

人工智能在局部放电检测中的应用(二): 模式识别与状态评估

范 路¹, 陆云才², 陶风波², 尹 毅¹

(1. 上海交通大学 电子信息与电气工程学院, 上海 200240;

2. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211102)

摘要:故障类型的模式识别以及状态评估对于故障诊断和维修至关重要。不同缺陷类型将产生具有差异性的局部放电信号, 缺陷的严重程度以及局部放电的演变过程同样会引起局部放电信号的改变, 这种情况能够转化为不同严重等级和发展阶段的模式识别, 模式识别属于典型的分类问题。本文对模式识别和状态评估这类分类问题进行综述。相比基于数理统计的分类结果, 人工智能算法实现了接近100%的识别准确率。然而当前研究中仍存在一些不足, 对此本文给出了解决策略并对未来的研究方向进行了展望。

关键词:局部放电; 分类; 特征提取; 模式识别; 状态评估; 人工智能

中图分类号: TM215; TM855 文献标志码: A 文章编号: 1009-9239(2021)07-0010-15

DOI: 10.16790/j.cnki.1009-9239.im.2021.07.002

Application of Artificial Intelligence in Partial Discharge Detection Part II: Pattern Recognition and Condition Assessment

FAN Lu¹, LU Yuncai², TAO Fengbo², YIN Yi¹

(1. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China; 2. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211102, China)

Abstract: The fault type recognition and condition assessment play the crucial roles in fault diagnosis and maintenance. Different defects will produce partial discharge signals with difference, and the partial discharge signal also changes with the defect severity and the evolution of partial discharge. This situation can be regarded as pattern recognition of different severity levels and evolution stages, and the pattern recognition is a typical classification problem. In this paper, classification problems such as pattern recognition and state assessment were reviewed. Compared to classification results based on mathematical statistics, artificial intelligence has achieved nearly 100% of recognition accuracy. However, there are still some shortcomings in current research, this paper gives some solution strategies and prospects future research direction.

Key words: partial discharge; classification; feature extraction; pattern recognition; condition assessment; artificial intelligence

0 引言

作为评估电力设备运行状态的重要指标, 局部放电的测量结果存在多样性, 这一方面是因为对于不同缺陷类型, 放电机理的差异使得不同放电类型

之间的局放信号存在固有差异, 缺陷类型的模式识别有利于准确诊断设备的故障原因^[1]; 另一方面是因为随着电力设备绝缘的逐渐劣化和局部放电的进一步发展, 局部放电信号特征也随之改变。掌握局放信号特征的发展规律有助于预测电力设备的运行状态和寿命。传统的模式识别和状态评估多采用放电信号在时频域上的数理统计量作为特征参量, 在噪声干扰和多源放电共存的情况下, 识别

收稿日期: 2020-06-08 修回日期: 2020-07-14

作者简介: 范路(1997-), 男(汉族), 安徽宿州人, 博士生, 研究方向为绝缘性能评估和智能诊断; 通信作者: 尹毅(1972-), 男(汉族), 江苏常州人, 教授, 研究方向为高电压与绝缘技术。

准确率难以进一步提升。通过降维算法提取的特征参量具有较强的抗干扰性,且人工智能算法能够根据放电特征有效区分时频域上相近的不同类型放电信号,因而在局部放电模式识别和状态评估领域得到广泛应用。

当前,有关人工智能在局部放电检测领域的研究满坑满谷,但相关的综述性文章较少,在众多的人工智能算法应用中,研究者缺乏对不同算法研究成果的对比分析。虽然有相关的博士论文综述了该领域的研究进展,但由于博士的研究方向较集中,难以对不同研究领域进行统筹归纳。

在局部放电的相关综述中,R BARTNIKAS^[2]最早在有关局部放电测量技术和检测方法的综述中涉及人工智能算法在模式识别领域的应用,其主要介绍了多层前馈神经网络、模糊推理以及分形理论的应用。其中多层神经网络具有高度的非线性特性,在局部放电模式识别方面取得了巨大的成功。N C SAHOO 等^[3]后续对局部放电的模式识别再次进行总结和展望,进一步完善了包含放电数据模式(基于时间分辨、相位分辨和非时间相位分辨)、特征提取(包含基于 PRPD 的统计量、脉冲拟合参数、数字信号处理的特征参数、放电图谱的分形特征和脉冲时间序列特征)、模式分类(包含聚类分析、人工神经网络和模糊推理)以及不同放电数据模式下的评估等内容。W J K RAYMOND 等^[4]同样基于放电模式进行分类总结,汇总内容主要包含信号去噪、特征提取以及模式识别,且文中介绍了不同识别算法的原理及具体应用,为相关研究学者提供了参考和借鉴。

随着研究的不断深入,相对于先前综述的粗略性总结,后续学者针对具体研究方向进行了综述。A A MASUD 等^[5]针对神经网络在局部放电模式识别中的应用进行了系统的总结,其主要内容包括 BP 神经网络、模块化神经网络、集成学习、概率神经网络(PNN)和径向基神经网络(RBF)的原理及应用,文中给出了不同神经网络在模式识别中的对比性研究以及适用性评估。M MONDAL 等^[6]从电力设备出发,针对电力变压器中的局部放电进行识别、检测和分类总结,介绍了基于电信号、声信号、电磁信号以及混合方法的检测技术以及人工智能法在去噪和模式识别中的应用。H JANANI 等^[7]第一次系统地对比了不同降维算法和分类算法间进行交叉使用的模式识别结果,文中基于 PRPD 特征

参量的模式识别,针对 IEC 60270:2015 的 6 种放电来源(3 种 SF₆ 气体放电模型、2 种变压器油放电模型和空气电晕放电模型)进行特征提取和模式识别,其中特征提取采用基于统计算子的特征量以及采用主成分分析(PCA)、局部线性嵌入(LLE)以及随机近邻嵌入(SNE)等 12 种机器学习降维得到的特征向量,模式识别采用支持向量机(SVM)、多层感知器(MLP)以及概率神经网络(PNN)等 10 种机器学习算法。研究结果表明,在最优参数设计的基础上,非线性降维算法优于线性降维算法和统计算子,核支持向量机(KSVM)、模糊向量机(FSVM)和 adaboost 优于另外 7 种机器学习算法,且识别准确率分别高达 99.4%、99.1% 和 98.6%。模糊分类器区别于其余算法对分类结果划分的精确性,采用“隶属度”原则,赋予多种放电类别不同的概率。

随着深度学习在局部放电模式识别中的应用,S BARRIOS 等^[8]对深度学习在局部放电模式识别中的研究进行总结,训练数据主要采用基于相位分析的局部放电(PRPD),主要介绍了用于特征提取和数据生成的自编码器(autoencoder)、基于序列数据模式识别的循环神经网络(RNN)、用于数据生成的对抗神经网络(GANs)以及基于放电图谱模式识别的卷积神经网络(CNN),他们认为相较于传统机器学习算法,深度神经网络(DNN)能够实现全自动的特征提取和模式识别。

国内学者对人工智能算法在局部放电中应用的相关研究不可胜数,李军浩等^[9]介绍了脉冲电流法、特高频检测法、超声波检测法以及化学检测法等局部放电检测技术的基本原理,并给出特征提取、模式识别以及放电源定位的基本策略,但文中仅谈及人工智能在这些领域中有所应用,并未对具体实现方案进行详细阐述。唐志国等^[10]对局部放电的模式识别进行总结,对不同放电数据模式(包含单脉冲、相位分布、脉冲序列、相邻脉冲参考电压差和分形特征)进行特征提取以及模式识别,介绍了神经网络以及支持向量机等人工智能算法的应用,但缺少深度学习的应用案例。刘云鹏等^[11]针对人工智能在电力变压器状态维修中的应用进行综述,归纳了人工智能在数据清洗、文本挖掘、图像识别、状态评估、故障诊断、状态预测和检修决策优化 7 种典型场景的应用,指出数据壁垒、数据质量以及异常样本匮乏限制了人工智能算法的应用。

先前的综述中均未对人工智能算法在模式识

别中应用的具体策略进行总结,本文针对人工智能算法在模式识别和状态评估领域中应用的具体策略进行综述,对当前研究内容的不足之处提出解决方案,并对未来研究方向加以展望。

1 人工智能算法的基本思想

1.1 人工神经网络

BP神经网络和径向基神经网络(RBFN)的基本思想已经在第1部分中阐述^[2],通过多个简单神经元相互连接形成一种具有广泛连接的人工网络,能够实现对高维数据的拟合。本文对概率神经网络、自组织映射神经网络以及深度神经网络进行介绍。

1.1.1 概率神经网络

概率神经网络(PNN)在径向基神经网络的基础上,结合密度函数估计和贝叶斯决策,采用最小化分类风险概率的策略实现分类过程,如图1所示。相比于RBF神经网络,PNN将数据分为多种类别,通过贝叶斯决策决定最优类别,其中输出层的输出与基于内核的概率密度成正比。

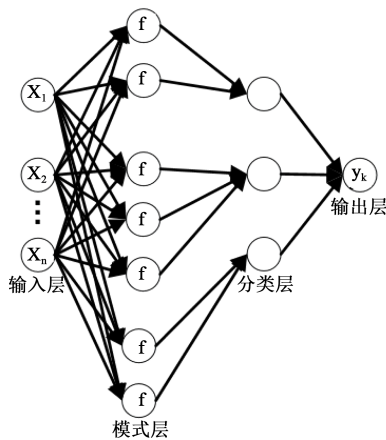


图1 概率神经网络

Fig.1 Probabilistic neural network

1.1.2 自组织映射神经网络

自组织映射(SOM或KOH)神经网络是一种无监督学习模式,采用多个神经元竞争的思想,研究表明大脑皮层中对于输入模式接近的兴奋,对应的兴奋神经元同样接近,如图2所示。SOM神经网络通过竞争层对输入向量进行对比分析,通过不同输入向量之间的距离来衡量向量间的相似性,实现不同类型输入的有效区分,训练过程加强兴奋神经元的权重,而其余神经元的权重保持不变。




图2 自组织映射神经网络

Fig.2 Self-organizing map neural network

1.1.3 卷积神经网络

卷积神经网络(convolutional neural network, CNN)基于生物学上感受野的机制而提出,主要用于图像处理。CNN的基本结构如图3所示^[8],其中卷积层实现局部连接和权重共享,用于提取局部区域的特征;池化层降低特征维数,避免过拟合;全连接层整合池化层中提取的特征信息,在图像分类问题中,全连接层的最后一层为softmax层,通过损失函数实现分类的训练过程。




图3 卷积神经网络

Fig.3 Convolutional neural network

1.1.4 循环神经网络

受大脑皮层(cerebral cortex)的解剖结构允许刺激在神经回路中循环传递的启发,西班牙神经生物学家Rafael Lorente de Nó由此提出反响回路假设,循环神经网络(recurrence neural network, RNN)应运而生,如图4所示。循环神经网络由多个循环单元全连接形成,每个循环单元的状态由上一时刻的状态和输入量共同决定。循环神经网络善于处理序列类型数据,因而广泛应用于自然语言处理。由于循环神经网络的多层嵌套结构会导致误差梯度消失,参数停止更新,故常采用其变体形式——长短期记忆(long short-term memory, LSTM)神经网络和门控循环单元(gated recurrent unit, GRU)。LSTM神经网络通过添加遗忘门的形式解决多层嵌套导致的梯度消失,而GRU则将LSTM神经网络的输入门和遗忘门合并为更新门,使得网络的当前状态与上一时刻的状态具有线性依赖关系。




图4 循环神经网络

Fig.4 Recurrence neural network

1.1.5 自编码器

如图5所示,自编码器包含编码器和解码器,其中编码器实现输入样本到特征空间的映射,解码器实现将特征空间向输出量的映射,训练目标为输入向量与输出向量一致。自编码器常用于提取样本的特征向量,与其他神经网络配合使用。




图5 自编码器
Fig.5 Autoencoder

1.1.6 生成对抗网络

生成对抗网络 (generative adversarial networks, GANs)模拟生物中对抗进化的改变,网络架构由生成器和判别器组合形成,生成器和判别器均采用深度神经网络,如图6所示。生成器训练的最终目标为判别器无法区分真实数据和生成数据,判别器训练的最终目标为区分生成器的生成数据与真实数据的差异,两者间对抗训练。生成对抗网络通过学习样本的特征产生新样本,常用于特征提取和增加数据样本量。目前应用较广的主要变体为基于 Wasserstein 距离的生成对抗网络(WGAN)、基于能量的生成对抗网络(EBGAN)和循环生成对抗网络(Cycle GAN)等。

1.2 聚类算法

聚类算法属于无监督学习方法,其主旨思想为“近朱者赤,近墨者黑”,将具有较高相似度的数据划分至同一类簇,将具有较高差异性的数据对象划分至不同类簇,常用算法有 K-means 聚类算法、Mean-Shift 聚类以及基于密度的带噪声空间聚类




图6 生成对抗网络

Fig.6 Generative adversarial network

等。K-means 聚类算法的实现流程为:首先随机选取 K 个初始聚类中心,通过计算样本点与聚类中心的距离寻找最近的聚类中心进行分类,并根据初步分类结果确定新的聚类中心,直至训练满足收敛条件,其主要工作流程如图7所示。

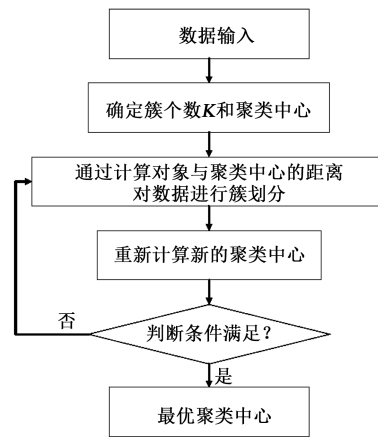


图7 K-means 聚类

Fig.7 K-means clustering

1.3 降维算法

随着大数据时代的到来,一方面数据量庞大且数据的特征信息存在冗余现象,另一方面背景噪声会干扰人工智能算法训练结果的准确度。对高维数据在损失尽可能小的情况下进行有损压缩,能够使人工智能算法易于收敛,从而提升训练效率,节约训练时间。常用的降维算法主要有主成分分析 (PCA)、局部线性嵌入 (LLE)和 t 分布随机近邻嵌入 (t-SNE)等。

1.3.1 主成分分析

主成分分析(PCA)是一种线性降维算法,能够通过线性代数基本知识推导^[13]。PCA的基本思想为:首先计算样本的协方差矩阵,对协方差矩阵进行特征值分解,在正交空间里选取最大的 k 个主特征值构成特征向量,如图8所示。

1.3.2 局部线性嵌入

局部线性嵌入(LLE)是基于流行学习提出的降




图8 主成分分析

Fig.8 Principal component analysis

维算法,其基本思想为空间中的一点根据周围点的线性组合求出,高维空间中的这种线性组合关系投影到低维空间应当保持不变,通过对低维空间进行正交分解,提取特征向量。相比于主成分分析,局部线性嵌入强调了数据点间的关系,认为空间距离较近的各点间存在线性关系,其主要工作流程如图9所示。




图9 局部线性嵌入

Fig.9 Local linear embedding

1.3.3 t分布随机近邻嵌入

t分布随机近邻嵌入(t-SNE)是一种可视化程度较好的降维算法,将高维数据降低到二维或三维空间可视化展示,如图10所示。通过高维空间和低维空间中数据点间的距离分别计算数据点间的相似性条件概率,采用最小化数据点间的Kullback - Leibler(KL)散度实现高维空间对低维空间的有效映射。相对于随机近邻嵌入(SNE),t-SNE采用t分布作为代价计算函数,t分布的长尾特征使得高维空间中相邻点在低维空间距离更近,而距离较远的点在低维空间相距更远。

1.4 模糊理论

经典集合论认为元素与集合的关系只有属于和不属于,强调精确性,认为非此即彼。而模糊集

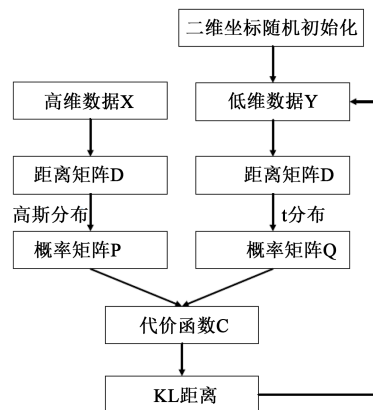


图10 t分布随机近邻嵌入

Fig.10 The t-distributed stochastic neighbor embedding

合论则用隶属度来表达元素和集合的关系,强调模糊性,认为亦此亦彼。模糊理论采用隶属度函数表达模糊性,通过模糊推理规则和运算,从数据中挖掘知识表达的逻辑关系,形成分类方案。模糊理论认为每种类别均有一定概率,其中概率最大者为最优分类结果,模糊分类结果提供的多样性有助于研究者针对自身理解进行主观决策。

1.5 支持向量机

支持向量机(SVM)常用于解决样本空间中线性不可分的问题,采用核函数将低维样本空间向量映射到高维空间,在高维空间中寻求线性划分平面,使超平面与样本间的距离最大,如图11所示。其中核函数的选取主要包含线性核函数和高斯核函数等。




图11 支持向量机

Fig.11 Support vector machine

1.6 分形理论

分形理论是混沌理论的重要分支,用于描述非线性系统的有序性和无序性的统一,以及确定性和随机性的统一。分形理论主要用于描述某种特征变换下的不变性,称为自相似性。自相似性是指某种结构(过程)的特征在不同空间(时间)尺度上具有一定的相似性,即系统(结构)的局部特性与整体

特性相似。分形中用于描述自相似性和复杂性的常用参数有分形维数和空缺率。其中分形维数主要分为5类^[14]:①改变观察尺度,采用具有特征长度的基本图形去近似图形;②基于测量关系,采用非整数维度进行测度;③基于统计思想,利用相关函数定义两点间的相关性,距离越远相关性越低,其衰减的速率与分形维数相关;④基于分布函数,通过不同尺度下的特征数分布函数求取;⑤根据频谱,对具有分形特征的变化过程,改变截止频率并不改变频谱形状,即测量尺度的改变不影响频谱波形。

2 人工智能在模式识别中的应用

电力设备运行中,不同缺陷的放电类型包含的放电机理存在差异性,因此将产生具有不同特征的局部放电。当前研究中有关局部放电的机理仍不明确,从放电信号出发,研究不同放电类型的模式识别有助于进一步完善放电理论。模式识别的研究内容主要分为两步:第一步为特征提取。由于多种检测方法得到的局部放电信号数据信息量大,包含较多冗余特性,如果输入量采用原始信号,训练过程费时费力,难以收敛,且识别准确率低。特征提取主要包含时域特性、频域特征、非线性特征以及人工智能算法降维得到的特征向量。对于时域特性,包含基于时间分辨和相位分辨两种,其中基于时间序列上提取的特征量主要有基于脉冲序列的幅值、脉冲宽度、重复率等;基于相位特征(PRPD)获取的特征量主要为平均值、方差、偏度、峭度、放电不对称性以及相关系数因子等。频域特征的特征参量主要有重心频率、均方根频率以及频率方差等。非线性特征参量主要包含基于放电图谱的分形维数和空缺率等。采用人工智能算法进行模式识别的第一步是对先前所述的特征向量进行降维,提取主特征向量。第二步为故障识别。针对不同缺陷类型产生的PD信号的特征向量差异,通过人工智能算法训练缺陷类型与特征向量的内在关联,对多种放电类型缺陷进行区分。

针对特征提取和故障识别,人工智能算法在模式识别中的应用表现为3种方案:①人工提取特征参量,主要包含时域特性、频域特征和非线性特征,对提取的特征向量进行故障识别,人工智能算法仅用于故障识别;②首先采用人工智能算法对放电特征的统计特征参量进行有效降维,输入维度的大小

影响模型收敛速度和识别准确率。针对特征提取后的主特征向量采用人工智能算法对放电类型进行有效识别;③将前两种方案的特征提取和故障识别同步进行。得益于深度学习的发展,第3种方案将特征提取和模式识别同步进行,特征提取隐含在深度神经网络当中,计算机通过自己的认知方式选取与放电类型最相关的特征量,仅展示故障识别的结果。

由于人工智能算法在模式识别领域的应用较广泛,研究中有关特征提取和故障识别的人工智能算法具有一定交叉性。本文以故障识别采用的不同算法作为划分标准,对聚类算法、神经网络、支持向量机、模糊分类以及集成学习的应用进行综述。

2.1 聚类算法的应用

聚类算法通过对不同类型的局放信号在特征空间上的聚类分析,实现放电类型的模式识别。文献[15]对时域和频域的累积能量函数提取特征,并采用K-means聚类算法实现多源PD的有效分离。区别于以统计参量作为输入,文献[16]采用主成分分析提取空间灰度依赖法(SGLDM)、灰度差直方图(GLDHM)、灰度游程法(GLRLM)和功率谱法(PSM)4种纹理分析算法的主特征参量,将12个特征参数减少为3个,减少了分类时间。其中第一主成分从负半周期的特征获取,第二主成分从正半周期的特征获取,第三主成分由整个特征集获取。文中通过最小距离分类器区分6种不同类型的PD信号源,识别准确率超过95%。由于聚类算法受噪声干扰的影响较大,且对于相似度较高的放电类型难以有效区分^[17],因此常用于区分度明显的放电类型模式识别。

2.2 神经网络的应用

神经网络作为应用最广的人工智能算法,不同类型的神经元设计以及训练过程的优化策略均使得训练效果具有差异性。总体而言,神经网络以其强大的非线性拟合能力能够解决传统线性分类器的固有缺陷。文献[18-19]采用BP神经网络对不同放电类型的局部放电信号进行有效识别,其中输入层神经元数量为基于统计提取后的特征参量数,输出层神经元数量为放电类型的个数,隐含层神经元个数介于两者之间,超参数由训练结果确定。为进一步优化BP神经网络的训练过程,文献[20]利用自适应遗传算法优化BP神经网络的训练过程,能够有效解决BP神经网络的初值敏感性和易局部收敛

问题,结果表明优化后的BP神经网络在4种典型GIS缺陷上具有较高的识别能力和泛化能力。随着分形及混沌理论的发展,区别于时频域特征,分形特征具有特征向量数目少且区分度明显的优势,在局部放电领域得到广泛应用^[21-22]。在采用BP神经网络进行模式识别的研究中,文献[18]采用三维PD形貌的分形维数和空缺率作为输入量实现放电模式识别,结果表明分形特征参量在神经网络中识别效果较好。文献[23]以特高频信号在时频图上的分形特征作为输入,模拟缺陷的识别准确率达到96%以上。与上述特高频信号相似,研究^[24]表明超声波信号中的分形维数和空缺率同样能够实现高识别准确率的模式分类。

相对于BP神经网络,径向基神经网络通过径向基函数将低维向量映射到高维空间,更能有效区分较为接近的放电故障,且径向基神经网络的抗干扰能力强。对于绝缘子的局部放电模式,文献[25]采用RBF神经网络进行模式识别,在不同的缺陷类型下,平均识别率达到94%。研究表明局部放电信号的多种特征参量均适用于RBF神经网络的训练,文献[26]采用正交最小二乘法训练的RBF神经网络对局部放电 Δu 模式下的不变矩特征参数进行训练,用于识别5种人工绝缘缺陷产生的局部放电信号,识别准确率均在85.7%以上。文献[27]将UHF信号在多尺度下小波变换后的小波系数网格维数作为特征输入量,最低识别率为70%。局放信号的分形参数同样适用于基于径向基神经网络的模式识别,文献[28]选取PD灰度图像的盒维数和信息维数作为特征量,采用径向基神经网络实现5种典型GIS缺陷类型的识别。而文献[29]则以放电相位、时间差和放电次数构成的三维谱图分形维数作为输入,实现5种人工油纸缺陷类型的识别,准确率高于90%,且具有较强的抗干扰能力。

由于径向基函数有效地隔离了不同放电类型,因而径向基神经网络具有很强的抗噪能力,更适用于实际运行环境。文献[30]实现信噪比(SNR)大于10 dB情况下的识别率高于75%的目标。为有效区分噪声干扰下的多源放电信号,文献[31]提出一种基于频谱重构的变电站多PD源分离算法,在仿真环境下,模拟多PD源和噪声干扰的UHF信号,结果发现RBF神经网络能够有效分离混合噪声信号的多源PD信号,仿真环境下当信噪比为10 dB时,信号分离率超过75%,在变电站检测中分离率超过

70%。

其他神经网络同样取得了优于BP神经网络的结果,通过改进BP神经网络中的激活函数和阈值,文献[32]设计了自适应小波神经网络并用于4种典型放电的模式识别,采用粒子群优化算法(PSO)进行初步优化和BP算法再次优化,识别准确率为100%。通过对比自组织映射(SOM)神经网络和BP神经网络对多种放电类型的模式识别结果,文献[33]认为SOM神经网络明显优于BP神经网络,识别准确率达到90%以上,且文中横向对比分析了SOM的不同神经网络结构对识别结果的影响。文献[34]采用PCA将基于统计量的37个特征降维成12个主成分因子,信息表征率在75%以上,采用概率神经网络(PNN)实现局部放电的模式识别,结果优于BP神经网络。基于输入特征向量的个数直接影响训练速度和识别准确率,文献[35]采用多种概率神经网络复合系统实现基于14个输入特征向量进行模式识别,结果表明输入特征量的增加,并不一定能够提高识别准确率,文中同样给出了不同神经网络架构应用于模式识别的宝贵意见。

2.3 支持向量机的应用

与RBF神经网络相似,支持向量机同样将低维向量映射到高维空间进行区分,因而具有较好的抗干扰能力和泛化能力。文献[36]提取 φ - q - n 灰度图像的正、负半周盒维数和信息维数作为特征参量,采用径向基作为核函数的SVM进行模式识别,相比于反向传播神经网络(BPNN)准确率有所提高,基本达到90%以上。文献[37]则针对放电信号的功率谱密度采用基于KL散度内核的支持向量机用于识别不同放电脉冲,其在多个放电源同时存在和噪声环境下仍具有较高的识别准确率,且对于无法区分的放电类型,仍可通过PRPD进一步区分。文献[38]对射频电流传感器采集的局部放电信号,采用SVM识别不同PD源,将相位平均电荷信息作为特征向量,在单一源62组的测试结果中错误分类为2组,但多源测试的识别结果不好。为消除噪声干扰对模式识别的影响,文献[39]基于统计得到的27个特征参量,采用分层式BPNN和SVM进行故障诊断,其中第一层实现放电信号与噪声信号的区分,第二层实现不同放电类型的识别,经过分层后识别率接近100%。

为进一步提高训练效率和识别准确率,通常对多维输入特征向量进行降维,文献[40]采用PCA从

UHF 信号的 36 个纹理特征中提取 6 个特征参量, 累积贡献率达到 100%。对于主要特征量采用 SVM 对 4 种放电类型进行模式识别, 识别准确率分别达到 97.67%、97.00%、97.67%、98.33%。文献[41]采用 PCA 将统计特征的 26 个特征量降维至 10 个特征量, 降维后的特征向量在 SVM 的识别准确率同样优于降维前。文献[42]通过 LLE 实现 UHF 信号基于统计量的降维处理, 采用 SVM 进行模式识别, 现场识别准确率为 92.1%。通过对比不同降维算法, 文献[7]认为 LLE 进行特征提取的结果与 PCA 特征提取相差不多, 但比 SNE 要低。对于 LLE 降维后的特征向量, SVM、FSVM、MLP 以及 RBFN 的识别对比结果表明 FSVM 识别准确率最高, 达到 97.8%。

支持向量机的参数选取是影响识别准确率的另一个重要因素, 文献[43]研究了基于不同特征参数的支持向量机对 PD 的模式识别, 并对比其识别准确率和泛化能力, 结果表明输入的 PD 特征量的选取对识别准确率和泛化能力的影响较大, 但通过选择适当的内核和特征参数能够有效提高支持向量机在模式识别中的应用。优化算法同样能够提升支持向量机训练的结果, 文献[44]则通过粒子群算法优化参数的支持向量机对经过主成分分析提取特征的 4 种典型局部放电信号进行识别, 平均识别率在 94.43% 以上。文献[45]采用 PSO 求取放电特征不同的 SVM 最优核参数, 识别准确率达到 96.25%, 优于 BPNN 和只采用 RBF 作为核函数的 SVM, 如表 1 所示。

表 1 最优核函数组合

Tab.1 Optimized kernel grouping

放电特征	最优核函数
时域特征	RBF
频域特征	Sigmoid
统计特征	RBF
小波域特征	RBF

2.4 深度神经网络的应用

随着深度学习的发展, 神经网络在局部放电模式识别领域得到了有效的推广, 神经网络通常将特征提取与故障识别两部分同步训练。自编码器作为特征提取器, 被广泛用于模式识别的特征提取部分, 文献[46]采用稀疏自编码器实现基于相位分辨脉冲序列(PRPS)图谱的特征提取, 将输入

的 3 600 维降至 25 维, 将提取的特征用于 BPNN、SVM 以及极限学习机(ELM), 均获得了超过 82% 的识别准确率。通过自编码器和传统机器学习算法的结合, 相比于统计方法提取特征, 文献[47]表明自编码器提取的特征参量能够显著提升支持向量机、BP 神经网络和随机森林在 4 种典型缺陷上的识别准确率, 3 种人工智能算法分别提升了 40.22%、25.99% 和 29.72%。通过将自编码器与 softmax 层结合能够实现特征提取与故障识别同步训练, 文献[48]采用深度稀疏自编码器实现噪声条件下的特征提取, 采用 softmax 作为分类器实现模式识别, 准确率为 91%。文献[49]将经过变分模态分解(VMD)后的各个分量进行 Hilbert 变换得到相应的 Hilbert 边际谱作为输入, 采用稀疏自编码器实现特征提取和模式识别, 准确率高达 98%, 优于 SVM 和 BPNN。文献[50]采用堆叠稀疏自编码(SSAE)提取模态分解后的局部放电信号, 在最后一层加入 softmax 分类器实现模式识别, 4 种典型缺陷下的总识别率为 97%, 优于基于 PRPD 特征和 BP 神经网络组合的识别结果, 如图 12 所示。

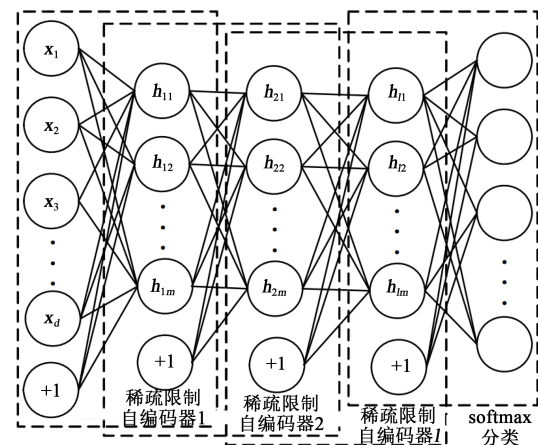


图 12 堆叠稀疏自编码

Fig.12 Stacked sparse autoencoding

卷积神经网络在局部放电模式识别领域的应用主要针对不同模式下局部放电信号的图像表征, 通过卷积层提取放电图像上的特征。文献[51]采用卷积神经网络对归一化后的 PRPS 图像进行识别, 在混合实验数据和现场数据的情况下, 4 种典型缺陷和干扰的识别准确率达到 86.7%, 高于准确率为 74.2% 的 SVM 和 70.2% 的 BPNN。文献[52]将灰度化和双线性插值归一化后的放电图像作为卷积神经网络输入, 在 4 种典型缺陷下的识别率均超过

94%, 结果同样优于结合统计因子与BPNN或SVM的识别结果。局放信号的去噪有助于进一步提升识别准确率, 文献[53]采用基于盲源分离的方式对放电超声信号时频图进行去噪处理, 对于去噪后的时频图采用卷积神经网络实现模式识别, 在学习率为0.0001时, 局部放电识别率均能达到90%以上, 高于SVM和kNN的结果。通过研究不同网络层数、不同激活函数以及不同池化方式对基于CNN识别效果的影响, 文献[54]指出采用swish函数作为激活函数性能较好, 识别准确率为90.67%, 且采用卷积神经网络的识别结果优于BPNN和SVM。

循环神经网络常用于处理序列类型数据, 放电信号属于典型的脉冲序列, 文献[55]采用长短期预测神经网络(LSTM)识别GIS 4种典型放电信号和噪声信号, 将PRPD信号一个电力周期内的128个数据点作为输入, 以5种信号类别的识别率作为输出, 以交叉熵作为代价函数标, 采用提前停止防止过拟合。识别结果表明LSTM在5种信号的识别率均优于线性支持向量机(SVM)、带有径向基函数的非线性SVM和BP神经网络, 但训练耗时最长。文末采用t-SNE对两层LSTM的向量空间进行可视化展示, 第二层LSTM能够有效地识别5种信号源的特征并区分开来, 如图13所示。




图13 LSTM不同层的t-SNE展示

Fig.13 The t-SNE representation of different LSTM layers

结合卷积神经网络和循环神经网络, 文献[56]采用CNN对UHF信号的时频图进行时域特征、频域特征和纹理特征的提取, 并将输出结果融合后作为LSTM的输入, 通过LSTM实现不同放电信号的模式识别, 如图14~15所示。文中对比了不同特征提取方案以及是否采用多传感器数据融合的模式识别, 认为多种特征提取和多传感器融合能够实现98.2%的最高识别准确率。文中将提取的50维特征向量通过t-SNE映射到三维空间上, 结果表明CNN提取的特征向量能够实现不同放电类型的有效区分。

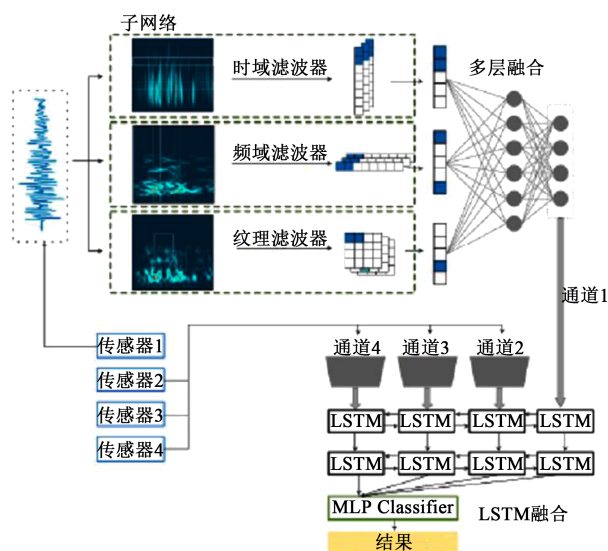


图14 多分辨率CNN和LSTM的融合

Fig.14 Fusion of multi-resolution CNN and LSTM

2.5 模糊分类器

区别于其他人工智能算法将分类结果确定为特定类别, 模糊分类器采用隶属度函数赋予多种放电类型不同的识别率, 识别率高者获胜。模糊性的存在提高了识别结果的泛化性能, 有助于工作人员基于自己的先验知识进行判断, 运用更加灵活。文献[57]采用模糊分类器分析PD脉冲的形状信息, 结果表明模糊分类器能够有效抑制噪声干扰。文献[58]则将模糊逻辑应用在不同空隙大小的放电脉冲波形, 采用梯度函数作为隶属度函数, 采用包含基于视在电荷迁移量、脉冲上升时间、下降时间、宽度和面积等特征的25条模糊规则进行模糊化处理以及去模糊化。在实际工程应用中, 文献[59]采用模糊算法对变压器、电缆以及旋转电机的PD源进行识别, 放电的PRPD图在该系统中被识别为具有不同概率的放电类型, 具有较好的鲁棒性。

模糊理论与聚类算法联合使用能够进一步提升聚类算法的分类结果, 常用于分离多源放电。文献[60]采用非支配排序遗传算法选取最优的4个特征子集, 采用模糊C均值聚类算法将脉冲从不同放电源中分离出来, 最大聚类精度达到92.33%。文献[61]采用模糊C均值聚类算法实现不同类型局部放电脉冲群的分类。对于提取S变换下UHF信号的时频特征, 文献[62]采用模糊C均值实现最高90.33%的聚类准确率。文献[63]通过双向改进模糊算法提取的特征参量进行聚类分析, 识别准确率为92.84%, 结果优于PCA和统计特征提取的

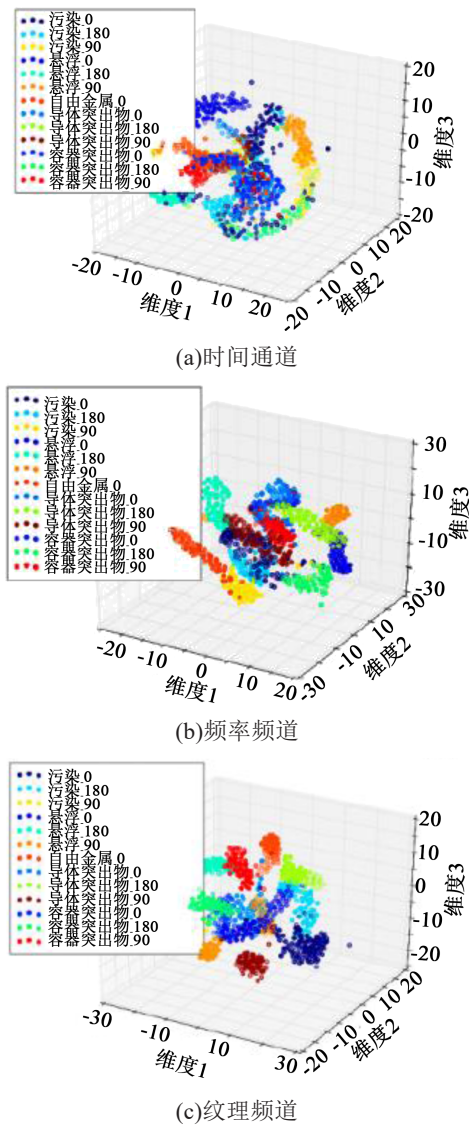


图 15 缺陷和位置的学习特征可视化

Fig.15 Visualization of the learned features for both the defects and positions

特征参量。当部分结果的隶属度较低时,舍弃这部分结果有助于进一步提高分类准确率,文献[64]将放电脉冲信号进行等效时频变换投影到二维平面上,在该平面上实现模糊聚类,当舍去隶属度低于70%的脉冲信号时,分类结果更加准确。与传统平面坐标系下的聚类不同,文献[17]在极坐标下采用K-means聚类实现不同放电类型的区分,识别准确率在80%以上,但对内部放电和沿面放电区分度不高。

2.6 集成学习

当上述人工智能算法训练结果达到瓶颈时,通过集成学习能够进一步提升效果。集成学习通过对已有的算法进行组合和优化,构建并组合多个学

习器完成学习任务。集成学习通过综合多个学习器的优势,识别结果通常优于单一学习器,且学习器种类的差异性能够提升集成学习的泛化能力。当前应用的集成学习算法主要有 Adaboost、Bagging、随机森林(RF)和集成神经网络(ENN)。Adaboost是一种自我优化过程,主旨思想为“亡羊补牢,为时不晚”,每一轮学习器后对训练样本的权重进行调整,对做错样本在后续过程提高训练权重,将最终训练得出的M个学习器进行加权组合。文献[65]采用 Adaboost 强化后的 BP 神经网络进行模式识别,结果优于单一的 BP 神经网络。文献[66]提取放电统计特征参数,用主成分分析(PCA)进行降维后,再用基于 Adaboost 的多感知器神经网络融合分类模型进行分类,识别准确率达 94.7%。文献[7]对比研究 Adaboost 与 SVM、模糊支持向量机(FSVM)、多层感知器(MLP)以及 RBFN 等人工智能算法在基于统计获取的特征向量以及不同降维算法得到的特征向量的模式识别结果,结果表明在绝大部分情况下 Adaboost 优于其他学习算法,在仅采用统计参量的情况下,识别准确率达到 95.8%,如表 2 所示。

Bagging 的主旨思想为“海纳百川,有容乃大”,通过有放回采样法, Bagging 算法分别训练生成不同学习器,最终决策采用投票选择,优中选优。文献[67]结合了 6 种神经网络,通过加权平均的策略进行输出,并与单个神经网络的结果进行比较,文中选择统计算子作为输入量,采用迭代次数、识别率和识别方差等作为评价指标。结果表明,在所有的缺陷类型中,集成神经网络的平均识别率均高于 95%,且集成神经网络具有较好的鲁棒性。文献[68]采用 5 个相同结构子神经网络组成的模块化神经网络,为每个子神经网络分配特定 PD 源识别任务,将结果与训练所有 PD 源的单个神经网络相比,模块化神经网络收敛更快且具有较高的识别准确率,训练准确率可达到 93.6% 以上。文献[69]先将基于统计分析得到的 108 个特征集分为 3 个互不交集的特征子集,分别采用子神经网络进行训练,采用 Bagging 投票决策进行集成,与单个神经网络进行对比,模块化神经网络训练速度更快,且泛化性能好。文中进一步对比了不同隐含神经元个数的影响,增加神经元个数对测试集的识别,准确率先上升后下降。针对 BP 神经网络和支持向量机两种算法,文献[70]对比采用了增强 Bagging、Bagging 和

表2 不同特征提取技术对分类器的分类准确率

	Statistical operators	PCA	FDA	KFDA	Kernal PCA	MDS	SPE	Isomap	SNE	LLE	NPE	LPP
SVM	92.1	95.7	96.1	91.9	94.7	95.5	84.2	97.2	95.8	95.5	88.3	93.3
KSVM	94.5	97.5	98.1	95.2	98.1	99.1	88.9	98.6	97.5	97.5	96.1	96.9
FSVM	95.6	97.8	98.1	96.7	98.9	99.4	90.5	98.6	98.3	97.8	96.7	98.1
FkNN	91.9	93.6	95.8	96.1	97.6	98.6	79.7	96.4	98.8	83.6	95.5	93.1
MLP	91.4	93.3	97.5	91.7	97.7	97.7	88.6	96.9	95.2	81.4	90.5	93.1
RBFN	95.3	96.9	97.7	95.8	98.6	96.9	89.3	92.8	93.1	95	90.8	97.8
PNN	93.6	95.3	98.1	92.8	96.1	96.4	85.0	96.1	93.6	82.7	88.1	96.1
Bayesian	94.7	96.1	97.2	96.4	96.4	97.8	90.2	96.9	94.4	96.1	91.1	95.8
Naïve-B	88.6	89.2	95.0	91.7	90.3	94.2	76.1	89.2	92.2	94.7	78.6	91.9
Adaboost	95.8	97.5	98.6	97.8	97.8	97.5	89.7	97.5	97.8	98.1	94.4	96.9

不采用 Bagging 3 种情况下 4 种典型缺陷类型的识别率,结果表明增强 Bagging 有助于提升识别准确率。

随机森林(RF)对决策树的识别结果进行集成,文献[71]采用随机森林算法以重采样的方式训练 k 个决策树,实验结果表明随机森林能够在白噪声干扰的环境下实现有无特定放电类型的区分,其性能优于 BPNN、SVM 和 K 近邻算法(KNN)。文献[72]研究了针板放电、沿面放电以及气隙放电 3 种放电类型的模式识别,在两类训练和测试样本集(样本 1 仅包含稳态放电数据,样本 2 包含起始状态和稳态)下,采用随机森林算法进行识别,并与最小二乘法支持向量机(LSSVM)的结果进行对比分析,结果表明随机森林在识别准确度和计算时间上优于 LSSVM,且包含起始状态数据集的识别准确率略低于只包含稳态放电数据的结果。

2.7 伪放电信号的生成

人工智能算法在局部放电的应用过程中,当优化算法和集成学习无法使模式识别的准确率进一步提高时,训练数据库的大小成为限制已有算法识别准确率的主要因素,相比于语音识别和图像处理等热门应用领域的数据库量,先前文献中的数据库含量只是沧海一粟。局部放电在线监测由于测试装置不同,不同的研究人员得出的 PD 信号存在固有差异性,局部放电的数据含量远远不足以保证训练得出的最优结果具有较好的泛化性能,因此进一步

提升识别准确率和泛化性能需要提高数据样本量。传统做法采用添加可变噪声(VNS)的方式提高数据含量,但先前的研究^[17,30-31,53]表明,在模式识别前,有效地去除噪声能够显著提高识别准确率,所以 VNS 的应用受到限制。随着生成对抗神经网络(GANs)在生成图像上的成功应用,GANs 通过学习原始数据特征进而生成新的数据,被广泛应用于增加数据库含量。文献[74]采用生成对抗网络学习 UHF 信号的深层特征并生成新的数据集,结果表明新数据集有助于提升分类器性能,且新数据集与实际数据集大小相等时识别准确率最高达到 95.67%,进一步增加新数据集将会降低识别准确率。文献[73]将 GANs 生成的数据用于模式识别,相比于只采用原始数据,添加等数据量的生成数据,在采用逻辑回归和支持向量机算法时,识别准确率分别提升了 1.72% 和 0.52%,与文献[74]的提升程度基本一致。

3 人工智能算法在状态评估中的应用

局部放电的演变过程以及严重性评估对于电力设备在线监测、状态评估以及对设备未来状态的预测至关重要。局部放电的严重性与设备的老化状态和残余寿命密切相关,能够反映电力设备状态的发展趋势。研究放电不同阶段的局放特征有助于及时发现潜在故障,人工智能算法常用于分析不同阶段的放电特征以研究局部放电的演变过程。其处理方法与模式识别采用的方式类似,将不同发

展阶段和不同严重性的局部放电视作不同类别的局部放电,因而先前有关模式识别的研究均可沿用。

聚类算法能够有效区分局部放电的不同发展阶段,文献[75]采用自适应阈值模糊聚类方法,按照统计参量因子将放电类别分为10类,分类结果分别对应于局部放电的不同发展阶段。相比于统计算子,降维后的特征向量能够提高训练效率和识别结果,文献[76]对PRPD中29个参量采用主成分分析法从不同层面提取总共12个主成分因子,发现不同老化状态的主成分特征向量存在差异性,能够实现油纸绝缘老化状态的聚类分析。文献[77]同样采用PCA提取统计算子中的主特征因子,采用最短距离的聚类分析,将不同的放电阶段分为初始放电阶段、放电发展阶段、放电稳定阶段和预击穿阶段。

神经网络和支持向量机能够有效区分不同老化阶段、污染状况下的局部放电信号,文献[78]从PD数据中提取特征,通过线性SVM实现电缆绝缘的不同老化状态识别,识别准确率达到95%。通过对电缆绝缘中具有气隙和电树特征的局部放电进行识别,文献[79]指出BP神经网络能够区分不同电树长度引起的放电脉冲,进而区分电缆的不同老化状态。文献[80]提出一种结合了粒子群算法的BP人工神经网络用于变压器绝缘老化状态评估,在无噪声的环境中,识别率超过94%。在添加30%噪声的情况下,仍然能够实现85%的识别率。不同污染颗粒与变压器油中放电的严重性密切相关,文献[81]采用支持向量机通过电信号和声信号对变压器油中某种污染颗粒的类型和尺寸进行确定,采用径向基函数作为内核,且采用二元粒子群优化算法对参数进行优化处理,优化参量为特征向量的大小、处理时间和粒子识别精度,对于声电联合测量的结果中污染颗粒的识别准确率达到100%,而只采用声信号和电信号的情况下,识别准确率分别达到84.167%和93.33%。文献[82]采用堆叠稀疏自编码器实现PD信号的特征提取,且提取的特征向量能够用于评价PD的严重性,其评估精度为92.2%,优于SVM的评估结果。

集成学习同样被用于不同放电阶段的识别,文献[83]采集油纸边界处 ρ - q - n 模式下不同施加电压下15 h内的PD数据,对于所有测试集,集成BP神经网络和单个神经网络均能区分前6 h和后9 h的PD模式,但ENN表现出更高的识别准确率和更低

的区分灵敏度,且能够捕获长时间放电模式下引起的微小变化。该作者在文献[84]继续研究了集成多层感知器、埃尔曼递归网络(ERNN)和RBFN的结果,识别准确率达到94.8%,优于单独的神经网络。基于局部放电二维图谱的统计算子和主成分分析提取了表征局部放电发展的六维特征量,文献[85]采用K-means聚类分析研究放电的不同发展阶段,结合随机森林算法集成多个分类器实现93.15%的识别准确率,结果优于RBF和SVM。

4 存在问题、解决策略及展望

人工智能算法在模式识别领域已经达到了接近100%的识别准确率,然而多数研究只是针对实验室的模型,实际运行中电力设备运行环境的差异导致模型算法的泛化性能较差,且不同学者间的研究缺乏标准的对照比较。通过总结本领域的研究进展,发现在模式识别和状态评估领域中仍存在不足之处,提出可行的解决策略及未来的研究方向。

(1)数据库的完备和含量对于人工智能算法的泛化能力至关重要,由于当前研究只针对单个设备或者实验室设计缺陷的测量结果,不同文献的训练样本间存在差异,训练得出的学习器难以直接应用于其他设备。后续研究需要构建联合局部放电数据库,保证放电信号的全面性和准确性,进而横向比较不同分类器的识别结果,提高训练分类器的泛化性能。

(2)不同放电缺陷类型测量数据量的差异性使得训练后的智能体偏向数据量大的缺陷类型,后续研究可通过GANs生成数据含量少的放电类型,或者训练学习器时分别对不同放电类型进行单独训练后集成。

(3)基于人工智能的诊断系统多采用脉冲电流法、超声波法和特高频检测法的数据,超高频法(SHF)的测量信号、放电光谱以及化学检测法很少使用。一方面由于不同局放检测方法对局放模式识别存在共性,后续研究可通过人工智能算法分析其中的相关性;另一方面多种测量结果的联合训练有助于实现对局部放电的全方位认知,不同检测方法提取的特征向量集合更适用于电力设备的状态检测。

(4)多特征向量的降维实现了局部放电训练准确性的提升,但经过人工智能算法降维之后的特征量与实际物理意义无法紧密结合。从已知物理含

义的特征向量中提取主要影响因素进行训练对于解释局部放电机理的差异性更为直观。

(5)深度学习在语音识别领域已经实现不同音色的区分,后续研究可借鉴其应用策略实现对多类型放电源共存时的有效区分。

(6)模式识别以其区分度明显和数据量大等优势易于取得成果,而当前研究中有关状态预测领域的内容较少。LSTM在诸如语音处理和电力负荷预测等方面得到了重要进展,后续研究可采用LSTM实现对局部放电特征量的有效预测,进而实现对电力设备状态的主动预警。

(7)局部放电的影响因素和局部放电测量结果间存在一定相关性,电力设备含水量和热点温度是影响局部放电严重性的重要因素。通过局放结果反演得到设备含水量和热点温度等特征信息有助于解决特殊情况下理化特性难以获取的难题。

参考文献:

- [1] 王昌长,李福祺,高胜友. 电力设备的在线监测与故障诊断[M]. 北京:清华大学出版社,2006.
- [2] BARTNIKAS R. Partial discharges - Their mechanism, detection and measurement[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2002,9(5):763-808.
- [3] SAHOO N C, SALAMA M M A, BARTNIKAS R. Trends in partial discharge pattern classification: A survey[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2005,12(2):248-264.
- [4] RAYMOND W J K, ILLIAS H A, BAKAR A H A, et al. Partial discharge classifications: Review of recent progress[J]. Measurement,2015,68:164-181.
- [5] MASUD A A, ALBARRACIN R, ARDILA-REY J A, et al. Artificial neural network application for partial discharge recognition: Survey and Future Directions[J]. Energies,2016(9):574.
- [6] MONDAL M, KUMBHAR G B. Detection, measurement, and classification of partial discharge in a power transformer: Methods, trends, and future research[J]. IETE Technical Review,2018, 35(5):483-493.
- [7] JANANI H, KORDI B. Towards automated statistical partial discharge source classification using pattern recognition techniques [J]. High Voltage,2018,3(3):162-169.
- [8] BARRIOS S, BULDAIN D, COMECH M P, et al. Partial discharge classification using deep learning methods-Survey of recent progress[J]. Energies,2019,12(13):2485.
- [9] 李军浩,韩旭涛,刘泽辉,等. 电气设备局部放电检测技术述评[J]. 高电压技术,2015,41(8):2583-2601.
- [10] 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.
- [11] 刘云鹏,许自强,李刚,等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术,2019,45(2): 337-348.
- [12] 陆云才,范路,陶风波,等. 人工智能在局部放电检测中的应用(一):去噪与故障定位[J]. 绝缘材料,2021,54(5):10-20.
- [13] 周志华. 机器学习[M]. 北京:清华大学出版社,2016:229-232.
- [14] 张济忠. 分形[M]. 北京:清华大学出版社,2011:111-122.
- [15] ZHU M X, ZHANG J N, LI Y, et al. Partial discharge signals separation using cumulative energy function and mathematical morphology gradient[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2016,23(1):482-493.
- [16] RAHMAN M K A, ARORA R, SRIVASTAVA S C. Partial discharge classification using principal component transformation [J]. IEE Proceedings-Science Measurement and Technology, 2000,147(1):7-13.
- [17] 靖小平,彭小圣,姜伟,等. 基于K-Means聚类算法的自动图谱识别在电缆局部放电在线监测系统中的应用[J]. 高电压技术, 2012,38(9):2437-2446.
- [18] CANDELA R, MIRELLI G, SCHIFANI R. PD recognition by means of statistical and fractal parameters and a neural network [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2000,7(1):87-94.
- [19] 任晓琨. GIS局部放电故障智能识别技术的研究[D]. 天津:河北工业大学,2014.
- [20] 印华,方志,张小勇,等. 根据UHF信号特征的GIS局部放电模式识别[J]. 高压电器,2005,41(1):19-20.
- [21] SATISH L, ZAENGL W S. Can fractal features be used for recognizing 3-d partial discharge patterns[J]. IEEE Transactions on Dielectrics and Electrical Insulation,1995,2(3):352-359.
- [22] KRIVDA A, GULSKI E, SATISH L, et al. The use of fractal features for recognition of 3-D discharge patterns[J]. IEEE Transactions on Dielectrics and Electrical Insulation,1995,2(5):889-892.
- [23] 杜伯学,魏国忠. 基于小波与分形理论的电力设备局部放电类型识别[J]. 电网技术,2006,30(13):76-80.
- [24] 李燕青,陈志业,律方成,等. 超声波法进行变压器局部放电模式识别的研究[J]. 中国电机工程学报,2003,23(2):112-115.
- [25] CHANG W Y. Partial discharge pattern recognition using radial basis function neural network[C]//2010 Asia-Pacific Power and Energy Engineering Conference. Chengdu, China: IEEE, 2010: 28-31.
- [26] 孟延辉,唐炬,周倩,等. 基于 Δu 模式和RBF网络的局部放电模式识别[J]. 重庆大学学报(自然科学版),2006,29(11):41-44.
- [27] 李剑,王小维,金卓睿,等. 变压器局部放电超高频信号多尺度网格维数的提取与识别[J]. 电网技术,2010,34(2):159-163.
- [28] 孙才新,许高峰,唐炬,等. 以盒维数和信息维数为识别特征量的GIS局部放电模式识别方法[J]. 中国电机工程学报,2005,25 (3):102-106.
- [29] 刘玲,廖瑞金,周淙,等. 基于放电时差的局部放电模式识别的研究[J]. 高电压技术,2007,33(8):35-39.
- [30] 侯慧娟,盛戈峰,孙旭日,等. 变电站多局部放电源分离的选择双谱算法[J]. 电网技术,2014,38(5):1379-1384.
- [31] HOU H J, SHENG G H, LI S F, et al. A novel algorithm for separating multiple PD sources in a substation based on spectrum

- reconstruction of UHF signals[J]. IEEE Transactions on Power Delivery,2015,30(2):809-817.
- [32] 罗新,牛海清,来立永,等.粒子群优化自适应小波神经网络在带电局放信号识别中的应用[J].电工技术学报,2014,29(10):326-333.
- [33] GULSKI E, KRIVDA A. Neural networks as a tool for recognition of partial discharges[J]. IEEE Transactions on Electrical Insulation,1993,28(6):984-1001.
- [34] 苑津莎,尚海昆.基于主成分分析和概率神经网络的变压器局部放电模式识别[J].电力自动化设备,2013,33(6):27-31.
- [35] KARTHIKEYAN B, GOPAL S, VENKATESH S. Partial discharge pattern classification using composite versions of probabilistic neural network inference engine[J]. Expert Systems with Applications,2008,34(3):1938-1947.
- [36] 弓艳朋,刘有为,吴立远.采用分形和支持向量机的气体绝缘组合电器局部放电类型识别[J].电网技术,2011,35(3):135-139.
- [37] ROBLES G, PARRADO H E, ARDILA R J, et al. Multiple partial discharge source discrimination with multiclass support vector machines[J]. Expert Systems with Application,2016,55:417-428.
- [38] HAO L, LEWIN P L. Partial discharge source discrimination using a support vector machine[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2010,17(1):189-197.
- [39] 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.
- [40] ZHOU W J, LIU Y S, LI P F, et al. Feature parameters extraction of power transformer PD signal based on texture features in TF representation[J]. IET Science Measurement & Technology 2017,11(4):445-452.
- [41] 律方成,金虎,王子建,等.基于主成分分析和多分类相关向量机的GIS局部放电模式识别[J].电工技术学报,2015,30(6):225-231.
- [42] 韩宝国,马驰,李静鹏,等.基于DTCWT与LLE算法的变压器局部放电特高频信号特征参数提取方法[J].电力系统保护与控制,2019,47(20):65-72.
- [43] HAO L, LEWIN P L, DODD S J. Comparison of support vector machine based partial discharge identification parameters[C]//Conference Record of the 2006 IEEE International Symposium on Electrical Insulation. Toronto,Canada:IEEE,2006.
- [44] 廖瑞金,袁磊,汪可,等.基于S变换和双向二维主成分分析的局部放电模式识别[J].重庆大学学报,2013,36(5):56-63.
- [45] 王瑜,苑津莎,尚海昆,等.组合核支持向量机在放电模式识别中的优化策略[J].电工技术学报,2015,30(2):229-236.
- [46] 何金,曹梦,王伟,等.基于稀疏自编码和极限学习机的局部放电模式识别[J].高压电器,2018,54(11):295-300.
- [47] LI S Y, MAN Y Y, ZHANG C, et al. PRPD data analysis with Auto-Encoder Network[C]//E3S Web of Conferences. Munich, Germany:EDP Sciences,2019:81.
- [48] 郗晓光,何金,曹梦,等.基于深度稀疏降噪自编码网络的局部放电模式识别[J].电气自动化,2018,40(4):115-118.
- [49] 高佳程,朱永利,郑艳艳,等.基于Hilbert边际谱和SAE-DNN的局部放电模式识别方法[J].电力系统自动化,2019,43(1):87-97.
- [50] 高佳程,朱永利,郑艳艳,等.基于VMD-WVD分布与堆栈稀疏自编码网络的局放类型识别[J].中国电机工程学报,2019,39(14):4118-4129.
- [51] 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.
- [52] 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.
- [53] 张重远,岳浩天,王博闻,等.基于相似矩阵盲源分离与卷积神经网络的局部放电超声信号深度学习模式识别方法[J].电网技术,2019,43(6):1900-1907.
- [54] 杨帆,王干军,彭小圣,等.基于卷积神经网络的高压电缆局部放电模式识别[J].电力自动化设备,2018,38(5):123-128.
- [55] NGUYEN M T, NGUYEN V H, YUN S J, et al. Recurrent neural network for partial discharge diagnosis in gas-insulated switchgear[J]. Energies,2018(11):1202.
- [56] LI G Y, WANG X H, LI X, et al. Partial Discharge recognition with a multi-resolution convolutional neural network[J]. Sensors, 2018,18(10):3512.
- [57] CONTIN A, CAVALLINI A, MONTANARI G C, et al. Digital detection and fuzzy classification of partial discharge signals[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2002, 9(3):335-348.
- [58] SALAMA M M A, BARTNIKAS R. Fuzzy logic applied to PD pattern classification[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2000,7(1):118-123.
- [59] CAVALLINI A, MONTANARI G C, PULETTI F, et al. A new methodology for the identification of PD in electrical apparatus: Properties and applications[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2005,12(2):203-215.
- [60] WANG K, LIAO R J, YANG L J, et al. Optimal features selected by NSGA-II for partial discharge pulses separation based on time-frequency representation and matrix decomposition[J]. IEEE Transactions on Dielectrics and Electrical Insulation,2013, 20(3):825-838.
- [61] 鲍全胜,郝峰杰,徐建忠,等.GIS局部放电脉冲分类特征提取算法[J].电工技术学报,2016,31(9):181-188.
- [62] 汪可,廖瑞金,王季宇,等.局部放电UHF脉冲的时频特征提取与聚类分析[J].电工技术学报,2015,30(2):211-219.
- [63] 汪可,廖瑞金,吴高林,等.采用双向改进模糊2DLDA算法提升多因素影响的局部放电识别可靠性[J].电工技术学报,2014,29(11):210-220.
- [64] 杨丽君,孙才新,廖瑞金,等.采用等效时频分析及模糊聚类法识别混合局部放电源[J].高电压技术,2010,36(7):1710-1717.
- [65] 张波,刘成国,徐忠,等.小波去噪对提高GIS超声局部放电信号识别率的研究[J].电气工程学报,2017,12(11):41-45.
- [66] 徐颖敏,姚林朋,钱勇,等.基于多分类器融合的XLPE电缆局部放电模式识别研究[J].电气自动化,2011,33(3):74-76.
- [67] MASUD A A, STEWART B G, MCMEEKIN S G. Application of an ensemble neural network for classifying partial discharge patterns[J]. Electric Power Systems Research,2014,110:154-162.

- [68] HONG T, FANG M T C, HILDER D. PD classification by a modular neural network based on task decomposition[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 1996, 3(2): 207-212.
- [69] HONG T, FANG M T C. Detection and classification of partial discharge using a feature decomposition-based modular neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2001, 50(5): 1349-1354.
- [70] JIANG T Y, LI J, ZHENG Y B, et al. Improved bagging algorithm for pattern recognition in UHF signals of partial discharges [J]. Energies, 2011(4): 1087-1101.
- [71] 程养春,张振亮.基于随机森林的变压器多源局部放电诊断[J].中国电机工程学报,2018,38(17):5246-5256.
- [72] SI W, LI S M, XIAO H S, et al. Defect pattern recognition based on partial discharge characteristics of oil-pressboard insulation for UHVDC converter transformer[J]. Energies, 2018(11): 592.
- [73] WU Y J, LU C, WANG G J, et al. Partial discharge data augmentation of high voltage cables based on the variable noise superposition and generative adversarial network[C]//2018 International Conference on Power System Technology. Guangzhou, China: IEEE, 2018.
- [74] WANG X H, HUANG H Y, HU Y, et al. Partial discharge pattern recognition with data augmentation based on generative adversarial networks[C]//2018 Condition Monitoring and Diagnosis. Western, Australia: IEEE, 2018: 1-4.
- [75] 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.
- [76] 廖瑞金,杨丽君,孙才新,等.基于局部放电主成分因子向量的油纸绝缘老化状态统计分析[J].中国电机工程学报,2006,26(14):114-119.
- [77] 陈伟根,蔚超,凌云,等.油纸绝缘气隙放电特征信息提取及其过程划分[J].电工技术学报,2011,26(4):7-12.
- [78] MORETTE N, DITCHI T, OUSSAR Y. Partial discharges measurements and analysis as an evaluation tool for the reliability of polymeric-insulated cables used under HVDC Conditions[C]//2018 IEEE 2nd International Conference on Dielectrics. Budapest, Hungary: IEEE, 2018: 1-4.
- [79] MAZROUA A A, BARTNIKAS R, SALAMA M M A. Neural network system using the multi-layer perceptron technique for the recognition of PD pulse shapes due to cavities and electrical trees[J]. IEEE Transactions on Power Delivery, 1995, 10(1): 92-96.
- [80] KUO C C. Artificial identification system for transformer insulation aging[J]. Expert Systems with Applications, 2010, 37(6): 4190-4197.
- [81] IBRAHIM K, SHARKAWY R M, SALAMA M M A, et al. Realization of partial discharge signals in transformer oils utilizing advanced computational techniques[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2012, 19(6): 1971-1981.
- [82] TANG J, JIN M, ZENG F P, et al. Assessment of PD severity in gas-insulated switchgear with an SSAE[J]. IET Science, Measurement & Technology, 2017, 11(4): 423-430.
- [83] MASUD A A, STEWART B G, MCMEEKIN S G, et al. Partial discharge pattern classification for an oil-pressboard interface [C]//Conference Record of IEEE International Symposium on Electrical Insulation. San Juan, USA: IEEE, 2012: 122-126.
- [84] MASUD A A, STEWART B, MCMEEKIN S G, et al. An ensemble neural network for recognizing PD patterns[C]//45th International Universities Power Engineering Conference. Cardiff, UK: IEEE, 2010.
- [85] 陈伟根,龙震泽,谢波,等.不同气隙尺寸的油纸绝缘气隙放电特征及发展阶段识别[J].电工技术学报,2016,31(10):49-58.