13] Dong M, Sun Z, Wang C. A pattern recognition method for partial discharge detection on insulated overhead conductors[C]//*IEEE Canadian Conference of Electrical and Computer Engineering (CCECE)*, Edmonton, AB, Canada, 2019.
- [14] Li Gaoyang, Rong Mingzhe, Wang Xiaohua, et al. Partial discharge patterns recognition with deep Convolutional Neural Networks[C]//*International Conference on Condition Monitoring and Diagnosis (CMD)*, Xi'an, China, 2016.
- [15] Lee D, Lee J, Choe J, et al. PD pattern recognition in Metal-clad switchgear by using UHF technology[C]//*3rd International Conference on Electric Power Equipment-Switching Technology (ICEPE-ST)*, Busan, Korea, 2015.
- [16] 司雯, 李天娇, 李斯盟, 等. 交直流复合电压下老化油纸绝缘针板模型局部放电特性[J]. *高电压技术*, 2017, 43(6): 1980-1987.
- SI Wen, LI Tianjiao, LI Simeng, et al. Partial discharge characteristics of needle-plate electrodes in aging oil-paper insulation under combined AC-DC voltage [J]. *High Voltage Engineering*, 2017, 43(6): 1980-1987.
- [17] 张晓星, 舒娜, 徐晓刚, 等. 基于三维谱图混沌特征的 GIS 局部放电识别[J]. *电工技术学报*, 2015, 30(1): 249-254.
- ZHANG Xiaoxing, SHU Na, XU Xiaogang, et al. GIS partial discharge recognition based on chaos features of the three-dimensional spectra[J]. *Transactions of China Electrotechnical Society*, 2015, 30(1): 249-254.
- [18] 董晨晔, 钱勇, 钟勇, 等. 基于 EEMD 和二维 Gabor 变换的 GIS 局放特征融合识别方法[J]. *电气自动化*, 2018, 40(5): 108-111.
- DONG Chenye, QIAN Yong, ZHONG Yong, et al. Method of GIS localization feature fusion based on EEMD and 2D Gabor transform[J]. *Electrical Automation*, 2018, 40(5): 108-111.
- [19] 李利品, 党瑞荣, 樊养余. 改进的 EEMD 算法及其在多相流检测中的应用[J]. *仪器仪表学报*, 2014, 35(10): 2365-2371.
- LI Lipin, DANG Ruihong, FAN Yangyu. Modified EEMD de-noising method and its application in multi-phase flow measurement[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(10): 2365-2371.
- [20] 徐伟, 陶亮. 二维实值 Gabor 变换在图像压缩上的应用[J]. *计算机工程与应用*, 2012, 48(7): 177-180+223.
- XU Wei, TAO Liang. Application of 2D real-valued discrete Gabor transform in image compression[J]. *Computer Engineering and Applications*, 2012, 48(7): 177-180+223.
- [21] 唐志国, 唐铭泽, 李金忠, 等. GIS 设备局部放电类型表现相似性及模式识别准确性的探讨[J]. *高电压技术*, 2018, 44(8): 2479-2485.
- TANG Zhiguo, TANG Mingze, LI Jinzhong, et al. Discussion on the resemblance of different partial discharges and accuracy of PD pattern recognition of GIS equipment[J]. *High Voltage Engineering*, 2018, 44(8): 2479-2485.
- [22] 孙林, 杨世元. 最小二乘支持向量机构造的函数链接型神经网络在滚动轴承故障诊断中的应用[J]. *中国电机*

- 工程学报,2010,30(8):82-87.
- SUN Lin, YANG Shiyuan. Application of functional link artificial neural networks constructed with least squares support vector machine in fault diagnosis of rolling bearings[J]. Proceedings of the CSEE,2010,30(8):82-87.
- [23] 黄景林,彭显刚,简胜超,等. 基于深度学习与不平衡样本集的输电线路故障分类[J]. 智慧电力,2021,49(2):114-119.
- HUANG Jinglin, PENG Xiangang, JIAN Shengchao, et al. Transmission line fault classification based on deep learning and imbalanced sample set[J]. Smart Power, 2021,49(2):114-119.
- [24] Vapnik V. The nature of statistical learning theory [M]. New York, USA: Springer-Verlag, 1995: 138-146.
- [25] 唐炬,林俊亦,卓然,等. 基于支持向量数据描述的局部放电类型识别[J]. 高电压技术, 2013, 39(5): 1046-1053.
- TANG Ju, LIN Junyi, ZHUO Ran, et al. Partial discharge type recognition based on support vector data description[J]. High Voltage Engineering, 2013, 39(5):1046-1053.
- [26] 唐松平,周舟,彭刚,等. 基于自适应神经模糊的 GIS 缺陷模式识别方法[J]. 计算机与数字工程,2019,47(9):2321-2326.
- TANG Songping, ZHOU Zhou, PENG Gang, et al. Defect pattern recognition method in GIS based on adaptive network-based fuzzy inference system[J]. Computer & Digital Engineering, 2019, 47(9):2321-2326.
- [27] 杨赢,邵能灵,郁惟镛. 基于自谐振神经网络的线路故障自适应选相元件[J]. 电力系统自动化,2005, 29(7):65-69+92.
- YANG Ying, TAI Nengling, YU Weiyong, et al. Adaptive phase selection relays utilizing adaptive resonance theory based artificial neural networks[J]. Automation of Electric Systems,2005,29(7):65-69+92.
- [28] 田猛,张波文,周腊吾,等. 基于 RBF 神经网络滑模变结构独立变桨控制研究[J]. 电力系统保护与控制, 2019,47(4):107-114.
- TIAN Meng, ZHANG Bowen, ZHOU Lawu, et al. Study of individual variable pitch control based on RBF neural networks-sliding mode control[J]. Power System Protection and Control,2019,47(4):107-114.
- [29] 胡凯旋,刘利强,李昌陵,等. 基于仿生模式识别的 GIS 局部放电类型辨识[J]. 高压电器,2016,52(2):35-41.
- HU Kaixuan, LIU Liqiang, LI Changling, et al. GIS partial discharge type recognition based on the BPR [J]. High Voltage Apparatus,2016,52(2):35-41.
- [30] 郑智聪,王红,齐林海. 基于深度学习模型融合的电压暂降源识别方法[J]. 中国电机工程学报,2019,39(1):97-104+324.
- ZHENG Zhicong, WANG Hong, QI Linhai, et al. Recognition method of voltage sag sources based on deep learning models' fusion[J]. Proceedings of the CSEE, 2019,39(1):97-104+324.
- [31] 黄雪薇,熊俊,张宇,等. 基于残差卷积神经网络的开关柜局部放电模式识别[J]. 中国电力,2021,54(2):44-51.
- HUANG Xueyou, XIONG Jun, ZHANG Yu, et al. Partial discharge pattern recognition of switchgear based on residual convolutional neural network[J]. Electric Power,2021,54(2):44-51.
- [32] 董纪兴,张殿海,任自艳,等. 基于深层卷积神经网络的电工钢片矢量磁特性模拟[J]. 高压电器,2021,57(4):28-33.
- DONG Jixing, ZHANG Dianhai, REN Ziyang, et al. Vector magnetic characteristics simulation of electrical steel sheet based on deep convolutional neural network [J]. High Voltage Apparatus,2021,57(4):28-33.
- [33] Hua Yuming, Guo Junhai, Zhao Hua. Deep belief networks and deep learning [C]// International Conference on Intelligent Computing and Internet of Things, Harbin, China, 2015.
- [34] 唐志国,唐铭泽,李金忠,等. 电气设备局部放电模式识别研究综述[J]. 高电压技术,2017,43(7):2263-2277.
- TANG Zhiguo, TANG Mingze, LI Jinzhong, et al. Review on partial discharge pattern recognition of electrical equipment [J]. High Voltage Apparatus, 2017, 43(7):2263-2277.