

DOI:10.19651/j.cnki.emt.2312649

基于卷积神经网络的局部放电声音识别研究*

汪志成¹ 王泽旺¹ 朱梦帆¹ 纪荣煥² 张斌¹

(1. 东华理工大学 南昌 330013; 2. 泉州维盾电气有限公司 泉州 362012)

摘要: 针对变压器与中压开关柜传统绝缘状态检测方法依赖人工的问题,本文基于可听声声音识别方法,通过将电力设备放电故障声音与正常工况声音、环境噪声进行混叠制作样本集,以模拟真实电力设备运行环境;对故障声音进行预处理后,使用声谱图提取声音的短时频率、能量分布等特征,构建声谱图数据集,结合改进的卷积神经网络实现对放电故障的检测;通过加入注意力机制,调节指数衰减学习率、数据集样本数量、音频采样率等方式进一步提升网络的精度,最终设计的网络模型识别准确率最高可达99.2%,相比其他检测方法优势明显,可实现对放电故障的在线检测。

关键词: 电力设备;局部放电;声谱图;声音识别;卷积神经网络

中图分类号: TP274+.5;TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Study on sound recognition of partial discharge based on convolutional neural network

Wang Zhicheng¹ Wang Zewang¹ Zhu Mengfan¹ Ji Ronghuan² Zhang Bin¹

(1. East China University of Technology, Nanchang 330013, China;

2. Quanzhou Weidun Electric Co., Ltd., Quanzhou 362012, China)

Abstract: In view of the problem that the traditional insulation state detection methods of transformers and medium-voltage switchgear rely on manual labor, this paper based on the audible sound recognition method, by mixing the discharge fault sound of power equipment with the sound of normal conditions and environmental noise to make a sample set, in order to simulate the real operating environment of power equipment. After the fault sound is preprocessed, the spectrogram is used to extract the short-time frequency and energy distribution features of the sound, and the spectrogram data set is constructed. Combined with the improved convolutional neural network, the discharge fault detection is realized. By adding the attention mechanism, adjusting the exponential decay learning rate, the number of data set samples, the audio sampling rate and other ways to further improve the accuracy of the network model, the final design of the network model identification accuracy up to 99.2%, compared with other detection methods have obvious advantages, can realize the online detection of discharge faults.

Keywords: electric power equipment; partial discharge; spectrogram of sound; voice recognition; convolutional neural network

0 引言

电力设备内部故障主要包括放电故障、过热故障、潮湿故障等。研究表明,85%以上的电网事故是由放电故障造成的,部分过热、潮湿故障也会引发放电故障^[1]。对电力设备局部放电的实时监测与故障类型的精准识别可以改变目前依靠人工定期巡检的现状,提高运维智能化水平。针对这一问题,国内外研究工作者先后提出了脉冲电流(pulsating

current,PC)检测法、暂态地电压(transient earth voltages,TEV)检测法、特高频(ultra high frequency,UHF)检测法、超声波检测法、可听声检测法等^[2],推动了该领域的技术发展。如刘宏亮等^[3]构造变压器局部放电缺陷模型系统,通过高频脉冲电流传感器测量不同放电故障脉冲电流信号。甘德刚等^[4]结合PC与UHF检测法,可有效避免现场环境的电磁干扰,实现对局部放电信号的检测识别。时广华^[5]通过

收稿日期:2023-01-16

* 基金项目:江西省科技合作专项重点项目(20212BDH80008)、科技部常规性科技援外项目(KY201702002)、江西省重点研发计划项目(20181BBE58006)、国家自然科学基金(12165001)项目资助

TEV 检测法设计缺陷模型,实现对中压开关柜内部绝缘状态的云端在线监测。Zhang 等^[6]通过卷积神经网络(convolutional neural networks, CNN),实现对不同放电故障类型超高频信号图谱的分类识别。Al 等^[7]通过粒子群优化与神经网络算法实现对局部放电声音信号的检测识别。符劲松^[8]通过实验模拟并采集变压器局部放电声音,建立火花放电声音模型,为后续声音识别提供理论依据。孙汉文等^[9]使用梅尔频率倒谱系数方法对合成的变压器放电声音提取声谱图,比较支持向量机(support vector machine, SVM)、朴素贝叶斯(naive Bayes, NB)、随机森林(random forests, RF)等多种机器学习算法的识别能力,实验结果表明 SVM 对放电故障类型的识别准确率最高。

综上所述,可听声检测法具有安全、非接触式、可实时监测等优势,表现出了较好的应用前景。但大部分研究对电力设备的具体工作环境噪声、放电声音特征等考虑不足,搭建的局部放电故障模型与实际工况契合度低,导致系统

识别效果差。针对以上问题,本文提出了一种基于 CNN 的局部放电声音识别方法。建立更加真实、全面的放电故障模型,并将电力设备正常工况声、放电故障声混叠各类环境噪声来逼近实际应用工况,建立样本库,构建卷积神经网络算法进行电力设备放电故障类型识别,分析数据集样本数量、采样频率等对识别效果的影响。

1 电力设备放电故障声音采集与预处理

1.1 放电故障声音采集

1) 实验平台搭建

当电力设备正常运行时,变压器会因叠片漏磁铁芯震动、油箱壁震动、变压器冷却风机等原因产生低频工作噪声,而中压开关柜工况声音微弱,噪声较小^[10]。当发生局部放电故障时,由于放电故障的类型与位置不同,产生的放电声音也不同。下面是变压器与中压开关柜的常见放电故障类型与位置总结^[11],如表 1 所示。

表 1 常见放电类型与对应设备故障位置

放电故障类型	故障位置
尖端放电	变压器的绕组毛刺、铁芯表面尖端处;开关柜的电缆接头针板,柜体表面尖端处(因制作工艺不佳产生)
气隙放电	油变油箱表面、干变绕组匝间绝缘气隙处;开关柜的电流互感器内部、绝缘子气隙(受热收缩所致)、套管内部等位置
沿面放电	变压器的固液(绝缘油)接触面处;开关柜断路器绝缘面、绝缘套管端部
悬浮微粒放电	变压器紧固件漆膜、油中金属微粒处;开关柜制造安装中散落金属微粒处

各类变压器与中压开关柜金属导体组成部分及绝缘介质材料相近,故发生局部放电故障时,不同种类设备在同种能级强度放电故障下产生的可听声声音也相近^[12]。因此,根据国际电工委员会(IEC)要求及关于绝缘材料电气强度实验方法标准 GB/T1048,本文设计了 4 种放电故障模型来模拟电力设备真实绝缘缺陷故障^[13],如图 1 所示。





图 1 电力设备的 4 种放电故障模型

4 种放电故障模型中,尖端放电模型可以模拟局部放电、火花放电、电弧放电 3 种不同能级放电故障,其余 3 种模型只能模拟局部放电故障^[14]。为使缺陷模型放电声音与电力设备实际放电声音相近,本文采用尖端电极—紫铜板—接地端、柱电极—环氧板—紫铜板—接地端、球柱电极—3 层环氧板(中间环氧板中央开孔)—紫铜板—接地端、柱电极—环氧板(金属微粒放置在环氧板上)—紫铜

板—接地端 4 种放电故障模型。

实验在江西省中低压输变电产品质量监督检验中心进行,所模拟的局部放电故障与各类变压器与中压开关柜实际故障保持一致。实验现场如图 2 所示,设备选用 10 kVA 的变压器与调压台输出可控交流高电压。本文对采集的声音质量要求较高,当采样频率高于原始音频最高频率的两倍时,才能将存储的数字信号高保真的还原为原始信号,采样频率越高,声音信号波形恢复的越准确。局部放电声音频率主要集中在 10 kHz 的高频段,因此音频采集装置选用最大采样频率为 48 000 Hz、频率响应范围为 50~20 kHz 的联想 B570 型号录音笔,保证了放电声音信号的精确度。另外,还选用 0~30 kV 直流高压电源给模型施加高压,录制放电音频,扩充实验数据。实验电路图如图 3 所示。



(a) 交流高电压实验现场

(b) 直流高电压实验现场

图 2 实验现场




图 3 实验电路图

2) 放电故障声音采集

具体实验步骤如下：

(1) 按照设计电路图连接变压器、调压台、保护电阻及放电故障模型，模型的高压端与低压端间隙距离控制为 2 mm。

(2) 将录音笔放置在距离模型 3 cm 远的支撑架上，保持在固定位置定点采集放电声音。

(3) 实验人员与实验装置保持一定的安全距离，使用调压台及高压电源对 4 种放电故障模型加压，当模型产生微弱可听放电声音时，记录电压值，停止加压，通过录音笔录制局部放电音频数据，4 种模型的录制时间均为 180 s。

(4) 对于尖端放电模型，在录制局部放电声音之后，继续升压至火花放电状态，此时示波器或高压电源有电流值显示，模型发出“劈啪”的放电声音，可观察到明显火花爆裂现象，停止加压，记录电压值。为保证电源及模型寿命，录制时间缩短为 60 s；继续升压至电弧放电状态，此时模型

发出明亮的电弧放电现象，记录击穿电压，录制时间同样为 60 s。

(5) 重复尖端模型放电实验两次，录制火花放电声音与电弧放电声音，每次录制时间为 60 s，使这两种声音的录制时长与四种局部放电的时长一致，均为 180 s。

(6) 控制不同的放电间距 (4 mm、6 mm)，重复步骤(1)~(5)。累计采集尖端局部放电、尖端火花放电、尖端电弧放电、沿面放电、气隙放电、悬浮放电 6 种放电故障类型声音各 540 s，共计 3 240 s。

(7) 断开电路，关闭录音装置，实验结束。

3) 电力设备正常工况声音采集

在对模拟放电声音采集的同时，为研究电力设备正常工况声音与放电故障声音区别，本文也采集了部分箱式变电站、电力变压器、开关柜的正常工况声音，录音笔的采集距离与模拟放电故障声音采集实验保持一致。每台设备录制时长 720 s，经剪辑后共获取电力设备正常工况声音有效时长 3 860 s。

1.2 声音预处理

1) 音频混叠

为使故障模型放电声音更加接近电力设备实际放电故障声音，采集部分箱式变电站、电力变压器以及不同开关柜的正常工况声音与模拟实验的放电故障声音进行混叠，混叠类型一时长表如表 2 所示。为进一步模拟电力设备真实工作环境，将电力设备正常工况声音及混叠后的 6 种放电故障声音添加变电站环境噪声、居民小区环境噪声，形成音频资源库，音频库类型一时长如表 3 所示。

表 2 混叠类型-时长表

s

混叠类型	尖端局部放电	尖端火花放电	尖端电弧放电	沿面放电	气隙放电	悬浮放电	合计
时长	540	540	540	540	540	540	3 240

表 3 音频库类型-时长表

s

音频类型	具体操作	时长	合计
正常工况声音	正常工况+变电站环境噪声	270	540
	正常工况+居民小区环境噪声	270	
6 种类型放电声音	放电声音+变电站环境噪声	1 620	3 240
	放电声音+居民小区环境噪声	1 620	

2) 滤波去噪

在放电声音采集过程中，由于高压电源采用过高的电压等级、设备震动、音频采集装置与周围设备距离较近等原因，使得采集的放电声音中掺杂有大量工频噪声。放电声音相比于工频噪声频率高出许多，因此需要采用高通滤波器进行滤波去噪。本文通过 Python 中的 librosa 声音信号处理库，对放电原始音频进行去噪处理，结果如图 4 所示。工频噪声经音频高通滤波器降噪后，明显过滤掉了原始信号中掺杂的具有较高幅值与较低密度的正弦波信号，

有效削弱了工频噪声，提高了音频质量。

2 声谱图特征提取与样本库构建

2.1 声谱图

声谱图将声音波形转换成三维的图像特征，从时间、频率、能量密度 3 个维度来描述声音信息，综合时域波形和频谱图的特点，保留了大量更为完整的声音信号特征。放电声音提取声谱图过程如图 5 所示。放电声音信号经分帧加窗后，进行傅里叶变换得到频率-幅值图，将频




图 4 工频噪声滤波前后时域图对比

率—幅值图逆时针旋转 90° 后映射到 $0 \sim 255$ 像素点的灰度值,生成声谱图。其中, x 轴为时间, y 轴为频率分布值,使用每个像素点灰度值来表示该点处的声音数据能量。




图 5 放电声音提取声谱图特征示意图

2.2 样本库构建

电力设备放电故障声音能量主要集中在 10 kHz 左右,故本文声谱图频率范围选取 $0 \sim 25 \text{ kHz}$,刻度标尺帧时长选取

25 ms ,将灰度图映射为 RGB 三通道的彩色声谱图,提取更加完整的声音频率与能量密度等特征信息。电力设备正常工作、局部放电、火花放电、电弧放电声谱图如图 6 所示。




图 6 电力设备声谱图

采用声谱图批量生成算法,将采集的声波序列快速转换成声谱图图像,构建声谱图样本库。不同类型的声谱图图像及其数量如表 4 所示。声谱图数量共计 $11\ 000$ 张,选取 70% 声谱图作为训练集, 30% 声谱图作为测试集。

表 4 声谱图类型-数量表

图像类别	正常工况	尖端放电	沿面放电	气隙放电	悬浮放电	火花放电	电弧放电
图像数量	2 000	1 500	1 500	1 500	1 500	1 500	1 500

3 基于放电声音识别的卷积神经网络优化

3.1 卷积神经网络选取

为尽可能的减少神经网络模型的训练时间,本文构建改进的 CNN^[15-18],在保留神经网络核心模块的基础上简化模型,提升模型的训练、识别速度,缓解模型退化的问题,同时更多的使用最大池化,从而提取更多的声音能量与频率分布信息,减少背景特征的干扰,突出声谱图纹理、斑块特征。分别采用 VGG16、Inception10、ResNet18 三种 CNN 实现对电力设备放电故障的检测识别,并对比分析 3 种网络的识别效果。

将声谱图批量送入 CNN。设定 epoch = 100,网络每完成一个 epoch 的训练则对所有测试集进行检测识别,并记录识别精度^[19]。VGG16、Inception10、ResNet18 三种 CNN 在 epoch = [0, 25), [25, 50), [50, 75), [75, 100] 4 个区间声谱图测试集的平均识别准确率^[15-16],如图 7 所示。改进的 ResNet18 卷积神经网络在经过 50 个 epoch 后,平均识别准确率优于 VGG16 和 Inception10,经过 100 个 epoch 后在测试集上平均识别率达 97.17%,更适用于电力设备放电故障声音识别。

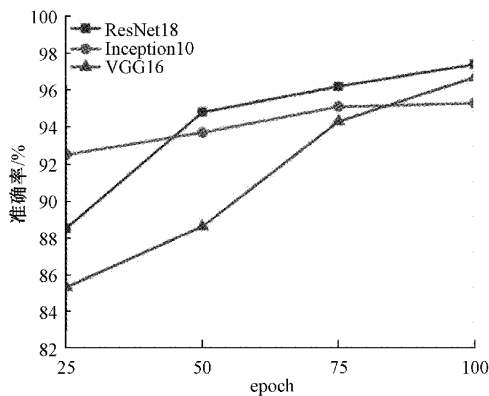


图 7 三种卷积神经网络模型识别准确率对比

3.2 引入卷积注意力机制模块

在 CNN 中插入注意力机制结构块 (convolutional block attention module, CBAM)^[20],可以提高算法对声谱图中高能量斑块及不同放电故障类型独有的短时频谱特征的关注度,弱化环境干扰噪声及电力设备正常工况的低频工作噪声,提高放电故障声音总体识别能力。CBAM 插入位置如图 8 所示,以 ResNet18 为例,CBAM 具体插至网络分类器的前端,即 ResNet18 结构块末端,形成优化后的网络结构。

CBAM 作用示意图如图 9 所示。当 CBAM 插入 CNN

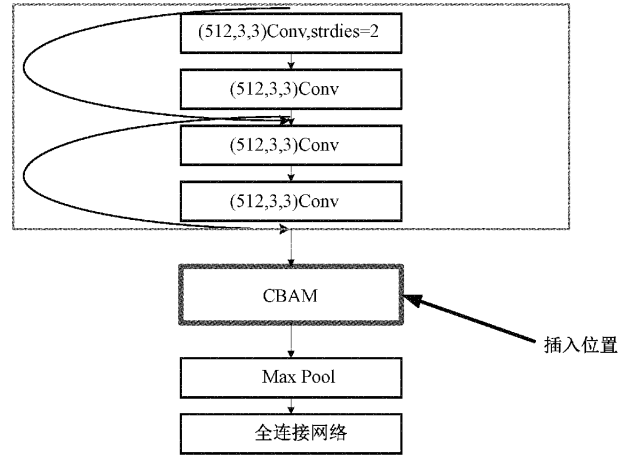


图 8 CBAM 具体插入位置

后,CBAM 会在声谱图的通道方向及二维空间方向分别赋予权重,促使神经网络快速学习声谱图关键通道及空间位置对模型识别能力的重要性,进而提高识别精度^[21-22]。




图 9 CBAM 作用示意图

3.3 调节学习率

学习率设定过小会导致损失函数的变化速度减慢,模型的收敛复杂度增加,网络的收敛时间延长;反之学习率设定过大,易引起梯度爆炸,网络难以收敛,损失函数可能直接忽略全局最优点,难以提高识别准确率。本文采用指数衰减学习率,先选取较大的学习率 $lr = 0.01$,以模型对测试集的识别率作为评估标准,每经过 3 个 epoch 的测试,若识别率没有得到提升,则自动通过指数衰减降低损失函数值,进而提高识别精度^[23]。指数衰减学习率公式如式(1)所示。

$$lr = lr_0 \cdot d^{\frac{e}{3}} \quad (1)$$

式中: lr_0 为初始学习率, d 为衰减因子,设定为 0.5, e 为

当前 epoch 数,学习率最低设定为 1×10^{-5} 。

3.4 模型优化结果

通过引入 CBAM 及设定指数衰减学习率,对 VGG16、Inception10、ResNet18 三种改进的 CNN 进行消融实验,重新训练 100 个 epoch,识别准确率对比如图 10 所示。由图可知,同时采用 CBAM 与指数衰减学习率,网络识别性能最佳,且引入 CBAM 相比采用指数衰减学习率,准确率提升更大。经优化后 ResNet18 在测试集上识别准确率最高,为 99.2%,优于 VGG16 的 95.15% 与 Inception10 的 96.57%,其中 ResNet18 模型识别准确率与损失函数值变化如图 11 所示。

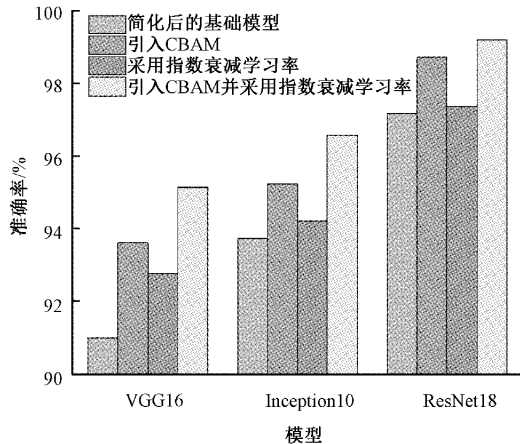


图 10 经优化后的模型识别准确率对比




图 11 优化后的 ResNet18 网络识别准确率与损失函数变化

4 检测方法对比与影响因素分析

4.1 不同检测方法横向对比验证

当局部放电发生时,会产生正负粒子的中和,此时电介质中会出现电流脉冲,PC 检测法将这种脉冲电流经信号处理后用于诊断局部放电故障;TEV 检测法是根据电磁波的集肤效应以及利用开关柜设备表面不连续的特征,测量开关柜内部发生放电时在设备外表面形成的对地暂态脉冲电压;UHF 检测法是在特高频段(300~3 000 MHz)检测局部放电位置产生的电流脉冲所激发的电磁波信号来诊断设备绝缘缺陷。本文基于自主设计的 4 种放电故

障模型,通过安装电流传感器、TEV 传感器与 UHF 传感器进行 50 次局部放电检测实验,与本文方法进行对比,结果如表 5 所示。

表 5 不同检测方法的识别精度

检测方法	PC	TEV	UHF	可听声
识别精度/%	92	86	78	100

由表 5 可见,本文基于可听声音识别方法,在 50 次实验中对正常工况以及 6 种放电故障类型全部识别正确,准确率达到 100%,其次为 PC 检测法,为 92%,UHF 检测法最低,为 78%。相比其他检测方法,本文方法优势明显,在满足识别精度的同时,可实现对放电故障的在线检测。

4.2 其他影响因素分析

1) 数据集样本数量

CNN 是基于数据驱动的,通常训练集过少会使模型过拟合,进而影响模型的识别率。本文声谱图数据集是通过模拟放电故障实验及声音预处理获得,声音数据收集复杂,所以通过控制不同数量的声谱图来分析模型对于数据集样本数量的依赖程度。将训练样本数量分别控制为总数据集的 10%、20%、...、100%,对应不同样本百分比重新对 ResNet18 进行 100 个 epoch 的训练,每完成一个 epoch 的训练则对测试集展开一次识别,记录测试集在 100 次识别任务中的平均识别准确率^[15-16],结果如图 12 所示。当声谱图训练样本数量达到总数据集的 70% 时,识别率趋于稳定。实验结果表明训练集达到 5 390 张时本模型具有良好的识别能力。




图 12 不同样本百分比的识别准确率

2) 采样频率

本文通过录制电力设备放电故障音频,将其送入模型来识别故障状态。分别将录制的音频数据采样频率设为 11 025、22 050、44 100 Hz,生成声谱图,送入模型分析采样频率对识别精度的影响,实验结果如表 6 所示。模型的识别精度在 11 025、22 050、44 100、48 000 Hz 4 种采样频率中没有明显变化。实验结果表明采样频率在 11 025~48 000 Hz 范围内变动时不会影响模型的识别能力。

表 6 音频采样频率对识别精度的影响

采样频率/Hz	11 025	22 050	44 100	48 000
识别精度/%	98.3	98.1	99.2	98.7

5 系统设计与部署

为了使 ResNet18 网络模型更好的调用,设计了电力设备放电故障识别系统。打开系统选择一段录制的时长为 1 分钟的音频(有持续 5 秒的悬浮放电声音),测试系统效果。系统识别结果如图 13 所示。封装的网络模型可以成功检测出音频是否发生放电故障及具体的放电故障类型。

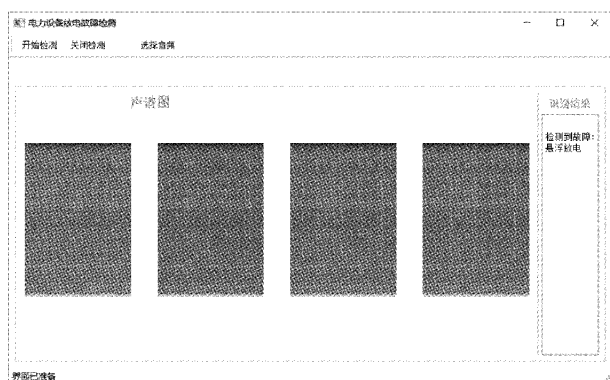


图 13 识别系统界面

Jetson Nano 是英伟达公司推出的先进嵌入式边缘计算平台。本文使用 Jetson Nano 进行嵌入式平台初步部署,如图 14 可见,可以在开关柜内部、变压器附近等电力设备处放置录音—传输模块,定时、定期采集电力设备声音信号,经 Zigbee 网络或 5G 网络与 Jetson Nano 实时交互数据,Jetson Nano 将音频数据预处理后批量生成声谱图,输入至 CNN 模型中判断设备有无发生放电故障。通过不断采集实际局部放电声音进一步扩充样本库,提高模型在复杂场景下的泛化能力。

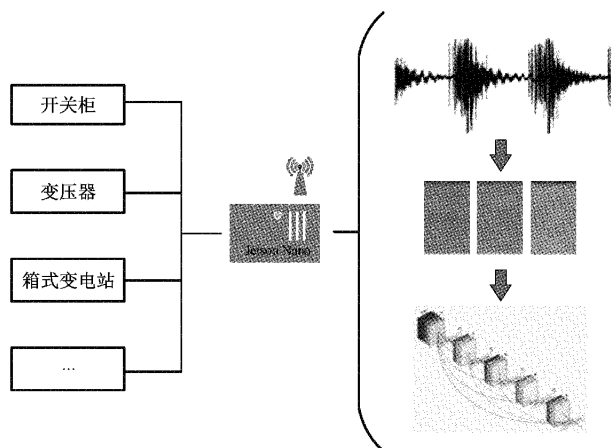


图 14 边缘计算方案

6 结 论

局部放电检测对电力系统的安全稳定运行起重要作用。本文在总结变压器、中压开关柜常见放电故障类型基础上,设计绝缘缺陷模型模拟放电故障声音,采集电力设备正常工况音频以及各种环境噪声与放电故障声音进行混叠预处理,之后使用声谱图特征提取方式构建样本库,分析改进的 VGG16、Inception10、ResNet18 三种 CNN 对电力设备放电故障声音的识别能力。实验结果表明 ResNet18 识别能力最强;通过引入 CBAM、调节学习率进一步提升模型的识别精度,经优化后 ResNet18 在自建声谱图数据集上的识别准确率最高可达 99.2%,相比其他检测方法,可以更为准确的判断是否发生放电故障以及具体故障类型;数据集样本数量对识别效果影响较大,声音采样频率在 11 025~48 000 Hz 范围内变化对识别效果影响较小。为进一步检验模型的识别效果,本文将模型部署到在网运行的变压器、中压开关柜,获取更多的声音数据,进一步提高模型在复杂场景下的泛化能力。

参考文献

- [1] 章政. 基于遗传编程的电力变压器绝缘故障诊断模型研究[D]. 上海:上海交通大学, 2007.
- [2] 高玉东. 基于深度学习的开关柜放电声音识别的研究[D]. 沈阳:沈阳工业大学, 2019.
- [3] 刘宏亮, 斌丁, 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, 244.
- [4] 甘德刚, 刘凡, 肖伟. 融合超高频及脉冲电流法的局部放电监测系统[J]. 电力自动化设备, 2013, 33(3): 162-165, 170.
- [5] 时广华. 开关柜局部放电带电检测与故障模式识别[D]. 南昌:东华理工大学, 2018.
- [6] ZHANG C, WANG G, GAO D, et al. A convolutional neural network-based UHF partial discharge atlas classification system for GIS [C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1802(3): 1-7.
- [7] AL G, PIAH M, BASHIR N. A review on hybrid wavelet regrouping particle swarm optimization neural networks for characterization of partial discharge acoustic signals [J]. Renewable and Sustainable Energy Reviews, 2015, 45: 20-35.
- [8] 符劲松. 基于可听声的变压器内部火花放电故障诊断研究[D]. 武汉:华中科技大学, 2013.
- [9] 孙汉文, 喆李, 盛戈峰, 等. 基于机器学习与卷积神经网络的放电声音识别研究[J]. 高压电器, 2020, 56(9): 107-113.
- [10] 陶诗洋, 冯义, 张天辰, 等. 基于脉冲电流法的高压

- 开关柜局部放电在线监测装置[J]. 电力系统保护与控制, 2019, 47(9): 145-149.
- [11] 孙抗, 郭景蝶, 马星河. 高压电缆局部放电小波包-峰值法在线检测与定位[J]. 电子测量与仪器学报, 2017, 31(7): 1099-1106.
- [12] 陈子正, 行鸿彦, 王瑞, 等. 一种铁路隧道衬砌掉块声音检测方法[J]. 电子测量与仪器学报, 2022, 36(1): 134-140.
- [13] 朱霄珣, 林佳伟, 刘宝平, 等. 基于 Iradon-CNN 的变压器局部放电状态识别方法[J]. 电子测量技术, 2022, 45(17): 36-42.
- [14] 刘宝升, 王涤, 马爱军, 等. 封闭环境空气局部放电组分研究[J]. 电力系统保护与控制, 2021, 49(9): 21-28.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778. doi: 10.1109/CVPR.2016.90.
- [16] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [17] 毛向向, 王红军, 韩凤霞, 等. 基于深度卷积神经网络的机电系统故障分类识别方法[J]. 电子测量与仪器学报, 2021, 35(2): 87-93.
- [18] 杨威, 蒲彩霞, 杨坤, 等. 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法[J]. 电力系统保护与控制, 2022, 50(6): 107-116.
- [19] RASHMI, UDAYAN G, MANUSHREE G. Comparative design analysis of optimized learning rate for convolutional neural network[J]. Lecture Notes on Data Engineering and Communications Technologies, 2021: 339-352, DOI: 10.1007/978-981-33-4582-9_26.
- [20] 于洋, 马军, 王晓东, 等. 融合深度可分离小卷积核和 CBAM 的改进 CNN 故障诊断模型[J]. 电子测量技术, 2022, 45(6): 171-178.
- [21] 金汉均, 曾星. 基于注意力机制的深度哈希图像检索方法[J]. 电子测量技术, 2021, 44(3): 144-148.
- [22] WOO S, PARK J, LEE J, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19, DOI:10.1007/978-3-030-01234-2_1.
- [23] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8): 2011-2023.

作者简介

汪志成, 博士, 副教授, 主要研究方向为新能源技术与应用。

E-mail: 277732648@qq.com

王泽旺(通信作者), 硕士研究生, 主要研究方向为电路与系统。

E-mail: 67077387@qq.com

朱梦帆, 硕士研究生, 主要研究方向为机械电子工程。

E-mail: 492128891@qq.com

纪荣焕, 中级工程师, 主要研究方向为嵌入式系统。

E-mail: jrh200310@163.com

张斌, 博士, 讲师, 主要研究方向为电子信息、新能源、核技术应用。

E-mail: 170243261@qq.com