

DOI:10.19651/j.cnki.emt.2208982

移动端卷积神经网络开关柜局部 放电样本生成与检测*

戴昕宇¹ 徐焕宇² 张宁³(1.南京信息工程大学自动化学院 南京 210044; 2.无锡学院 无锡 214063;
3.科大讯飞工业智能业务部 杭州 310012)

摘要: 局部放电是造成高压电气设备最终发生绝缘击穿的重要原因,也是绝缘劣化的重要标征,针对目前开关柜局部放电常规检测手段存在检测信息量少,时效性差,诊断准确率低等问题,本文提出了一种可集成在移动端设备的卷积神经网络检测方法,并针对实际情况中存在放电类别样本不均匀的问题,提出了一种故障样本生成方法。将采集到的超声波信号经过去噪和预处理后通过短时傅里叶变换转化为二维时频谱图,输入卷积神经网络中进行局部放电模式识别,针对实际场景中出现故障样本不均匀问题,使用 AE-DCGAN 生成对抗网络生成故障样本。实例实验表明,本文所提出方法在移动端 t710 算力条件下,其准确率达到 97% 以上,算力达到 0.27 s,生成数据样本 MSE 误差均低于 0.067。

关键词: 局部放电;超声波检测;深度学习;故障样本生成

中图分类号: TM854 **文献标识码:** A **国家标准学科分类代码:** 470.4017

Partial discharge sample generation and detection of convolutional neural network switchgear at mobile end

Dai Xinyu¹ Xu Huanyu² Zhang Ning³(1. School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;
2. Wuxi University, Wuxi 214063, China;
3. iFLYTEK Industrial Intelligence Business Department, Hangzhou 310012, China)

Abstract: Partial discharge is an important cause of insulation breakdown of high-voltage electrical equipment, but also an important indicator of insulation deterioration, in view of the current switchgear partial discharge conventional detection methods have a small amount of detection information, poor timeliness, low diagnostic accuracy and other issues, this paper proposes a convolutional neural network detection method that can be integrated in mobile devices, and for the actual situation there is a problem of uneven discharge class samples, a fault sample generation method is proposed. The collected ultrasonic signal is de-noised and pre-processed into a two-dimensional temporal spectrogram by short-term Fourier transform, and the partial discharge pattern is identified in the input convolutional neural network, and the adversarial network is used to generate the fault sample for the problem of uneven fault sample in the actual scene. The example experiments show that the accuracy rate of the proposed method in this paper reaches more than 97%, the computing power reaches 0.27 seconds under the condition of t710 computing power of the mobile terminal, and the error of the MSE generated data sample is lower than 0.067.

Keywords: partial discharge; ultrasonic detection; deep learning; fault sample generation

0 引言

电网设备的大部分故障都是由于绝缘体老化造成的,

局部放电在电力设备中的表现形式是绝缘介质中局部区域击穿导致的放电现象,所以也是绝缘劣化的初始现象。从开关柜局部放电发生的位置、放电过程和现象来看可将其

收稿日期:2022-02-09

* 基金项目:国家自然科学基金(11704377,42105143)项目资助

分为 3 种类型:电晕放电、悬浮放电、表面放电,通过模式识别的方式可以分辨出局部放电类型,从而可以判断变压器设备是否需要检修和定位绝缘体劣化位置。

在高压开关柜局部放电发生的过程中,产生的脉冲电流会使局部区域瞬间加热膨胀,形成超声波,其从其放电点处以球面波方式传播。脉冲电流^[1-4]、TEV 法和超声波检测法等传统检测方法^[5-8]基于采集信息的量作为评判条件,因此不具备局部放电模式识别能力。对于不同类别的局部放电,其产生超声波的时频谱图也有所差异,本文提出一种可集成在移动端设备上的卷积神经网络对采集到的超声波信号进行模式识别,通过减少网络参数的方式,减少对硬件算力环境的依赖。与文献[9]通过深度可分离卷积代替常规卷积减少模型参数不同,本文使用多个 3×3 的卷积核,扩大卷积核感受域的方式,替代大尺度卷积核,从而减少网络参数,并将超声波信号的二维时频图作为特征,可有效对 3 种放电模式进行识别。对于特征的降维,与文献[10] LDA 对特征进行降维不同,本文运用梅尔倒谱对时频谱图进行下采样,减少特征矩阵参数,保留其二维特性。

深度学习神经网络的训练需要样本类别达到均衡,样本的数量不均匀往往导致训练效果差,模式识别能力差等问题。在实际情况中故障样本的出现频率往往小于正常样本,DC-GAN 对抗网络^[11-13]是一种基于生成器和判别器生成与原始数据分布几乎相同的假数据,本文提出了一种基于 DC-GAN 对抗网络的 AE-DCGAN 网络对故障样本实现样本生成,增加故障样本的数量,使训练集类别达到均衡。

1 数据处理和模型选取

1.1 技术研究方案

总的技术方案为:将采集到的开关柜局部放电超声波数据按 7:3 比例划分为训练集和测试集,数据归一标准化,并对其进行降噪处理、分帧加窗为二维时频谱图,建立类别样本特征矩阵数据集,选定模式识别网络进行训练和测试。对于实际场景中放电类别出现不均匀的情况,运用 AE-DCGAN 对抗网络对预处理之后的进行故障样本重构,实现三类放电样本数量均匀。技术流程如图 1 所示。

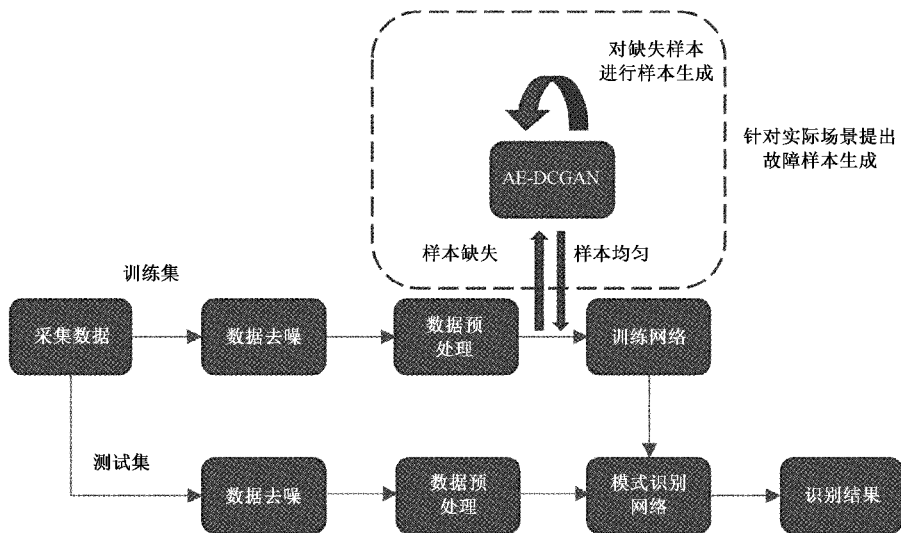


图 1 技术流程

1.2 超声波信号的预处理

基于奈奎斯特采样定律对超声波信号进行采集,将高压开关柜不同位置采集的 3 种超声波音频数据经过高通滤波器后按照类别比例分为训练集(0.7)和测试集(0.3),并对其进行归一标准化,以大于其放电工频周期(50 Hz)进行分帧,设置帧移为帧长的 $1/3$ 加窗,保证样本数量和帧信号的周期性,短时傅里叶处理、倒谱整理为对数功率时频谱图,图 2 为 3 种放电的时频谱图,3 种放电类型均为持续放电,周期为 20 ms。

在一维时域信号经过预处理后变化为时频谱图后,其时域特征和频域特征都得以体现,区分度远远大于时域图像,现实场景中存在的低频干扰,也得以在时频图上得到体现(如图 2 所示)。

1.3 信号的低频去噪

实际场景中采集的超声波信号中往往参杂着环境因素所带来的低频噪音,本文采用小波分解硬阈值量化的方法对存在的低频干扰进行去除。

本文对采集到的一维时域信号进行小波去噪^[14-15],分为 3 个步骤:小波分解,阈值量化,信号重构:

小波分解:根据小波基的正交性和对称性和选定 haar 小波作为小波基。根据信号复杂度,基于去噪后频谱图信噪比,对一维时域信号进行两次迭代分解。图 3 为小波分解示意图。

阈值量化:保留大尺度(高频系数)下的所有分解值,对于小尺度(低频部分)设定阈值,将阈值以下的小波系数清零。考虑到声音信号的连续性,没有采用文献^[16]的局部

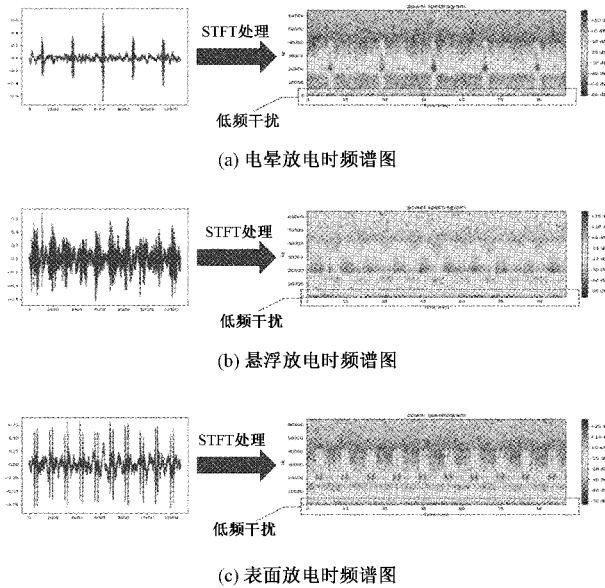


图2 局部放电时频谱图

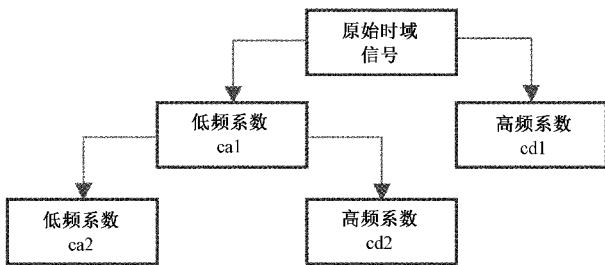


图3 小波分解示意图

自适应阈值,选取全局统一阈值,可有效的抑制白噪声干扰^[17],其计算公式如式(1)所示。

$$\mu = \sigma \sqrt{2 \ln N} \quad (1)$$

其中, $\sigma = MAD/0.6745$, MAD 为首层小波分解系数绝对值的中间值, 0.6745 为高斯噪声标准方差的调节系数, N 为信号的长度。阈值函数选取硬阈值法,使得重构后的信号有更好的逼近性。

$$\omega_{new} = \begin{cases} 0, & x < \mu \\ \omega, & x \geq \mu \end{cases} \quad (2)$$

式(2)为硬阈值函数,其中 ω_{new} 滤波后的小波域系数, ω 为小波分解后的小波系数。

信号重构:将处理过后的小波系数小波逆变换进行重构,恢复为去除低频干扰的时域信号。

1.4 故障样本生成

鉴于在实际场景中存在3种放电出现频率不均匀,需要样本数量均匀的情况,本文提出了一种基于DCGAN的AE-DCGAN网络。DCGAN对抗网络主要由生成器和判别器组成,利用生成器和判别器的对抗性,生成判别器难以分辨的假数据。本文提出的AE-DCGAN,基于DCGAN结合了自编码(AutoEncoder)网络的故障诊断特点,使用

预训练自编码网络作为生成器的手段,解决了对抗网络中因对抗不平衡导致难以达到纳什平衡的问题,使得网络的稳定性和真假数据的相似度得到提升。运用LeakyReLU代替ReLU,解决ReLU存在的神经元死亡问题,避免数据压缩时特征消失的情况,LeakyReLU公式如下:

$$f(x) = \begin{cases} x, & x > 0 \\ 0.01x, & \text{其他} \end{cases} \quad (3)$$

AE-DCGAN主要由生成器和判别器组成:

生成器网络结构为卷积自编码网络,相对于DCGAN对抗网络,预训练生成器的对抗性得到明显提高。下面是生成器的详细架构:

1)第一层为卷积层,含有32个大小为 3×3 的卷积核对特征矩阵进行降采样,卷积步长为 1×1 ,在输出前,用Batchnorm对数据进行归一化,并利用LeakyReLU激活该层。

2)第二层,第三层都是卷积层,第二层使用了64个卷积核,第三层使用了128个卷积核,并且两层都使用了最大值池化对数据进行了降采样,其他参数都与第一层类似。

3)第四层为反卷积层,由128个反卷积核组成,每个核大小为 3×3 ,步长为 1×1 。卷积层中去池化层,用反卷积层代替池化层的方法对数据进行上采样。

4)第五层,第六层都为反卷积层,分别使用64个和32个反卷积层组成,每层都使用Batchnorm对数据进行归一化,利于网络收敛。

5)最后一层为输出层,其输入为第三层的输出,使用LeakyReLU函数激活后输出反卷积的结果。生成器结构如图4所示。




图4 生成器网络结构

将原始数据和生成器自编码网络得到的假数据分别打标签后作为判别器的输入训练判别器网络,使得判别器的判别能力增强。同时,将假数据与真数据标签的损失用于更新生成器自编码网络的参数,使得生成器生成的假数据接近于真数据,与判别器网络形成对抗。下面为判别器的详细架构。

1)第一层为卷积层,输入通道为1,由16个 3×3 的卷积核组成,并加入池化层实现降采样,最后使用Relu激活函数激活该层。

2)第二层为卷积层,输入通道为16,由32个 3×3 的

卷积核组成,并加入池化层进行降采样,最后使用 Relu 激活该层。

3)第三层为卷积层,输入通道为 32,由 64 个 3 * 3 的卷积核组成,并加入池化层进行降采样,最后使用 Relu 激活该层。

4)第四层为全连接层,输入为特征矩阵拉平的一维数据,输出为 64 的特征向量。

5)最后一层为输出层,输入为 64 的一维数据,Sigmoid 函数为每个类别发生的可能性分配概率,使用二分类交叉熵计算器损失,图 5 为网络详细结构。




图 5 判别器网络结构

AE-DCGAN 网络的训练过程:

AE-DCGAN 中的生成器和判别器分别运用了卷积自编码网络和卷积神经网络,生成器的作用是前向传播将输入的超声波二维数据尺寸压缩,再将生成的编码矩阵经过反卷积后进行解码,得到与原始特征图一样大小的假数据,将生成的假数据与原始数据进行混合,在有监督的情况下,再次输入判别器,由此迭代循环输入。设在判别器分类下,假数据分配概率为 $P_{g(x)}$,原始数据分配概率为 $P_{data(x)}$,分类概率 $D(x)$ 的计算公式如式(4)所示。

$$D(x) = \frac{P_{data(x)}}{P_{data(x)} + P_{g(x)}} \quad (4)$$

在不断进行循环输入的过程中,当 $P_{g(x)} = P_{data(x)}$,并且原始数据和假数据的欧式距离在不断减少的情况下,网络目标达到最优值。生成器和判别器相互博弈之后的结果是判别器难以判断生成器生成的数据是否真实,判别器对数据的分类概率 $D(x) = 0.5$,即 $P_{g(x)} = P_{data(x)}$ 。

AE-DCGAN 网络的实现故障样本生成过程:

当 $D(x) = 0.5$ 时,真假数据的相似度达到合适阈值,网络参数达到理想状态,将缺失样本的原始数据输入 AE-DCGAN 网络,输出与原始样本大小维度一致的假数据,将假数据与原始数据混合,迭代输入网络,使缺失样本数目达到增加,从而样本类别数量达到均衡。

1.5 超声波信号的检测识别

Alexnet^[18]模型用于局部放电识别^[18]时,在使用两个 GPU 进行训练的情况下,可以作为变压器局部放电信号模式识别的神经网络模型,缺点是需要的算力环境较高,在移动端仪器上难以实现,根据 VGG 网络^[19]运用多个 3 * 3 卷积核扩大特征提取范围的思想,本文提出了一种减少卷

积层数,增加卷积核数目的局部放电模式识别网络,使其在保证模式识别的条件下减少网络参数,提高了时效性和准确性,其结构如下:

网络输入是超声波时频图经梅尔倒谱(MFCC)^[20]处理后 28 * 28 的特征矩阵。下面是网络结构:

1)第一层为输入层,输入通道为 1,28 * 28 的样本数据。

2)第二层为卷积层,输入通道为 1,由 16 个 3 * 3 的卷积核组成,并加入池化层实现降采样,最后使用 Leakyrelu 激活函数激活该层。

3)第三层为卷积层,输入通道为 16,由 32 个 3 * 3 的卷积核组成,并加入池化层进行降采样,最后使用 Leakyrelu 激活该层。

4)第四层为全连接层,输入为 32 * 7 * 7 的一维数据,输出为 64 的特征向量。

5)最后一层为输出层,输入为 64 的一维数据,使用 Softmax 函数为每个类别发生的可能性分配概率。局部放电模式识别网络的详细结构如图 6 所示。




图 6 局部放电模式识别网络结构

模式识别网络的训练测试流程如图 7 所示。

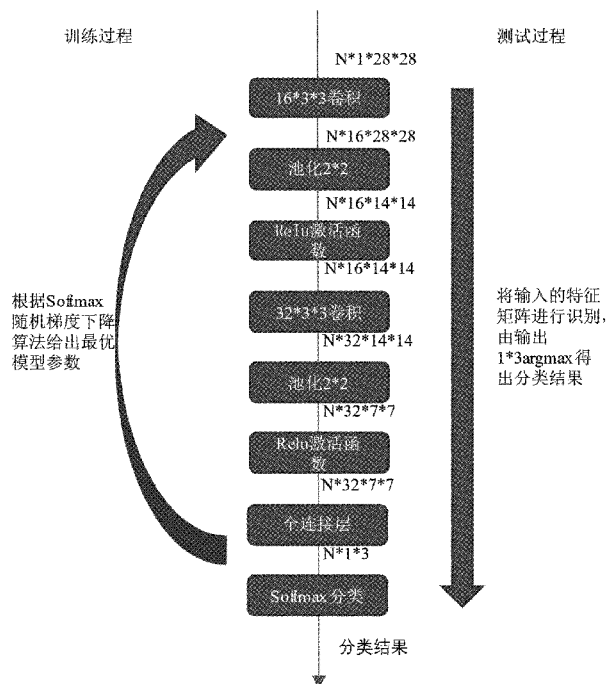


图 7 模式识别网络测试训练流程

2 实例实验结果与分析

实际场景中高压开关柜局部放电的中心频段在 40 kHz 左右,超声波采集设备采用 30GM 系列 128 kHz 采样率的超声波信号探头对高压开关柜设备缝隙进行三次非接触式超声波信号采集,采集地点为兰亭站变电站的高压开关柜,采集位置分别为高压开关柜的母线通风杠缝隙、断路器位置面板缝隙、高压电缆接头线位置缝隙、通风口。采集数据按照 1.2 节进行超声波信号的预处理,并按照帧长 100 ms,帧移 33 ms 对其进行分帧、加窗、短时傅里叶变换转化为时频谱图。训练样本中电晕、悬浮和表面的样本个数分别为 2 841、214、2 673。依照 1.3 节对其时域数据进行小波去噪。

$$SNR = 10 \lg \frac{P_{signal}}{P_{noise}} \quad (5)$$

式(5)中 SNR 信噪比是衡量信号质量的计量方式, P_{signal} 为信号本身的能量, P_{noise} 为噪音的能量,表 1 为 3 种放电的去噪前后 SNR 对比(取类别均值),表面放电去噪效果如图 8 所示。

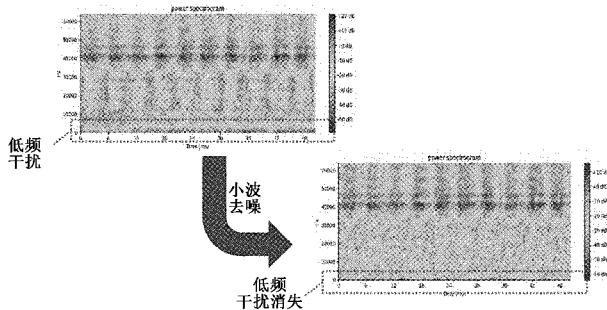


图 8 表面放电去噪效果图

表 1 小波去噪前后 SNR 对比 dB

放电类别	电晕	悬浮	表面
去噪前 SNR	37.5	49.1	51.8
去噪后 SNR	74.9	80.8	77.9

经过两次小波分解,并进行阈值量化重构后,信号的低频干扰消失,其 SNR 均提升了 30 dB 左右,去噪后 SNR 均大于 70 dB。采集过程中,悬浮放电样本在开关柜局部放电中出现的概率较低,多在第二次采集数据的断路器位置面板缝隙位置出现,样本数量远远小于其余两种放电类型,将去噪之后的悬浮放电的音频样本数据依照 1.4 节训练 AE-DCGAN 网络,经过 1 000 次迭代得出重构数据如图 9(以悬浮放电灰度图为例),图 10 为 AE-DCGAN 网络与 DC-GAN 网络训练对比图(每一百次训练显示一次分类器分类概率 $D(x)$)。

重构之后的悬浮放电数据的平均信噪比为 82 dB。图 10 为重构之后的灰度图,对比原始信号其信号边缘锐化良好,利于神经网络进行特征提取。由图 11 样本生成



图 9 数据重构效果图(悬浮放电)




图 10 对抗网络训练对比图

网络训练对比图可知,AE-DCGAN 网络在 500 次训练后达到平衡状态,分类概率 $D(x)$ 维持在 0.5 左右,而 DCGAN 网络在同样的判别器情况下在 900 次训练后达到平衡状态。分别输入悬浮放电测试数据对两种对抗网络的重构效果进行 MSE 测试,对比 DCGAN,AE-GAN 生成数据的数据的 MSE 均小 0.67,而 DCGAN 网络的 MSE 均大于 0.96,其重构效果不及 AE-DCGAN。故障样本重构后,其样本类别数量达到均衡,将采集的 4 个位置 3 次采集数据时频谱图经过梅尔倒谱(MFCC)转化为 28×28 特征图,划分训练集(0.7)和测试集(0.3)按照 1.5 节(模式识别网络的训练和测试)分别进行训练和测试。本文提出的局部放电模式识别网络和 Alexnet 模式识别网络的测试结果如表 1、2 所示。表 3 为 Alexnet、本文局部放电模型识别网络、MLP(多层感知机)的参数数量和综合检测效果对比(综合检测为类别数据混合检测,算力为 T710 测试机上进行一次运算所耗费的时间)。

表 2 局部放电模式识别网络测试结果 %

电晕放电	母线	高压电缆	断路器	通风口
第一次	95	96	98	95
第二次	95	96	79	96
第三次	96	82	93	96
悬浮放电	母线	高压电缆	断路器	通风口
第一次	100	100	100	99
第二次	99	98	100	99
第三次	99	99	100	100
表面放电	母线	高压电缆	断路器	通风口
第一次	93	100	91	100
第二次	91	99	99	99
第三次	99	99	100	99

表 3 Alexnet 模式识别网络测试结果 %

电晕放电	母线	高压电缆	断路器	通风口
第一次	98	100	92	100
第二次	100	97	98	98
第三次	100	78	85	97
悬浮放电	母线	高压电缆	断路器	通风口
第一次	96	94	44	79
第二次	92	86	72	85
第三次	61	82	93	92
表面放电	母线	高压电缆	断路器	通风口
第一次	99	96	33	92
第二次	98	99	93	98
第三次	75	70	98	100

表 4 网络参数综合测试结果对比

网络名称	Alexnet	局部放电模式识别网络	MLP
识别准确性	95.87%	97.93%	87.16%
模型参数量	3.2×10^6	4.5×10^5	7.7×10^6
算力	2.38 s	0.15 s	2.93 s

由表 1、2 可知,在训练 50 次之后,在 t710 测试环境下,本文提出的局部放电模式识别网络在断路器位置面板缝隙对悬浮放电的识别率优于 Alexnet 模式识别网络,对母线通风杠位置缝隙的识别率整体大于 Alexnet 模式识别网络。由表 3 可知,MLP 多层感知机因全连接层较多,网络的参数量均多于其余网络参数量,直接使用时域信号作为特征,导致识别率低于其余两种网络模型。综合测试下局部放电模式识别网络的时效性和准确率均优于 Alexnet,其时效性也远远高于 Alexnet 模式识别算法。

3 结 论

本文基于超声波检测法的方法,将一维的时域信号转化为时频谱图,增加了时间和频域两个维度能量特性,基于 VGG 卷积神经网络的思想,运用了较少的网络参数构建了一种模式识别率高、卷积核感受域广、并可集成在移动端的局部放电模式识别网络。此方法对比常规局部放电检测法具有模式识别的功能,获取的信息量大,其准确率、时效性均高于 Alexnet 模式识别网络和 MLP 神经网络。在实际场景的高压开关柜中,悬浮放电作为最难触发的放电模式其出现频率低于其他两种放电模式,由于深度学习神经网络要求训练数据均匀分布,才能达到良好的识别效果,本文提出了一种基于 DC-GAN 的 AE-DCGAN 对抗网络生成故障样本数据,解决了对抗网络中存在的难以达到纳什平衡的问题,增加了网络训练的时效性,解决了因样本不均匀导致的训练效果不佳的情况。

参考文献

- [1] 谢荣斌,杨超,中强,等. 暂态对地电压法与脉冲电流法测量开关柜局部放电的特性对比[J/OL]. 中国电力, 2021, 12(16):1-12.
- [2] 牛智强,凌旺,刘世俊,等. 三相高频脉冲电流法局部放电在线监测系统的应用[J]. 中国新通信, 2021, 23(15):105-106.
- [3] 陈君强,王鹏,黄寅,等. 变频电机绝缘局放电压自动测试系统设计[J]. 电子测量与仪器学报, 2019, 223(7):114-121.
- [4] HÜSEYİN I, HASSEN A, NABIL M, et al. Bcst proximity point results for geraghty type? -Proximal contractions with an application[J]. Axioms, 2019, 8(3):95-100.
- [5] 刘宏亮,丁斌,高树国,等. 基于宽频带脉冲电流法的变压器局部放电多端检测技术研究[J]. 高压电器, 2018, 54(11):233-238.
- [6] ZHANG D, LI CB, SHAHIDEHPOUR M, et al. A bi-level machine learning method for fault diagnosis of oil-immersed transformers with feature explainability[J]. International Journal of Electrical Power and Energy Systems, 2022, 134:55-61.
- [7] BANDI T, OHTSUKA S. Partial discharge detection of multiple-narrow band antenna under the radio communication noise [J]. IEEJ Transactions on Electrical and Electronic Engineering, 2021, 16(5): 412-420.
- [8] ABU S A. Application of logistic regression algorithm in the interpretation of dissolved gas analysis for power transformers[J]. Electronics, 2021, 10(10):314-319.
- [9] 程江洲,温静怡,鲍刚,等. 基于 T-MobileNet-L 模型的 GIS 局部放电模式识别研究[J]. 电子测量技术, 2021, 44(20):22-28.
- [10] 王卓,朱宁宁,郑祥. 基于 LDA 和 RBF 神经网络的开关柜局部放电模式识别方法研究[J]. 电子测量技术, 2021, 44(14):148-152.
- [11] 张承圣,邵振国,陈飞雄,等. 基于条件深度卷积生成对抗网络的新能源发电场景数据迁移方法[J/OL]. 电网技术, 2022, 1-10:1-11.
- [12] 李宝琴,吴俊勇,强子玥,等. 基于改进 DCGAN 的电力系统暂态稳定增强型自适应评估[J/OL]. 电力系统自动化, 2022, 1-10:1-13.
- [13] 欧莉莉. 基于半监督编码的深度卷积对抗网络模型研究及应用[D]. 青岛:青岛大学, 2021.
- [14] 余传本,刘增力. 一种改进的贝叶斯小波阈值图像去噪算法[J]. 电视技术, 2021, 45(10):106-111.
- [15] 石黄霞,李文亮,杨白洁. 小波分析和支持向量机的电力系统局部放电检测方法[J]. 自动化技术与应用,

- 2021, 40(6):6-9,14.
- [16] 付伟. 基于自适应阈值的高压电缆局部放电信号降噪研究[J]. 电子测量技术, 2020, 343(11):138-141.
- [17] 郑祥, 付大赓. 局部放电应答器中白噪声干扰抑制的滤波器设计[J]. 电子测量技术, 2020, 43(337):130-133.
- [18] 吕天成. 基于深度学习的变压器局部放电分析和诊断方法研究[D]. 保定:华北电力大学, 2019.
- [19] 张铠臻, 李艳武, 刘博, 等. 基于 VGG16 网络的超参数调整策略的研究[J]. 科技与创新, 2021(22):10-13.
- [20] 王学光, 诸珺文, 张爱新. 基于 MFCC 特征的声纹同

一性鉴定方法[J]. 计算机科学, 2021, 48(12):343-348.

作者简介

戴昕宇, 硕士研究生, 主要研究方向为局部放电检测与模式识别。

E-mail:1121826000@qq.com

徐焕宇(通信作者), 博士, 高级讲师, 主要研究方向为计算机视觉, 图像处理。

E-mail:xhydtc@hotmail.com

张宁, 硕士, 高级算法工程师, 主要研究方向为声学振动。

E-mail:a_zhangning@126.com