

DOI:10.13296/j.1001-1609.hva.2019.12.014

## 基于深度学习的变压器局部放电模式识别研究

周 秀, 朱洪波, 马云龙, 刘威峰, 高 博, 田 天, 罗 艳,  
李秀广, 何宁辉

(国网宁夏电力有限公司电力科学研究院, 银川 750011)

**摘要:** 针对传统PD模式识别用统计特征量需要依赖专家经验而缺乏一定的泛化性问题和卷积神经网络(CNN)模式识别算法缺乏PD图谱时序特征信息的问题,文中构建了基于CNN-LSTM深度学习的PD PRPD图谱模式识别模型,该模型综合了CNN善于挖掘PRPD图谱局部空间信息的优点和长短时记忆网络(LSTM)善于挖掘PD图谱时序特征信息的优点,可同时提取PRPD图谱的局部空间特征和时序特征,利用变压器典型绝缘缺陷放电图谱对构建的网络进行性能测试,并与CNN和LSTM对比,结果表明,对于PD图谱稳定的悬浮电位缺陷,CNN-LSTM和CNN的识别能力均为100%,但是对于金属突出物缺陷、油纸气隙缺陷和沿面放电缺陷,CNN-LSTM的识别能力优于CNN,CNN-LSTM网络的整体识别性能优于CNN和LSTM。

**关键词:** 局部放电; 模式识别; CNN; LSTM; 混合网络

### Partial Discharge Pattern Recognition of Transformer Based on Deep Learning

ZHOU Xiu, ZHU Hongbo, MA Yunlong, LIU Weifeng, GAO Bo, TIAN Tian, LUO Yan,  
LI Xiuguang, HE Ninghui

(Power Research Institute of State Grid Ningxia Power Co., Yinchuan 750011, China)

**Abstract:** In this paper the research on transformer(partial discharge PD) pattern recognition work is carried out. The problem of the statistical feature quantity for PD pattern recognition depends on the expert experience and lacks certain generalization. The CNN convolutional neural network mode pattern recognition algorithm lacks the time series feature information of PD map. The PD PRPD pattern pattern recognition algorithm of CNN-LSTM which combines the advantages of CNN network to exploit the local spatial information of PRPD map and the advantages of LSTM long and short memory network to exploit the time series feature information of PD map is proposed. The feature vector output by CNN pooling layer is used as the input of LSTM. The spatial characteristics and timing characteristics are model-recognized by Softmax classifier. The performance of CNN-LSTM is compared with CNN network and LSTM network CNN and CNN-LSTM have 100% recognition ability for PD spectrum stable suspension potential defects but CNN-LSTM has better recognition ability than CNN for metal protrusion defects oil paper air gap defects and creeping discharge defects which shows that the overall recognition performance of CNN-LSTM network is better than CNN and LSTM.

**Key words:** partial discharge; pattern recognition; CNN; LSTM; hybrid network

## 0 引言

局部放电类似于电力装备绝缘系统内的慢性肿瘤,长期的放电过程将导致绝缘的击穿,甚至引发火灾等安全事故<sup>[1-3]</sup>。电力变压器内部绝缘结构

复杂,局部放电(partial discharge, PD)绝缘缺陷的类型也不尽相同,通过对PD绝缘缺陷类型的有效识别,有助于准确地了解和掌握变压器内部绝缘缺陷的性质和特征,对于掌握设备的绝缘状况及指导设备的检修等工作有着十分重要的工程意义<sup>[4]</sup>。目

前,关于PD缺陷类型的模式识别主要是建立在以统计特征量的基础上,而统计特征量的有效提取需要依赖领域内的专家经验,缺乏一定的泛化性<sup>[5-6]</sup>。

随着图像、文字、视频等研究领域识别技术的快速发展,基于深度学习的分类算法,例如,深度置信网络(DBN)、深度神经网络(DNN)、卷积神经网络(CNN)也开始逐渐在PD模式识别领域获得应用<sup>[7-10]</sup>。2017年,湖南大学郑剑等学者采用CNN进行变压器PD的模式识别,实验结果表明,CNN的识别率明显优于传统识别方法<sup>[6]</sup>。2018年,上海交通大学江秀臣、盛戈峰等学者将CNN应用于GIS PD的模式识别,并将基于CNN的识别结果与SVM和BP神经网络进行对比,结果表明CNN的识别准确率优于SVM和BP神经网络<sup>[10-12]</sup>,并对循环神经网络(RNN)、深度神经网络(DNN)和CNN的超声波识别效果进行了对比<sup>[8]</sup>。德国斯图加特大学的MIRZAEI H等学者将长短期记忆网络(LSTM)应用于绝缘油中不同PD缺陷类型的识别,结果表明,在时域单脉冲电信号作为输入的情况下,LSTM的识别精度略低于基于统计特征的随机森林法,但由于LSTM法具有无需进行人为统计识别特征的优点,仍然获得作者的推荐<sup>[7]</sup>。

目前,现场电力设备PD在线监测系统的显示通常为图谱形式,图谱为画面形式,所以采用图像识别领域比较成熟的CNN直接对图谱进行识别会取得不错的效果。而如果从时间轴角度上观察,现场PD图谱是一个随放电时间的增加和放电强度的变化而发生局部波动(跳动)的视频,图谱特征呈现随时间发生变化的时间序列特征,而恰好LSTM具有优异的时序信息捕捉功能,因此,针对在线监测系统PD图谱的模式识别,综合CNN和LSTM两种方法的优势,文中提出了基于CNN-LSTM网络的PD识别算法,采用CNN挖掘图谱的局部空间信息,结合LSTM挖掘图谱的时序信息,将两类特征信息结合起来,实现PD在线监测系统图谱的精准模式识别。

## 1 基于CNN和LSTM的深度学习算法

### 1.1 CNN深度学习算法

作为图像识别领域广泛应用的多层神经网络识别算法,CNN是一种前馈神经网络,具有局部感知、网络权重共享和多卷积核等主要特征。典型的卷积神经网络通常包含5层,分别为输入层、卷积层、池化层、全连接层和输出层,见图1<sup>[13-15]</sup>。

输入层输入的通常为识别对象对应的像素矩阵(RGB)。卷积层由多个特征面组成,每个特征面




图1 典型卷积神经网络

Fig. 1 Typical convolutional neural network

包含多个神经元,在前馈期间,卷积核对输入进行卷积操作,提取局部区域上的特征集。假设第 $i$ 层卷积层输出的特征向量为 $H_i$ ,则存在

$$H_i = f(H_{i-1} \otimes w_i + b_i) \quad (1)$$

式(1)中: $f(\cdot)$ 为激活函数; $w_i$ 和 $b_i$ 分别为第 $i$ 层卷积层的权值向量和偏移量。池化层同样由多个特征面组成,每个特征面与卷积层的特征面一一对应,见图1。全连接层的神经元和上一层特征面相连接,提取上一层特征面中具有分类特征的信息,经过线性/非线性运算将输出输入到输出层。输出层的作用是将全连接层的非标准化输出映射到预测输出类别上的概率分布。

### 1.2 LSTM深度学习算法

为了解决循环神经网络无法获取长间隔输入的时间特征信息,德国学者S. Hochreiter和瑞士学者J. Schmidhuber提出了在循环神经网络中增加一个门控(cell)结构的改进型循环神经网络,增加门控结构的循环神经网络就是长短期记忆网络(LSTM),门控结构主要包括3个门,分别为遗忘门(forget gate)、输入门(input gate)和输出门(output gate),遗忘门决定丢弃的信息量,输入门决定输入的信息量,输出门决定输出的信息量<sup>[16-18]</sup>。

长短期记忆网络门控单元结构见图2。图2中:符号 $\otimes$ 表示向量元素相乘;符号 $\oplus$ 表示向量的拼接; $x_t$ 为当前时刻门控单元输入; $h_{t-1}$ 表示相邻上一时刻门控单元的输出; $c_{t-1}$ 为相邻上一时刻门控单元的状态; $c_t$ 为当前时刻门控单元的状态; $h_t$ 为当前时刻门控单元的输出; $\sigma$ 表示函数 $\text{sigmoid}(\cdot)$ ;  $\tanh$ 表示函数 $\tanh(\cdot)$ 。




图2 LSTM cell单元结构

Fig. 2 LSTM cell structure

### 1.3 CNN-LSTM 深度学习算法

#### 1.3.1 网络架构

CNN-LSTM 是卷积神经网络(CNN)和长短时记忆网络(LSTM)的结合体,综合了两者的优点:利用卷积神经网络利于提取网络输入局部特征的优点提取PD图谱的空间特征,利用长短时记忆网络利于提取不同时刻输入之间时序特征的优点提取不同时刻PD图谱上的时序特征,最后通过 Softmax 分类器进行模式识别。CNN-LSTM 深度学习算法的网络架构见图3。




图3 CNN-LSTM PD 图谱识别混合网络架构

Fig. 3 CNN-LSTM PD spectrum identification hybrid network architecture

在CNN处理层,需要提取的是输入图谱的空间信息,并生成对应的特征向量。令  $N$  为输入PD图谱的数量,对于输入的单张图谱,假设该图谱的像素矩阵为  $m \times n$ ,卷积核的大小为  $k \times k$ ,采用 same 方式卷积,对输入图像的外围进行零元素填充,填充长度为  $k/2$ ,图像矩阵由大小  $m \times n$  扩充为  $(m+k) \times (n+k)$ ,从而保证卷积运算后的输出结果和输入维数的不变。令  $v_{ij}$  为扩充后输入图像第  $i$  行第  $j$  列像素值,则以  $v_{ij}$  为卷积核领域窗口顶角元素的窗口内矩阵元素为

$$X_{ij} = \begin{pmatrix} v_{ij} & \cdots & v_{i(j+k-1)} \\ \vdots & \ddots & \vdots \\ v_{(i+k-1)(j)} & \cdots & v_{(i+k-1)(j+k-1)} \end{pmatrix} \quad (2)$$

基于式(1)对窗口矩阵  $X_{ij}$  卷积运算

$$Y_{ij} = f(X_{ij} \otimes w_i + b_i) \quad (3)$$

式(3)中激活函数采用 ReLU 函数

$$f(x) = \max(0, x) \quad (4)$$

在完成输入图谱的卷积运算后,采用最大池化法对卷积层的输出  $Y_{ij}$  进行池化,获取池化窗口内的最大特征值,实现特征集合的二次优化,用  $R_n$  表示第  $n$  张输入图谱经过卷积、池化后的特征图谱,则存在

$$R_n = \max(Y_{ij}) \quad (5)$$

当完成所有输入PD图谱的特征提取后,卷积神经网络层处理提取的特征矩阵则为

$$R = (R_1, R_2, \dots, R_n, \dots, R_N) \quad (6)$$

由于输入的PD图谱集是随着时间在一定程度上波动的图谱,假设第  $n$  张输入图谱对应的获取时刻为  $t$ ,则可以将  $R_n$  作为  $t$  时刻长短时记忆网络的输入,用  $R_t$  来表示  $R_n$ ,则对应的长短时记忆网络的单元更新过程为:

$$f_t = \sigma(W_f [R_t; x_t] + b_f) \quad (7)$$

$$i_t = \sigma(W_i [R_t; x_t] + b_i) \quad (8)$$

$$o_t = \sigma(W_o [R_t; x_t] + b_o) \quad (9)$$

$$C_t = \tanh(W_c [R_t; x_t] + b_c) \quad (10)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes C_t \quad (11)$$

$$h_t = o_t \otimes \tanh(c_t) \quad (12)$$

式(7)-(12)中:  $W_f$ 、 $W_i$  和  $W_o$  分别为遗忘门、输入门和输出门的权重矩阵;  $b_f$ 、 $b_i$  和  $b_o$  分别为遗忘门、输入门和输出门的偏置项;  $C_t$  为输入单元的状态;  $W_c$  和  $b_c$  分别为输入单元状态的权重矩阵和偏置项。

#### 1.3.2 算法流程

基于CNN-LSTM的变压器缝隙泄漏电磁波PD模式识别流程见图4。首先将UHF天线传感器耦合到的PD图谱集分为训练集和测试集两部分,然后对PD图谱进行预处理,保证模式识别网络输入的规范化,预处理操作包括放电幅值的归一化、图谱色彩的灰度化和二值化、以及通过阈值剪切提取图谱中有效的待输入数据,最后将预处理后的训练集图谱灰度矩阵输入到待训练的CNN-LSTM模式识别网络,训练过程采用反向传播采用梯度下降法,待网络输出和期望值之间的误差值小于等于期望值,结束训练,最后将预处理后的测试图谱集输入到训练好的CNN-LSTM模式识别网络,对网络训练结果进行验证。

## 2 实验

### 2.1 实验电路

变压器PD缝隙泄漏电磁波模式识别实验电路见图5,绝缘油为25号变压器油,传感器为定向耦合金属外壳屏蔽Vivaldi天线,实验结果见图6。

### 2.2 变压器典型局放缺陷模型的构建

对于电力变压器,根据运行经验可知,易发生PD的部位包括变压器绕组匝间、出线端绝缘纸板、油屏、压板、紧固件、油中气泡和杂质微粒,可以将电




图4 CNN-LSTM混合网络的算法流程图

Fig. 4 Algorithm flow chart of CNN-LSTM




图5 变压器PD缝隙泄漏电磁波模式识别实验电路

Fig. 5 Transformer PD slot leakage electromagnetic wave pattern recognition experiment circuit


图6 UHF天线阵列检测到的PD电磁波信号  
(采样率:10 GHz)

Fig. 6 PD electromagnetic wave signal detected by UHF antenna array (sampling rate: 10 GHz)

力变压器PD类型归结为如下几类:油隙放电(绕组中部油—隔板绝缘、绕组端部、接触绝缘导线和电工纸、线圈间);引线、搭接线等油纸绝缘中的PD;绕组匝间绝缘局部击穿;电工纸沿面滑闪放电<sup>[19-21]</sup>。为了对CNN-LSTM网络的PD模式识别效果进行验证,文中设置了四种典型变压器PD绝缘缺陷类型:金属突出物缺陷、油纸气隙缺陷、沿面放电缺陷和悬浮电位缺陷,见图7。




图7 4种变压器典型PD绝缘缺陷模型

Fig. 7 Typical PD insulation defect model of four transformers

采用逐步升压法逐渐升高实验电压,确定模拟缺陷的起始放电电压  $U_a$  和击穿电压  $U_b$ ,调节实验电压为  $U_m$ ,其中

$$U_m = (U_a + U_b) / 2 \quad (13)$$

保持实验电压稳定,利用Tek DPO 7000示波器同时采集分压电容两端电压(提供相位信息)和Vivaldi天线传感器捕获的高频电磁波信号,采样率为50 MHz,共采集2 500个交流周期的PD UHF信号。

### 2.3 局放实验结果的分析

假设绝缘缺陷放电脉冲起始采样时刻为  $t$ ,单个绝缘缺陷PD脉冲信号的整个采样过程用时  $\Delta T$ ,则电力变压器4种典型绝缘缺陷  $t$  时刻、 $(t + \Delta T/2)$  时刻和  $(t + \Delta T)$  时刻下的PD图谱见图8-11。




(a) 金属突出物缺陷 $t$ 时刻PD脉冲信号图谱(b) 金属突出物缺陷( $t+\Delta T/2$ )时刻PD脉冲信号图谱(c) 金属突出物缺陷( $t+\Delta T$ )时刻PD脉冲信号图谱

图8 电力变压器绝缘油中金属突出物缺陷PD UHF PRPD图谱

Fig. 8 PD UHF PRPD spectrum of metal protrusion defects in insulating oil of power transformer







(a) 油纸气隙缺陷 $t$ 时刻PD脉冲信号图谱(b) 油纸气隙缺陷( $t+\Delta T/2$ )时刻PD脉冲信号图谱(c) 油纸气隙缺陷( $t+\Delta T$ )时刻PD脉冲信号图谱图9 电力变压器绝缘油中油纸气隙缺陷PD图谱  
Fig. 9 PD spectrum of oil film air gap defects in power transformer insulating oil(a) 油纸沿面放电缺陷 $t$ 时刻PD脉冲信号图谱(b) 油纸沿面放电缺陷( $t+\Delta T/2$ )时刻PD脉冲信号图谱(c) 油纸沿面放电缺陷( $t+\Delta T$ )时刻PD脉冲信号图谱

图10 电力变压器绝缘油中油纸沿面放电缺陷PD图谱

Fig. 10 PD spectrum of oil surface paper discharge defect in power transformer insulating oil




(a) 悬浮电位缺陷 $t$ 时刻PD脉冲信号图谱(b) 悬浮电位缺陷( $t+\Delta T/2$ )时刻PD脉冲信号图谱(c) 悬浮电位缺陷( $t+\Delta T$ )时刻PD脉冲信号图谱

图11 电力变压器绝缘油中悬浮电位缺陷PD图谱

Fig. 11 PD spectrum of floating potential defects in insulating oil of power transformer

由图8可知,金属突出物缺陷在不同放电时刻下的放电脉冲图谱存在一定的波动性,起始采样时刻的PD脉冲信号主要集中在交流相位正半周和负半周峰值附近,正半周峰值附近的放电脉冲数略大于负半周峰值附近的放电脉冲数,随着加压时间的增加,PD图谱逐渐向整个交流相位区间扩展。

由图9可知,气隙绝缘缺陷在不同放电时刻下的放电脉冲图谱同样存在一定的波动性,起始采样时刻,PD脉冲主要集中在正半周锐角相位区间和负半周锐角相位区间,随着加压时间的增加,PD脉冲分布的相位区间逐渐增加,交流相位正半周内的PD脉冲从正半周锐角相位区间向正半周起始过零点相位区间的方向扩展,交流相位负半周内的PD脉冲则从负半周锐角相位区间向负半周起始过零点相位区间的方向扩展。

从图10中可以看出,油纸沿面PD脉冲的稳定性不如金属突出物缺陷和油纸气隙缺陷,油纸沿面PD脉冲的相位分布区间存在较大的波动性,在起始采样时刻,PD脉冲主要集中在正半周偏向于锐角区间和负半周偏向于锐角区间,负半周的放电次数和对应的脉冲幅值均大于正半周,随着加压时间的增加,PD脉冲的分布区间已逐渐向交流相位正负半周的过零点扩展,直至PD脉冲的分布区间已将近布满整个交流相位区间。

图11为悬浮电位缺陷在25号变压器绝缘油下的PD UHF PRPD图谱,气隙绝缘缺陷放电过程稳定,随着加压时间的增加,放电脉冲的相位区间保持稳定,分布在正半周过起始零点和负半周起始过零点附近。

3 算法性能的对比分析

3.1 算法参数的设置

CNN-LSTM混合网络的主要参数设置见表1。PD模式识别装置的配置为:英特尔i5处理器(2.5 GHz),内存为8 GB,系统为Win7,运行环境为Tensorflow (Anaconda)。识别对象为电力变压器4类典型绝缘缺陷PD图谱:金属突出物缺陷、油纸气隙缺陷、油纸沿面放电缺陷和悬浮电位缺陷,输入数据为PDUHF PRPD图谱,其中训练集数据占数据样本集的80%,测试集数据占数据样本集的20%。

3.2 性能对比结果

根据表1参数值进行CNN-LSTM网络设置,卷积层层数为5、池化层层数为5、LSTM的层数为1,其余参数为系统默认,将灰度化处理后的PD图谱单通道矩阵数据输入网络进行训练和识别,并以总体

表1 CNN-LSTM混合网络的主要参数设置  
Table 1 Main parameter settings of CNN-LSTM hybrid network

| 项目        | 参数设置        |
|-----------|-------------|
| 卷积核尺寸及步长  | (5×5, 1)    |
| 池化方式      | Max-pooling |
| 池化窗口尺寸及步长 | (2×2, 2)    |
| 填充模式      | Same Mode   |
| 激活函数      | Relu        |
| 权重        | 随机正太分布      |
| LSTM节点数   | 100         |
| 优化函数      | SGD         |
| 学习率       | 0.001       |

预测准确率 $P_r$ 为作为CNN-LSTM网络模式识别能力的评价参数, $P_r$ 的计算为

$$P_r = \frac{N_p}{N_{sum}}$$

(14)

式(14)中: $N_p$ 为CNN-LSTM网络所预测的PD类型和实际放电类型相一致的样本数; $N_{sum}$ 为样本总数。CNN-LSTM网络对电力变压器不同类型典型绝缘缺陷的识别结果见表2。

从表2中可以看出,CNN-LSTM对悬浮电位绝缘缺陷的准确识别率最高,识别率达到100%,对沿面PD绝缘缺陷的识别率最低,但也达到了89%的识别率。

表2 CNN-LSTM混合网络对不同类型典型绝缘缺陷的识别结果

Table 2 Identification results of different types of typical insulation defects in CNN-LSTM hybrid network %

| $P_r$   | 识别为金属突出物缺陷的比率 | 识别为油纸气隙缺陷的比率 | 识别为沿面放电缺陷的比率 | 识别为悬浮电位缺陷的比率 |
|---------|---------------|--------------|--------------|--------------|
| 金属突出物缺陷 | 94            | 4            | 2            | 0            |
| 油纸气隙缺陷  | 6             | 90           | 3            | 1            |
| 沿面放电缺陷  | 5             | 6            | 89           | 0            |
| 悬浮电位缺陷  | 0             | 0            | 0            | 100          |

分别将相同数据PD图谱数据输入到卷积神经网络CNN和长短时记忆网络LSTM网络,其中CNN网络和LSTM网络的参数设置和CNN-LSTM网络设置相同,其余参数为系统默认,对比CNN-LSTM网络、CNN网络和LSTM网络对电力变压器PD典型绝缘缺陷的模式识别性能,对比结果见表3。

从表3中可以看出,对于金属突出物缺陷、油纸气隙缺陷和沿面放电缺陷,CNN-LSTM网络的局部PD图谱模式识别效果优于CNN网络和LSTM网络,

表3 电力变压器典型绝缘缺陷识别性能对比结果

Table 3 Performance comparison of typical insulation

| $P_r$    | defects of power transformers |        |        |        | % |
|----------|-------------------------------|--------|--------|--------|---|
|          | 金属突出物缺陷                       | 油纸气隙缺陷 | 沿面放电缺陷 | 悬浮电位缺陷 |   |
| CNN      | 83                            | 80     | 85     | 100    |   |
| LSTM     | 80                            | 78     | 82     | 98     |   |
| CNN-LSTM | 94                            | 90     | 89     | 100    |   |

但是对于悬浮电位缺陷,CNN-LSTM网络的识别效果和CNN的识别效果相同,均为100%,这样的效果与不同类型绝缘缺陷PD图谱的波动情况相照应,悬浮电位缺陷的放电图谱的稳定性明显优于其他类型的放电图谱,而LSTM网络的优势在于时序特征信息的提取,所以在CNN-LSTM网络对悬浮电位缺陷类型进行模式识别时,LSTM网络并未提供过多帮助,但是对于金属突出物缺陷、油纸气隙缺陷和沿面放电缺陷,这三类缺陷的放电图谱随着恒压条件下加压时间的增加,其对应放电图谱的波动性较明显,此时,LSTM网络提取图谱时序特征信息的优势获得体现,提高了CNN网络对这些缺陷类型的识别精度。

#### 4 结论

文中构建了基于CNN-LSTM混合网络的电力变压器PD模式识别算法,该算法综合了CNN善于挖掘PD图谱局部空间信息的优势和LSTM善于挖掘PD图谱时序特征信息的优势,通过研究获得了以下两点结论:

1)构建了CNN-LSTM混合网络PD模式识别构架,通过卷积层和池化层实现PD图谱信息的局部空间特征信息的提取,然后将提取的特征信息输入到LSTM网络提取包含时序特征信息的所有的PD图谱识别特征信息,最后经全连接层和Softmax分类器实现PD绝缘缺陷的模式识别,算法的有效性进行验证,结果表明文中提出的算法可有效实现PD绝缘缺陷的模式识别;

2)对比了CNN、LSTM和CNN-LSTM网络对不同PD绝缘缺陷的模式识别能力,结果表明,对于PD图谱稳定的悬浮电位缺陷,CNN和CNN-LSTM的识别能力均为100%,但是对于金属突出物缺陷、油纸气隙缺陷和沿面放电缺陷,CNN-LSTM的识别能力优于CNN和LSTM。

#### 参考文献:

[1] KHAN Q, REFAAT S S, ABU-RUB H, et al. Partial dis-

charge detection and diagnosis in gas insulated switchgear: State of the art[J]. IEEE Electrical Insulation Magazine, 2019, 35(4): 16-33.

[2] 李 臻, 罗林根, 陈敬德, 等. 基于特高频无线传感阵列的新型局部放电定位方法[J]. 高电压技术, 2019, 45(2): 418-425.

LI Zhen, LUO Linggen, CHEN Jingde, et al. Novel localization method for partial discharge based on utral-high frequency wireless sensor array[J]. High Voltage Engineering, 2019, 45(2):418-425.

[3] SHAFIQ M, KAUHANIEMI K, ROBLES G, et al. Partial discharge signal propagation in medium voltage branched cable feeder[J]. IEEE Electrical Insulation Magazine, 2018 (34): 18-29.

[4] 张秦侵, 宋 辉, 姜 勇, 等. 基于OS-ELM的变压器局部放电模式识别[J]. 高电压技术, 2018, 44(4):1122-1130.

ZHANG Qinqin, SONG Hui, JIANG Yong, et al. Partial discharge pattern recognition of transformer based on OS-ELM [J]. High Voltage Engineering, 2018, 44(4):1122-1130.

[5] BASHARAN V, MARIA SILUVAIRAJ W I, RAMASAMY VELAYUTHAM M. Recognition of multiple partial discharge patterns by multi-class support vector machine using fractal image processing technique[J]. IET Science, Measurement & Technology, 2018, 12(8):1031-1038.

[6] 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.

[7] ADAM B, TENBOHLEN S. Classification of multiple PD sources by signal features and LSTM networks[C]//IEEE International Conference on High Voltage Engineering and Application (ICHVE). ATHENS, Greece: IEEE, 2018: 1-4.

[8] ZHANG Q, LIN J, SONG H, et al. Fault identification based on pd ultrasonic signal using RNN, DNN and CNN[C]//Condition Monitoring and Diagnosis(CMD). Perth, WA, Australia: IEEE, 2018: 1-6.

[9] BANNO K, NAKAMURA Y, FUJII Y, et al. Partial discharge source classification for switchgears with transient earth voltage sensor using convolutional neural network[C]//Condition Monitoring and Diagnosis (CMD). Perth, WA, Australia: IEEE, 2018: 1-5.

[10] 宋 辉, 代杰杰, 张卫东, 等. 复杂数据源下基于深度卷积网络的局部放电模式识别[J]. 高电压技术, 2018, 44(11):3625-3633.

SONG Hui, DAI Jiejie, ZHANG Weidong, et al. Partial discharge pattern recognition based on deep convolutional neural network under complex data sources[J]. High Voltage Engineering, 2018, 44(11):3625-3633.

[11] WAN X, SONG H, LUO L, et al. Pattern recognition of par-

- tial discharge image based on one-dimensional convolutional neural network[C]//Condition Monitoring and Diagnosis (CMD). Perth, WA, Australia: IEEE, 2018: 1-4.
- [12] 万晓琪, 宋 辉, 罗林根, 等. 卷积神经网络在局部放电图像模式识别中的应用[J]. 电网技术, 2018, 43(6): 2219-2226.
- WAN Xiaoqi, SONG Hui, LUO Lingen, et al. Application of convolutional neural networks in pattern recognition of partial discharge image[J]. Power System Technology, 2018, 43(6): 2219-2226.
- [13] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [14] 刘兆英, 李玉鉴, 张 婷, 等. 深度学习: 卷积神经网络从入门到精通[M]. 北京: 机械工业出版社, 2018.
- LIU Zhangying, LI Yujian, ZHANG Ting, et al. Deep learning: Convolutional neural networks from initial to proficient [M]. Beijing: Machinery Industry Press, 2018.
- [15] WIKIPEDIA. Convolutional neural network-wikipedia[EB/OL]. [https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network). 2019-2-18.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [17] GERS F A, SCHRAUDOLPH N N, SCHMIDHUBER J. Learning precise timing with LSTM recurrent networks[J]. Journal of Machine Learning Research, 2002(3): 115-143.
- [18] SUNDERMEYER M, NEY H, SCHLÜTER R. From feedforward to recurrent LSTM neural networks for language modeling[J]. IEEE/ACM Transactions on Audio, Speech and Language Processing (TASLP), 2015, 23(3): 517-529.
- [19] 杨剑锋. 变压器内绝缘典型缺陷局部放电特性及产气规律研究[D]. 重庆: 重庆大学, 2010.
- YANG Jianfeng. Study on characteristics of partial discharge and the gas generation law for the typical defects in transformer internal insulation[D]. Chongqing: Chongqing University, 2010.
- [20] 王国利, 郝艳捧, 贾志东, 等. 电力变压器典型局放模型放电脉冲的特性研究[J]. 高电压技术, 2001, 21(2): 5-8.
- WANG Guoli, HAO Yanpeng, JIA Zhidong, et al. Study on pulse current of typical PD models in power transformer[J]. High Voltage Engineering, 2001, 21(2): 5-8.
- [21] 周加斌. 油中悬移微粒产生的局部放电特性与特征提取研究[D]. 重庆: 重庆大学, 2012.
- ZHOU Jiabin. Study on discharge characteristics and feature extraction for suspended movable particles defects in transformer oil[D]. Chongqing: Chongqing University, 2012.
- 周 秀(1984—), 男, 硕士研究生, 高级工程师, 状态检测室主管, 研究方向为变压器状态检修管理及线圈类设备故障诊断分析。
- 罗 艳(1990—), 女, 硕士研究生, 中级工程师, 主要研究方向为变压器故障诊断及状态检修(通讯作者)。