

基于卷积网络的 GIS 局部放电缺陷诊断方法与应用

张聪聪¹, 王刚¹, 高栋¹, 殷伟¹, 王凯¹, 路铭¹, 刘英男², 李亚锦²

(1. 国网山东省电力公司东营供电公司, 山东 东营 257091;

2. 山东大学电气工程学院, 山东 济南 250061)

摘要:局部放电检测信号是判断 GIS 设备是否存在绝缘缺陷的重要判据,变电站复杂电磁信号干扰增加了现场局部放电模式的识别难度,易造成误报。因此提出了一种基于卷积网络的 GIS 局部放电缺陷诊断方法,将干扰下的检测图谱作为模型识别中的一种输出类型,研究基于 VGG-16 结构卷积神经网络的局部放电模式识别算法,利用迁移学习对模型参数进行初始化,从构建的变电站 GIS 设备特高频检测图谱库中抽取样本作为训练集和测试集,通过模型训练得到识别模型。为辅助现场运维,设计基于两层架构的 GIS 局部放电缺陷诊断和运维系统以及实现流程,应用到某市供电公司 GIS 运维中,结果表明,GIS 局部放电缺陷诊断及系统可有效识别出特高频检测图谱中的缺陷类型和干扰,为现场运维决策提供依据,提升现场运维检修效率。

关键词:气体绝缘组合电器;两层知识架构;干扰识别;局部放电诊断;模式识别

DOI: 10.12067/ATEEE2011038

文章编号: 1003-3076(2021)03-0072-09

中图分类号: TM855

1 引言

气体绝缘组合电器(Gas Insulated Switchgear, GIS)是一种以 SF₆ 气体为绝缘介质的电网关键设备。为减少组合电器绝缘故障发生概率,局部放电检测技术得到广泛应用^[1]。随着 GIS 在电网中的占比不断增加和组合电器局部放电检测工作的开展,电网现场积累了一定的检测图谱和运维数据,同时组合电器现场运维工作对智能辅助决策水平提出了更高要求。如何有效分析和应用这些数据,进一步提高组合电器设备绝缘风险判别的准确性和运维决策效率,是当前需解决的问题。

目前国内外学者针对 GIS 局部放电检测数据的缺陷分类识别做了一定研究^[1],提出了局部放电相位分布模式(Phase Resolved Partial Discharge, PRPD)、脉冲序列分布(Phase Resolved Pulse Sequence, PRPS)等模式下特征参数的提取和分类方法,如文献[2]通过不同缺陷类型放电时 SF₆ 气体分解组分特点,构建识别模型。文献[3]通过不同放电类型的信号建立自回归模型。上述研究主要针

对局部放电结构化特征进行提取和识别,难以直接应用到特高频图谱的分类识别中。针对非结构化数据的识别,文献[4]总结了 GIS 局部放电典型图谱,文献[5]提出模糊 Petri 网的 GIS 故障建模及推理方法,文献[6,7]将深度学习方法应用到局部放电模式识别中,构建了深层卷积网络模型,提取局部放电大数据的深层特征以提高复杂数据源下的识别正确率。上述方法针对非结构化图谱的分析做了尝试,但由于不同厂家、型号的检测仪器性能有所差别,导致局部放电检测分析的 PRPD 和 PRPS 图谱数据结构不一致,直接采用深度神经网络进行拟合训练,算法准确性和适应性难以满足实际需求。

局部放电检测信号是判断 GIS 设备是否存在绝缘缺陷的重要判据,但由于带电检测工作相对复杂,现场环境干扰因素较多,变电站内高压套管电晕放电等会在 GIS 室内产生特高频干扰信号。在知识储备不足的情况下,会造成特高频检测结果的误判。检测结果的可靠性很大程度取决于检测人员的业务水平,严重制约了组合电器设备缺陷诊断准确性的提升。

收稿日期: 2020-11-26

基金项目: 国网山东省电力公司科技项目(2018A-108)

作者简介: 张聪聪(1989-),男,山东籍,工程师,研究方向为变电设备检修;

刘英男(1987-),男,内蒙古籍,助理研究员,硕士,研究方向为变电站在线监测及智能运维(通讯作者)。

在上述分析基础上,针对组合电器图谱识别准确率提升问题,本文提出一种基于卷积网络的 GIS 局部放电缺陷诊断方法,首先利用 GIS 局部放电检测图谱和运维检修记录,对图谱和缺陷类型进行分类,将干扰下的检测图谱作为模型识别中的一种输出类型,构建不同检测终端的典型故障图谱知识库。研究基于 VGG-16 结构卷积神经网络的局部放电模式识别算法,利用迁移学习的方式,通过 VGG-16 网络模型参数优化卷积层、池化层和全连接层的模型参数,解决特高频检测图谱的分类与局部放电识别准确率问题。通过增强现实技术将诊断结果和缺陷原因增强显示在现场移动终端上,辅助现场诊断缺陷,从而提升现场运维检修效率。

2 特高频局部放电图谱库建模及缺陷原因分类

某市电力公司合计 306 座(含市局 142 座,县局 164 座)110 kV 及以上 GIS 变电站,通过搜集该电力公司近 8 年运维和检修数据,获取实际运行环境下变电站组合电器的检测图谱,包括尖端放电、绝缘件气隙放电、沿面放电、悬浮放电、自由金属颗粒以及干扰六种类型。现场检测时利用局部放电巡检仪和示波器,在变电站进行特高频局部放电信号的 PRPD 和 PRPS 图谱采集。

现场发现的局部放电缺陷经进一步停电试验并解体得到验证,确认缺陷类型。现场检测信号采集测点选取 GIS 上的盆式绝缘子进行测量。为增加干扰数据源,在 GIS 周围,通过现场测试获取干扰图谱,采用示波器抓取干扰波形,人工标记干扰信号来源,采用局部放电巡检仪获取 PRPD 和 PRPS 图谱,变电站现场检测中主要仪器型号及关键参数如表 1 所示。共搜集现场检测图谱 500 张,形成检测信号图谱库,包括尖端放电 120 张、绝缘件内部气隙放电 80 张、沿面放电 20 张、悬浮放电 80 张、自由金属颗粒 75 张以及干扰图谱 125 张,用于局部放电模式的训练与测试。典型缺陷检测图谱如图 1 所示,尖端放电呈单簇明显特征,绝缘件内部气隙放电特征为两簇相当,沿面放电呈一大一小特征,悬浮放电呈内外八字特征,自由金属颗粒放电无明显极性特征。

现场测试发现,在变电站普遍存在三类干扰信号,分别为手机干扰、室内风机干扰和电子围栏干扰,图 2 所示为部分典型干扰的 PRPS 和 PRPD 检测图谱。

表 1 变电站现场检测主要仪器型号及关键参数

Tab.1 Main testing instrument type and key parameters

设备类型	型号	主要参数
局部放电信号分析定位检测仪	EC4000Plus	采样频率:20 GHz,模拟带宽 2 GHz
便携式局部放电检测仪	EC4000	信号采样频率 100 MHz,动态范围-80~8 dBm。
示波器	DSO-X3104	4 通道 1 GHz 带宽,最高达 5 GS/s 采样率

根据获取的局部放电带电检测图谱数据,对样本信息进行标注,结合运维检修数据,建立图谱信息库,特征量包括设备名称、设备类型、设备厂家、运行年限、缺陷部位、缺陷严重程度、检测图谱对应 ID、缺陷类型、缺陷原因和处理建议,其中检测图谱包括脉冲相位图(PRPD)和脉序相位图(PRPS)图谱。

根据带电检测技术导则^[8]将带注释的图谱集分为 6 类,包含尖端放电、绝缘件内部气隙放电、沿面放电、悬浮放电、自由金属颗粒以及干扰。信息模型中的特征量定义为组合电器局部放电缺陷诊断知识的结构化表达,结合运维历史记录,形成知识库,明确不同缺陷类型对应的缺陷原因、不同故障类型的故障概率。5 类典型放电模式以及干扰对应的缺陷原因如表 2 所示。

表 2 典型局部放电模式与缺陷原因

Tab.2 Typical discharge mode and defect cause

典型图谱模式	缺陷原因
尖端放电	存在金属毛刺或尖端
绝缘件内部气隙放电	绝缘内部开裂或存在气隙
沿面放电	绝缘表面损伤或脏污
悬浮放电	金属部件松动
自由金属颗粒	安装过程中,内部遗留的金属颗粒
干扰	周围有明显电磁信号

3 深度学习理论研究

3.1 卷积神经网络

卷积神经网络是一种有监督的深度学习分类模型,可从样本图谱中识别关键特征^[9]。CNN 网络结构包括输入层、卷积层、池化层、全连接层和 SoftMax 输出层。其结构如图 3 所示,其中卷积层对图像进行卷积计算提取多个特征,利用池化层对特征图进行子采样。其中卷积层计算公式为:

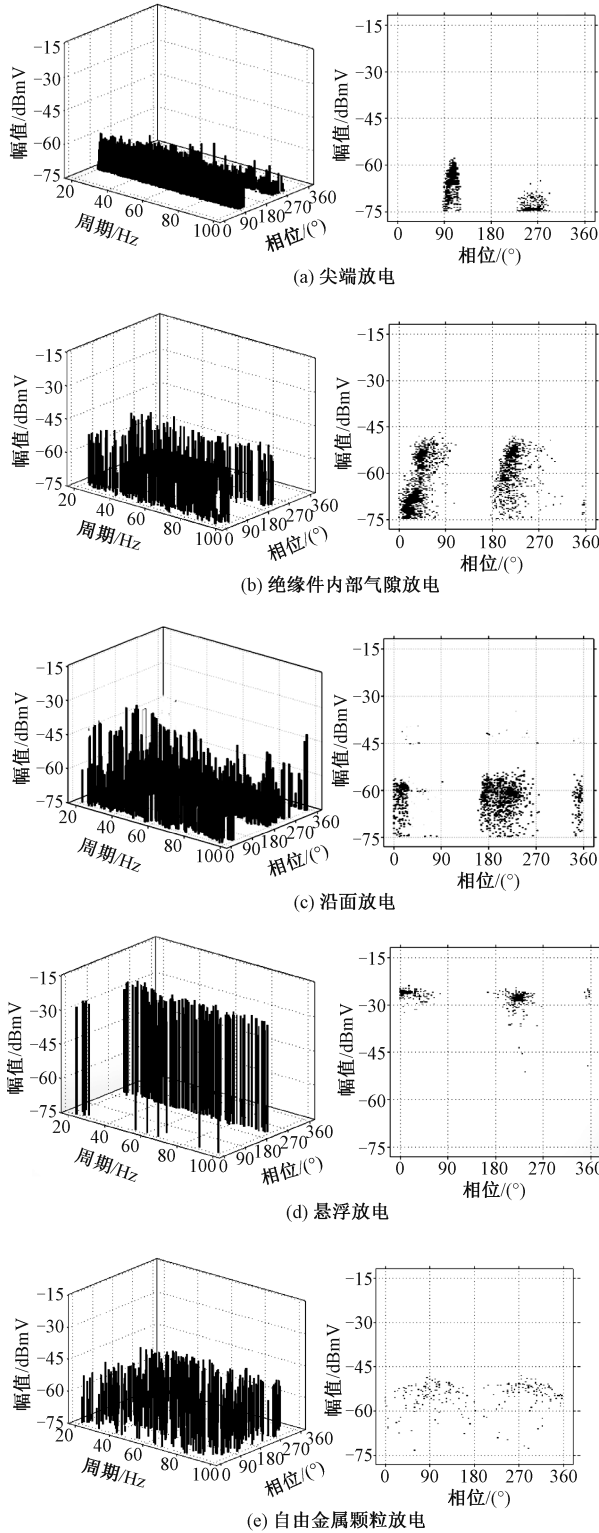


图1 典型局部放电图谱

Fig.1 Typical partial discharge pattern

$$y = f\left(\sum_{j=0}^{J-1} \sum_{i=0}^{I-1} x_{m+i, n+j} \omega_{ij} + b\right) \quad (1)$$

式中, x 为图像中 (M, N) 的二维向量; ω 为长和宽分别为 j, i 的卷积核; b 为偏置项; y 为卷积计算结果;

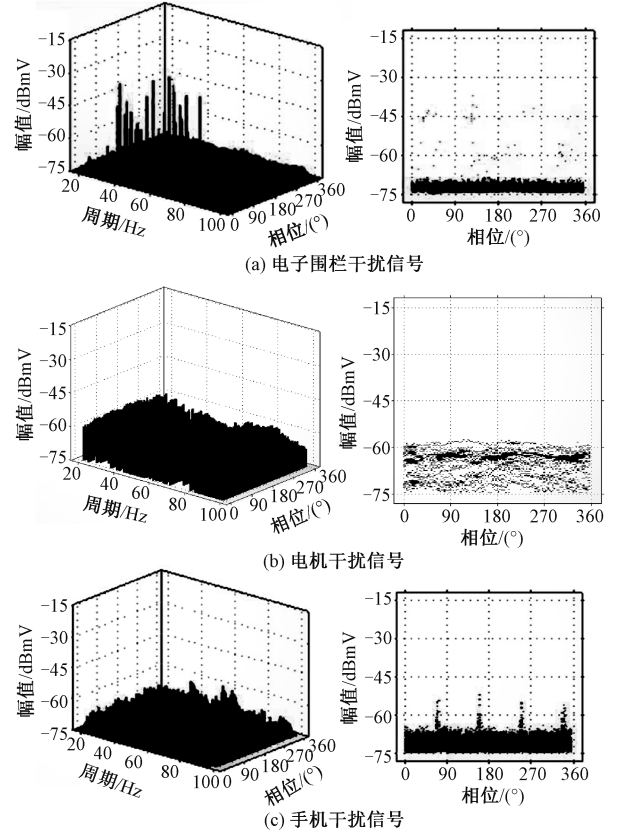


图2 部分典型干扰信号

Fig.2 Typical jamming signal image




图3 多层卷积神经网络结构

Fig.3 Structure of convolutional neural network

$f()$ 为激活函数。

通过卷积层和池化层的多层组合,对图像特征进行降维。最后通过全连接整合特征子图,利用分类器进行分类。

卷积神经网络通过前馈计算,利用激活函数将上一层输出作为下一层的输入,最终网络输出表达为:

$$O = f_n(\cdots f_2(f_1(XW_1)W_2)\cdots W_n) \quad (2)$$

式中, $f()$ 为激活函数; X 为输入数据; W 为各层参数。网络模型中各层参数 W 包括权重和偏置,利用梯度下降法更新并优化网络各个参数,最小化误差。代价函数计算方法为:

$$J(W) = -\frac{1}{n} \left[\sum_{i=1}^n \sum_{j=1}^k 1\{y_{(i)} = j\} \log \frac{e^{W_j^T x_{(i)}}}{\sum_{c=1}^k e^{W_c^T x_{(i)}}} \right] \quad (3)$$

其中, $k=3$, 表示 R、G、B 3 个通道的灰度图像个数; T 为含有标签的样本集和; 表达式 $y_{(i)} = j$ 为真则取值为 1, 否则为 0; $x_{(i)}$ 为样本集合; $y_{(i)}$ 为分类标签。

3.2 VGG 模型

VGG 是 Karzen^[9] 等在 ILSVRC 2014 中提出的卷积神经网络, 包含 6 个配置, 区别为卷积核大小和卷积层数目。其中性能最好的配置包括 13 个卷积层, 3 个全连接层和 5 个池化层, 即 VGG-16。

在训练中, VGG-16 的输入为固定大小 (224×224) 包含有 RGB 像素的图片。在输入过程中, VGG-16 将图像中的 RGB 像素值从各个像素中分别提取出来, 作为训练过程的输入。

数据随后被顺序输入到多个卷积栈中。每个卷积栈包含两或三个卷积层。卷积层均使用 3×3 的卷积核, 卷积步长被确定为 1 像素。卷积层后为 max-polling 层, 整个网络共包含 5 个 max-polling 层, 将网络切分为 5 个阶段的卷积特征提取。

在所有卷积栈后是三个全连接层。前两个全连接层包括 4 096 个连接, 第三个全连接层执行了 1 000 类的分类, 包含有 1 000 条连接。最后一个层为 soft-max 层。

所有的隐层均采用非线性反射机制和 ReLU 为激活函数。

3.3 迁移学习

由于训练 VGG-16 需要大量的样本集作为输入, 因此在小样本学习下并不适用。迁移学习^[10] 则可以解决小样本情况下的训练问题, 其基本原理如图 4 所示。

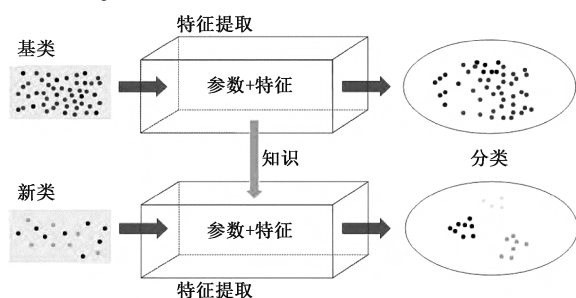


图 4 迁移学习

Fig.4 Transfer learning

迁移学习关注目标任务, 可以分为基于特征, 基于共享参数和基于关系的迁移。基于特征的迁移学习利用数据间的特征关系实现训练集数据增强。基于关系的迁移学习利用了知识蒸馏^[11] 的概念, 通过引入复杂但数据量大的网络来诱导精简的学生网

络。知识蒸馏为了减少网络架构, 同时把网络的知识保留下来。基于共享参数的迁移学习^[12] 利用与训练好的模型, 对图像中的不同特征进行提取, 重新构建分类层, 以实现一个新的网络, 从而对目标数据集分类。

4 基于迁移学习的局部放电模式识别方法

受检测设备类型以及外界干扰的影响, 现场检测时特高频局部放电缺陷图谱与典型图谱比较在相位和幅值上均有一定的偏移, 由于深度卷积网络具有对输入样本平移、缩放和扭曲不变特性^[6], 因此本文采用基于 VGG-16 和迁移学习方法构建识别算法实现对不同厂家的特高频图谱缺陷类型的诊断。

4.1 图像预处理

模式识别模型需要将输入的图像数据处理为便于模型读取的数据。本文选取样本数据来自于现场带电检测得到的特高频图谱和试验仿真图谱。由于带电检测仪器厂商的封闭性, 难以获取原始的模拟量数据。而且由于不同的厂家采用不同的标准和数据协议格式, 无法将不同的原始数据处理为相同格式的数据。综上所述, 采取原始数据做数据处理存在诸多困难, 为了提高实用性, 本文利用不同厂家的检测设备直接导出的图谱数据为数据样本进行训练和分类。由于能够获取的样本数据较小, 而深度学习技术需要较大的数据量。为了提高训练后模型的鲁棒性, 需要基于样本数据进行数据增强。

首先对图像进行翻转和旋转处理, 可将数据集扩展至旋转前的 4 倍。随后对图像进行随机裁剪处理。取裁剪框与原始图片纵横比相同, 且裁剪框在纵向或横向上与原始图片比例为 80%~100%, 随机选取裁剪框大小。对于每张图片, 随机裁剪 99 次, 并和原始图片一起作为增强后的数据集。经过数据增强后, 原始数据集被扩展到 400 倍, 极大提高了样本数据的大小。

在数据增强后, 为了使图像数据能够输入到 VGG-16 网络中, 需要对图像的大小做变换处理。本文采用了双线性插值的方式对数据做处理, 使得图像满足 VGG-16 网络输入的维度 224×224。

4.2 基于 VGG-16 的局部放电识别模型

在将高频图谱图像数据转换为矩阵后, 本文基于 VGG-16 和迁移学习方法构建局部放电识别模型, 实现对特高频检测图谱的分类。结构图如图 5 所示, 具体识别流程为: ①对搜集的局部放电检测图

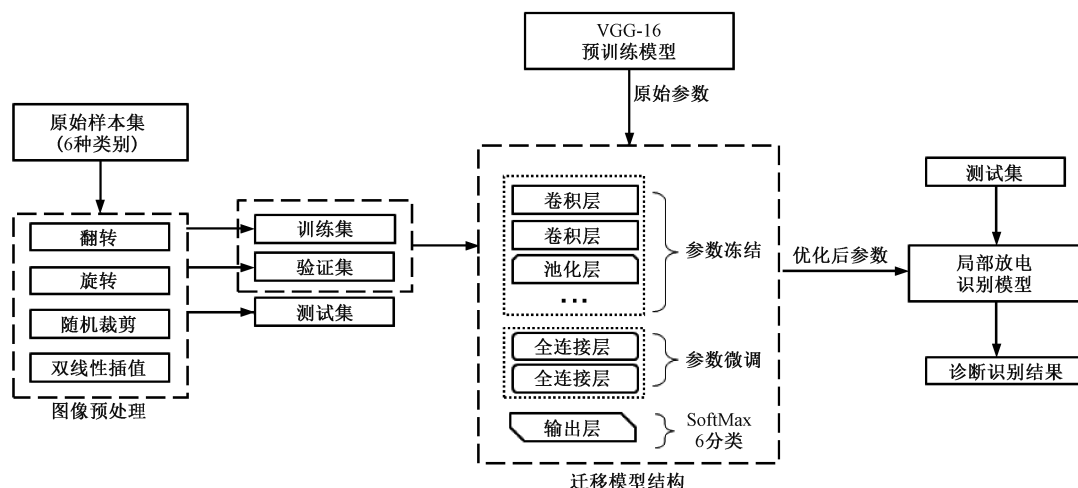


图5 局部放电识别模型结构

Fig.5 Structure of partial discharge recognition model

谱进行预处理,构建训练样本集;②基于 VGG-16 网络和迁移学习构建局部放电识别模型;③模型训练;④模型测试。最终得到训练好的局部放电识别模型,当新的检测图谱输入网络模型,可输出相应的诊断分析结果。

典型的 VGG-16 卷积神经网络^[13]包含了 16 个网络结构层,基于 ImageNet 数据集训练得到 VGG-16 网络模型^[14]。本文中网络结构包括 1 个输入层,13 个卷积层,5 个对应的池化层,2 个全连接层和 1 个 SoftMax 输出分类层。其中卷积层和池化层的参数使用预训练模型的原始参数做初始化,随后将各层参数冻结。冻结的目的为避免冻结层的参数修改,保存网络的泛化能力。

本文采用 2 个全连接层替换典型结构中的 3 个全连接层。这是由于较少的全连接层数对小样本数据更具有优势。

由于本文的目标分类包含 6 种高频图谱类型,因此输出分类层分类数设置为 6 种。

本模型的激活函数采用 ReLU 函数,与原始的 VGG-16 模型保持一致。

本模型采取反向传播算法,通过计算实际网络分类输出与期望计算的标注样本之间的差异,不断优化微调全连接层的模型参数,使实际网络输出更加接近目标值。

模型设计完成后,将输入样本集迭代训练。预处理后的样本数据将按固定比例 5:2:3 随机划分,得到训练集、验证集和测试集。在每次训练迭代过程中,将把随机选取训练集的 30%输入到模型中基于反向传播原理训练参数。在每次迭代后,将输

入验证集以验证模型分类的准确度和损失。并将验证集分类的结果作为模型是否收敛的标准。如果在迭代过程中,模型连续 5 次以上验证集的损失函数值不再下降,则判断模型为收敛。

经过训练,最终得到针对特高频检测图谱中局部放电图谱分类的识别模型。

4.3 实验及结果分析

本文基于 VGG-16 的卷积神经网络结构,利用 TensorFlow 深度学习框架、Python 语言、PyCharm 集成开发环境搭建模型进行实验。

实验数据集为现场带电检测得到的特高频图谱,识别的类别包括尖端放电、绝缘件内部气隙放电、沿面放电、悬浮放电、自由金属颗粒以及干扰。

首先根据变电站现场检测获取的 500 组样本数据建立样本集,样本集包括尖端放电 120 张、绝缘件内部气隙放电 80 张、沿面放电 20 张、悬浮放电 80 张、自由金属颗粒 75 张以及干扰图谱 125 张。每条样本包括 Images 和标注 Labels。其中 Images 为图谱及图片编号信息。标注 Labels 包括图片编号,缺陷类别。缺陷类别采用 One-hot 编码方式。训练样本集 D 可表示为:

$$D = \{(x_{(1)}, y_{(1)}), \dots, (x_{(k)}, y_{(k)})\} \quad (4)$$

式中, $y_{(k)}$ 为具体缺陷分类; $x_{(k)}$ 为对应不同缺陷分类下的训练样本集合。

通过数据预处理中翻转、旋转、随机裁剪的操作,将单张样本图片扩充为 400 张,则样本集可扩充至 200 000 张。按照 5:2:3 的比例,将其划分为训练集、验证集和测试集。随后利用本文所描述的迁移学习模型对样本数据进行模式识别的训练和测试。

VGG-16 的卷积神经网络结构中,输入层为预处理后 224×224 的数据,卷积层采用 3×3 大小的卷积核,步长为 1。池化层采用 2×2 的池化窗口,步长为 2。输出选用 SoftMax 分类器,模型的激活函数采用 ReLU 函数。迭代次数为 1 200 次,学习速率为 0.001,单次网络训练样本数据设为 100。实际经 800 次迭代时训练基本完成,损失函数值为 0.001 4。通过测试集中正确识别样本数与总样本数的对比评估,可知该算法识别的正确率达 91.5%。

进一步的,与传统分析模型支持向量机、BPNN 以及文献[7]所提的 LeNet-5 结构的神经网络进行对比分析,利用本文搜集的样本集,不同模型识别的效果如表 3 所示。从表 3 中可以看出对于不同的放电类型,VGG-16 网络模型均能保持在最高的识别准确率。

表 3 不同模型测试结果

Tab.3 Test results of different models

放电类型	识别准确率(%)			
	SVM	BPNN	LeNet-5	VGG-16NET
尖端放电	80.6	84.5	93.2	96.5
绝缘件内部 气隙放电	67	69.9	72.4	88.2
沿面放电	61.3	60.8	70.2	75.6
悬浮放电	76.2	72.8	95.1	96.61
自由金属颗粒	71.4	74.3	78.6	94
干扰	68.7	59.6	87.6	97.8
平均识别 准确率(%)	70.9	70.3	82.9	91.5

比较 VGG-16 模型和表现次优的 LeNet-5 模型。由于 VGG-16 模型相较于 LeNet-5 多了卷积和池化层,可提取出图谱中更多细微的特征,因此 VGG-16 模型优于 LeNet-5 模型,测试结果也进一步验证了 VGG-16 模型具有更高的识别准确率。

5 系统功能设计与实现

5.1 基于两层架构的局部放电模式识别系统

本文基于局部放电迁移学习模型建立了两个层级的分析架构,分为云端层和站级层^[15]。云端层搭建基于局部放电迁移学习模型的组合电器设备运行分析模块。站级层运行诊断分析模块,支持脱敏数据上传和利用上层训练好的迁移学习模型实现检测图谱类型的识别,具体流程如图 6 所示。

云端层支持汇总站级层的脱敏检测图谱数据和

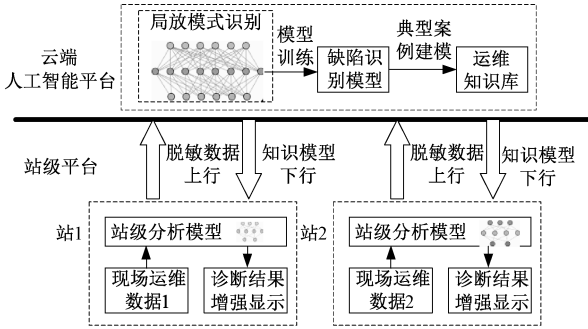


图 6 局部放电模式识别系统架构

Fig.6 Architecture of partial discharge pattern recognition system

运维信息。由于站内设备检测信息为各单位运维信息,内部数据并不对外公开且不交互。为了降低敏感程度,本系统只需获取检修过程中发现的异常图谱数据,且不需要过多的额外信息。云端层利用这些数据和信息实现汇总训练,生成迁移学习模型,并将模型数据下发到各个站级平台中。

站级层基于本地运维数据与分析模型识别局部放电类型,解决了由于站级区域内数据样本数少而无法有效训练模型的问题,从而提升模型识别的准确率,提高现场应对复杂作业的处置能力。

云端中的局部放电识别模型将持续更新,根据新的检测数据和结论,反复训练生成更加准确的模型。从而自动调整模型中关于设备缺陷识别的参数指标和不同故障类型的故障概率,保证局部放电事件频谱分类准确率,为运维检修现场提供有效的诊断支撑。

本文将上述基于 VGG-16 网络的局部放电模式识别算法和两层知识架构应用到实际运维检修系统中,设计包括局部放电检测仪和智能终端的组合电器特高频图谱识别和运维系统,系统结构如图 7 所示。

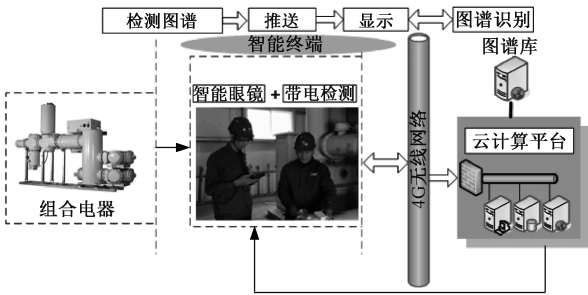


图 7 应用系统架构

Fig.7 System architecture

5.2 智能交互终端及应用流程

现场采用莫克 EC4000P 局部放电检测仪进行 GIS 的局部放电带电检测。EC4000P 通过蓝牙传输接口与现场智能终端传输检测数据。采集终端通过智能终端实现系统识别平台与现场的交互。智能终端与局部放电检测仪采用蓝牙传输,智能终端将获取的图谱信息通过 4G 终端传回系统平台。系统平台根据图谱库和图像识别算法,分析检测图谱,并将识别结果返回至智能终端。同时专家和管理人员可利用智能终端对现场进行作业监督和远程协助,为运维现场提供实时指挥决策和专家支持。信息交互示意图如图 8 所示。

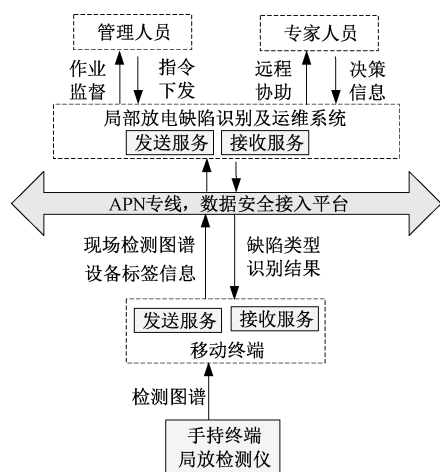


图 8 信息交互示意图

Fig.8 Diagrammatic sketch of information exchange

具体应用流程如图 9 所示。现场运维人员利用智能终端将检测图谱、设备类型和设备型号汇总上传到缺陷诊断和运维系统,通过上层训练好的图像识别算法,对现场检测传输回的图谱进行识别,将局部放电类型和缺陷原因返回到智能终端,现场查看。根据返回的诊断结果,现场进行排查,通过智能终端将现场排查结果反馈至智能分析平台(包括设备缺陷类型和缺陷原因),云端根据现场反馈结果,形成缺陷名称和原因的样本记录,修正局部放电特征与缺陷间的相关性。

5.3 应用案例

将上述训练好的识别模型及系统应用到现场检测诊断中。带电检测发现某 220 kV 变电站 212 GIS 间隔母线特高频检测信号异常,特高频测点分布如图 10 所示。检测图谱如图 11 所示,特征呈绝缘件内部气隙放电特征,但由于现场存在干扰,检测人员无法直接判断。

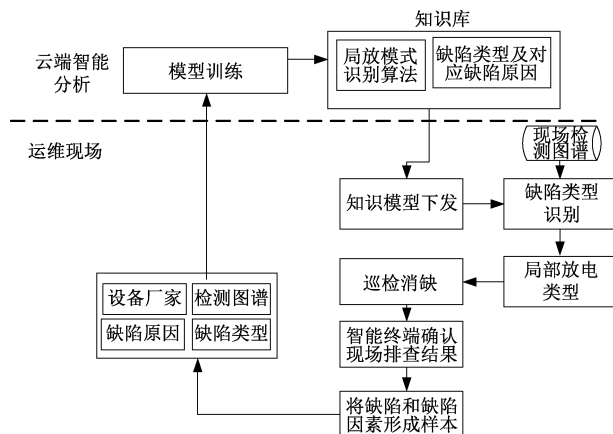


图 9 应用流程

Fig.9 Application process




图 10 特高频测点

Fig.10 UHF measuring point




图 11 检测图谱

Fig.11 Detection atlas

利用智能终端将检测图谱、设备类型及设备型号上传到缺陷诊断系统,基于 CNN 的局部放电模式识别算法识别缺陷类型,输出概率高的分类结果:绝缘件内部气隙放电缺陷概率 87.4%,干扰 8%(结果未全部列出)。系统将识别得到的最大概率对应的缺陷类型返回至智能终端叠加显示。进一步的采用屏蔽带法,将除传感器位置以外的盆式绝缘子其他部位全部包扎,再进行检测,发现放电幅值分散性较大,呈现绝缘放电特征,检测图谱如图 12 所示。将

检测图谱输入诊断系统,可知绝缘件内部气隙放电缺陷概率为 97.3%,识别结果如图 13 所示。




图 12 屏蔽干扰后检测图谱

Fig.12 Detection spectrum after shielding interference



图 13 识别结果

Fig.13 Recognition results

基于诊断结果,对 212 间隔下侧 1 号母线进行了解体检修,检查发现 220 kV 1 号母线 B 相支撑绝缘子存在黑色痕迹,疑似放电灼伤,判断为母线绝缘子制造工艺不良,导致在运行电压下绝缘内部开裂,产生气隙放电,具体缺陷部位如图 14 所示。




图 14 220 kV 1 母线绝缘子缺陷部位

Fig.14 Defective parts of 220 kV 1 bus insulator

针对缺陷情况,对母线支柱绝缘子进行了更换,设备投运后,局部放电检测无异常,缺陷消除,设备恢复正常运行。通过智能终端及系统平台,将该绝缘缺陷图谱存储到图谱库中,更新样本库。

6 结论

本文将卷积神经网络应用到 GIS 运维检修工作中。基于 GIS 局部放电检测图谱和运维检修记录,对于干扰图谱和局部放电缺陷类型进行分类,建立了

不同检测终端的典型故障图谱知识库。利用 VGG-16 结构的卷积神经网络识别局部放电模式,汇总多源数据进行模型训练,提高模型识别准确率。研发一种现场检测后台算法实时分析的 GIS 局部放电诊断系统,通过现场数据-终端-智能识别的过程,快速判断特高频异常信号。通过增强现实技术将诊断结果和缺陷原因增强显示在现场移动终端上,辅助现场诊断缺陷,从而提升现场运维检修效率。随着带电检测数据和案例的增多,可基于深度学习对特高频局部放电图谱数据和缺陷原因进行分析,不断优化识别算法,提高在线识别准确率。

参考文献 (References):

- [1] 李军浩,韩旭涛,刘泽辉,等 (Li Junhao, Han Xutao, Liu Zehui, et al.). 电气设备局部放电检测技术述评 (Review on partial discharge measurement technology of electrical equipment) [J]. 高电压技术 (High Voltage Engineering), 2015, 41 (8): 2583-2601.
- [2] 王姣,刘利强,胡凯旋,等 (Wang Jiao, Liu Liqiang, Hu Kaixuan, et al.). 基于 ANFIS 的 GIS 设备局部放电故障辨识 (Fault identification of GIS equipment partial discharge based on ANFIS) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2016, 35 (4): 75-80.
- [3] 张建安,王恩俊,陈焕栩,等 (Zhang Jianwen, Wang Enjun, Chen Huanxu, et al.). 基于自回归模型和超球面支持向量机的局部放电模式识别 (Partial discharge pattern recognition based on autoregression model and hypersphere support vector machine) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2016, 35 (9): 29-34.
- [4] 曾雄杰,刘旭明 (Zeng Xiongjie, Liu Xuming). GIS 设备局放类型图谱以及现场局放测试诊断图谱的应用 (Illustrated catalogue application of PD types and on-site diagnostic of PD test in GIS) [J]. 高压电器 (High Voltage Apparatus), 2013, 49 (11): 31-36.
- [5] 王涛云,马宏忠,崔杨柳,等 (Wang Taoyun, Ma Hongzhong, Cui Yangliu, et al.). 基于模糊 Petri 网的 GIS 故障诊断与可靠性分析 (Fault diagnosis and reliability analysis for GIS based on fuzzy Petri net) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2016, 35 (5): 67-73.
- [6] 宋辉,代杰杰,张卫东,等 (Song Hui, Dai Jiejie, Zhang Weidong, et al.). 复杂数据源下基于深度卷积神经网络的局部放电模式识别 (Partial discharge pattern recognition based on deep convolutional neural network under complex data sources) [J]. 高电压技术 (High Voltage Engineering), 2018, 44 (11): 3625-3633.

- [7] 张新伯, 唐炬, 潘成, 等 (Zhang Xinbo, Tang Ju, Pan Cheng, et al.). 用于局部放电模式识别的深度置信网络方法 (Research of partial discharge recognition based on deep belief nets) [J]. 电网技术 (Power System Technology), 2016, 40 (10): 3272-3278.
- [8] Q/GDW 11059.2-2013, 气体绝缘金属封闭开关设备局部放电带电测试技术现场应用导则 (第 2 部分 特高频法) (Field application guide for partial discharge on-site testing technology of GIS (Part2: Ultra high frequency)) [S].
- [9] Karen Simonyan, Andrew Zisserman. Very deep convolutional networks for large-scale image recognition [A]. International Conference on Learning Representations [C]. 2015. 1-14.
- [10] 刘颖, 雷研博, 范九伦, 等 (Liu Ying, Lei Yanbo, Fan Jiulun, et al.). 基于小样本学习的图像分类技术综述 (Survey on image classification technology based on small sample learning) [J]. 自动化学报 (Acta Automatica Sinica), 2020, 46 (4): 1-20.
- [11] Geoffrey Hinton, Oriol Vinyals, Jeff Dean. Distilling the knowledge in a neural network [DB/OL]. Computer Science, Mathematics ArXiv2015.
- [12] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [A]. Proceedings of the 26th International Conference on Neural Information Processing Systems [C]. Lake Tahoe, Nevada, USA, 2012. 1106-1114.
- [13] 周俊宇, 赵艳明 (Zhou Junyu, ZhaoYanming). 卷积神经网络在图像分类和目标检测应用综述 (Application of convolution neural network in image classification and object detection) [J]. 计算机工程与应用 (CEA), 2017, 53 (13): 34-41
- [14] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks [A]. Proceedings of the Advances in Neural Information Processing Systems [C]. 2012. 1097-1105.
- [15] 彭红霞, 文艳, 王磊, 等 (Peng Hongxia, Wen Yan, Wang Lei, et al.). 基于两层知识架构的电力设备差异化运维技术 (Differential operating maintenance technology of power equipment based on two-layer knowledge architecture) [J]. 高压电器 (High Voltage Apparatus), 2019, 55 (7): 221-226.

Partial discharge pattern recognition based on convolutional neural network

ZHANG Cong-cong¹, WANG Gang¹, GAO Dong¹, YIN Wei¹, WANG Kai¹, LU Ming¹,
LIU Ying-nan², LI Ya-jin²

(1.Dongying Power Supply Company of State Grid, Dongying 257091, China;

2.School of Electrical Engineering, Shandong University, Jinan 250061, China)

Abstract: Partial discharge (PD) detection signal is an important criterion for judging whether the equipment has insulation defects. However, due to the interference of environment and electromagnetic and other signals, PD pattern recognition is difficult. Limited by the experience and interference of personnel, small number of samples and other factors, the efficiency of local discharge defect diagnosis and operation and maintenance of field combined electrical appliances needs to be further improved. In order to solve these problems, a method of PD defect diagnosis and operation and maintenance based on convolution network is proposed. Based on GIS Partial Discharge Detection map and operation and maintenance records, the map and defect types are classified, and the typical fault map knowledge base of different detection terminals is constructed. The algorithm of PD pattern recognition based on convolutional neural network with vgg-16 structure is studied to realize the classification of UHF detection pattern and PD recognition. Research and development of GIS Partial Discharge defect diagnosis and operation and maintenance system is based on two-tier architecture. Multiple station level detection maps and operation and maintenance information are collected and trained in the upper layer. Model parameters and knowledge are distributed to each station for application. The model runs online and automatically adjusts the model according to new detection data and conclusions. Based on the defect data of power company operation and maintenance, the validity of the GIS Partial Discharge defect diagnosis method are analyzed and verified, which can provide theoretical basis for equipment operation and maintenance decision. So the efficiency of on-site operation and maintenance efficiency is further improved.

Key words: gas insulated switchgear; two-layer knowledge architecture; partial discharge maintenance; pattern recognition