

DOI:10.19651/j.cnki.emt.2106822

# 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

王卓 朱宁宁 郑祥

(大连交通大学 电气信息工程学院 大连 116028)

**摘要:** 针对传统信号特征提取方法存在高维数和无效信息过多的问题,提出了一种基于线性判别算法和径向基神经网络的开关柜局部放电模式识别方法。该方法将两种算法结合,达到识别速率和识别准确率双优的目的。首先,建立开关柜的3种超声波局部放电(PD)模型。然后,利用时频分析和小波分解,提取信号的时频特征和小波系数特征,通过线性判别算法(LDA)对提取的特征向量进行降维处理,最后利用径向基(RBF)神经网络对局部放电缺陷类型进行分类,其识别准确率均在90%以上,并且训练时间缩减50%以上,证明该识别方法具有实用性。

**关键词:** 局部放电模式识别;径向基神经网络;线性判别算法;小波降噪

**中图分类号:** TM933 **文献标识码:** A **国家标准学科分类代码:** 510.1050

## Research on partial discharge pattern recognition method of switchgear based on LDA and RBF neural network

Wang Zhuo Zhu Ningning Zheng Xiang

(School of Electrical Information Engineering, Dalian Jiaotong University, Dalian 116028, China)

**Abstract:** Aiming at the problems of high dimensionality and too much invalid information in traditional signal feature extraction methods, this paper proposes a switchgear partial discharge pattern recognition method based on linear discriminant algorithm and radial basis neural network. This method combines the two algorithms to achieve the purpose of both the recognition rate and the recognition accuracy. First, establish three ultrasonic partial discharge (PD) models of the switchgear. Then, time-frequency analysis and wavelet decomposition are used to extract the time-frequency features and wavelet coefficient features of the signal, and the extracted feature vectors are reduced by linear discriminant algorithm (LDA). Finally, the radial basis basis (RBF) neural network is used to analyze the local the types of discharge defects are classified, and the recognition accuracy is above 90%, and the training time is reduced by more than 50%, which proves that the recognition method is practical.

**Keywords:** partial discharge pattern recognition; radial basis function neural network; linear discrimination algorithm; wavelet denoising

## 0 引言

开关柜是在电力系统进行发电、输电、配电和电能转换的过程中,常见的一类电气设备。开关柜在运行过程中由于绝缘老化或者受外界其他因素影响,会产生绝缘缺陷,导致局部放电的产生。由此,对于局部放电模式和缺陷类型的识别显得尤为重要,是避免电力系统发生事故的重要手段之一。在众多检测方法中,超声波检测法由于与高压设备之间没有直接的电气联系,因此具有灵敏度高、抗干扰性强和可靠性高等优点,同时随着近些年超声波传感器灵敏

度的不断提高,超声波检测法在局部放电信号的检测和绝缘诊断方面有广泛应用<sup>[1-4]</sup>。

不同类型的开关柜局部放电其超声波放电波形有一定的差别,故可利用这一特点进行局部放电模式识别。传统的局部放电信号特征量提取的参数可达30多个<sup>[5]</sup>,通过数据挖掘算法可以对特征量进行降维处理,如文献[6]对图像、统计和分形这3个方面进行特征提取,提取27个特征量,进一步通过BP神经网络进行局部放电模式识别;文献[7]根据信号波形提取了26个特征量,为获得更快的数据处理速度,进一步采用主成分分析法(PCA)进行特征

收稿日期:2021-06-01

量降维得到10个新的特征量。通过对一些文献的研究表明日前对于高维数的局部放电信号特征量降维并没有形成一个统一的标准,但局部放电信号特征值降维处理对于局部放电模式识别十分重要。

同时,局部放电模式识别的算法越来越多,如K近邻法(k-nearest neighbour, KNN)<sup>[8]</sup>、支持向量机法(support vector machine, SVM)<sup>[9-13]</sup>、BP神经网络法<sup>[14]</sup>等。KNN模式识别算法准确率受近邻数目K的影响,且没有考虑到不同样本之间的差异性<sup>[15]</sup>;SVM是目前使用较为热门的一类识别算法,识别能力较好。但存在着核函数及其系数确定困难的缺点<sup>[10,12]</sup>,且传统SVM模式识别算法为二分类识别算法,对于局部放电模式识别这类多分类识别问题,需要多个SVM分类器或与其他识别算法相结合方能达到较好的识别效果;BP神经网络作为局部放电模式识别应用最广泛的算法之一,其收敛较慢且易陷入局部最优,影响局部放电模式识别的效果<sup>[16]</sup>。

基于以上问题,本文提出了一种基于LDA和RBF神经网络的局部放电模式识别方法:对仿真的局部放电信号,先进行特征提取,接着采用LDA对特征参量进行降维处理最后利用RBF神经网络进行分类。

## 1 LDA降维算法原理

LDA是一种常用的数据降维算法,其原理是将带标签的数据通过投影到维度更低的空间中,使投影后的数据类内方差最小,类间方差最大,以得到较好的降维效果。LDA算法的基本原理如下。

已有数据集  $\mathbf{D} = (x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$ , 其中样本  $x_i$  为任意  $n$  维向量,类别  $y_i \in C_1, C_2, \dots, C_k$ , 定义  $N_{j(j \in 1, 2, \dots, k)}$  是第  $j$  类的样本个数,  $X_{j(j \in 1, 2, \dots, k)}$  是第  $j$  类样本集合,  $\mu_{j(j \in 1, 2, \dots, k)}$  是第  $j$  类样本的均值,  $\sigma_j$  是第  $j$  类样本的均方差,下面以简述其算法原理  $\mu_j$  的表达式如式(1)所示。

$$\mu_j = \frac{1}{N_j} \sum_{x \in X} x \quad (1)$$

式中:  $j \in \{0, 1, \dots, j\}$ 。  $\sigma_j$  的表达式如式(2)所示。

$$\sigma_j = \sum_{x \in X} (x - \mu_j)(x - \mu_j)^T \quad (2)$$

式中:  $j \in \{0, 1, \dots, j\}$ , 将其降维。寻找一个向量  $w$ , 样本中心投影之后如式(3)所示。

$$\mu_{wj} = w\mu_j \quad (3)$$

定义散度矩阵如式(4)所示。

$$\mathbf{S}_w = \sum_{j=1}^k \sum_{x \in X} (x - \mu_j)(x - \mu_j)^T \quad (4)$$

上述公式用来表示各个类内数据点聚集程度。定义类间散度矩阵如式(5)所示。

$$\mathbf{S}_b = \sum_{j=1}^k N_j (\mu_j - u)(\mu_j - u)^T \quad (5)$$

上述公式用于表示不同类的分散程度。此时设投影到

的低维空间维度为  $d$ , 对应的基向量为  $w_1, w_2, \dots, w_d$ , 构成矩阵  $w$  函数  $J$ , 如式(6)所示。

$$J = \frac{w^T \mathbf{S}_b w}{w^T \mathbf{S}_w w} \quad (6)$$

由于分子和分母都是关于  $w$  的二次项, 不失一般性, 可以设式(7):

$$w^T \mathbf{S}_w w = 1 \quad (7)$$

求  $J$  的最大值就可以转换为式(8)和(9):

$$\min_w -w^T \mathbf{S}_b w \quad (8)$$

$$\text{s. t. } w^T \mathbf{S}_w w = 1 \quad (9)$$

运用拉格朗日乘法可得式(10):

$$\mathbf{S}_w^{-1} \mathbf{S}_b w = \lambda w \quad (10)$$

此时函数有最大值。所以取前  $d$  个最大的特征值对应的特征向量组成  $w$ 。由于  $\mathbf{S}_b$  是  $k$  个秩为 1 的矩阵相加而成, 所以其秩小于等于  $k$ 。最后一个  $u_k$  可以由前  $k-1$  个表示, 因此, LDA 降维算法降维之后的维度最高为  $k-1$ 。

## 2 RBF神经网络

RBF神经网络是在20世纪80年代Moody和Darken提出了一种以函数逼近为基础的神经网络结构模型, 也被称作径向基函数网络。在这种结构模型中具有单个隐含层的3层前馈神经网络, 由输入层、具有径向基函数神经元的隐含层和输出层构成。 $n$  维样本输入  $m$  维输出的RBF神经网络结构如图1所示。




图1 RBF神经网络结构

RBF神经网络的基本思想是通过隐单元的“基”构成隐藏层空间, 对输入矢量进行变换, 将低维的模式输入数据变换到高维空间内, 使得在低维空间内的线性不可分问题在高维空间内线性可分。在确定RBF中心点  $C_{ij}$  之后, 这种映射关系随之确定。在结构图中,  $C_{ij}$  和  $D_{ij}$  表示隐含层空间的中心参数和宽度向量, 这两个参数可以随机产生,  $W_{kj}$  表示隐含层与输出层之间连接的权值。输入矢量表示为  $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ , 隐含层节点的激活函数可以表示为  $\varphi_j(x)$ , 其中  $j = 1, 2, \dots, p$ , 在日前的应用性上, 隐含层神经元的核函数多数采用高斯核函数, 如式(11)所示。

$$G_j(x_i) = \exp\left(-\frac{\|x_i - c_j\|^2}{\sigma_j^2}\right) \quad (11)$$

式中:  $G_j(x_i)$  为隐含层中第  $j$  个神经元输出,  $i, j$  分别代表样本数量和隐含层数;  $c_j$  代表网络数据中心, 且与  $\mathbf{X}$  的维数相同;  $\sigma_j^2$  代表高斯函数的方差;  $\|x_i - c_j\|$  代表欧氏范数。

根据计算可得到 RBF 神经网络的中心点、宽度以及权值表达式如下所示:

$$\Delta c_j = \eta_1 \frac{\omega_j}{\sigma_j^2} \sum_{i=1}^n e_j G(x_i)(x_i - c_j) \quad (12)$$

$$\Delta \sigma_j = \eta_2 \frac{\omega_j}{\sigma_j^3} \sum_{i=1}^n e_j G(x_i) \|x_i - c_j\|^2 \quad (13)$$

$$\Delta w_j = \eta_3 \sum_{i=1}^n e_j G(x_i) \quad (14)$$

算法的学习步骤如下:

1) 确定输入输出参数

(1) 确定输入量  $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ ,  $n$  为输入层节点个数。

(2) 确定输出向量  $\mathbf{Y}$  输出量表示为  $\mathbf{Y} = [y_1, y_2, \dots, y_m]^T$ 。

2) 参数计算

(1) 隐含层与输出层连接权值, 计算方法如式 (15) 所示。

$$W_{kj} = k_{\min} + j \frac{k_{\max} - k_{\min}}{m + 1} \quad (15)$$

式中:  $k_{\min}$  和  $k_{\max}$  为样本数集中的第  $k$  个输出神经元中期望输出的最小数值和最大数值。

(2) 隐含层中各神经元的中心参数, 计算方法如式 (16) 所示。

$$C_{ij} = i_{\min} + \frac{i_{\max} - i_{\min}}{2p} + (j - 1) \frac{i_{\max} - i_{\min}}{p} \quad (16)$$

式中:  $j = 1, 2, \dots, p$ 。

(3) 宽度向量计算方法如式 (17) 所示。

$$D_{ij} = d_f \sqrt{\frac{1}{n} \sum_{k=1}^n (x_i^k - c_{ij})^2} \quad (17)$$

式中:  $d_f$  是宽度调节系数, 取值范围为  $[0, 1]$ 。

(4) 计算隐含层第  $j$  个神经元的输出值  $\varphi_j$  为式 (18):

$$\varphi_j = \exp\left(-\left\|\frac{x_i - C_j}{D_j}\right\|^2\right) \quad (18)$$

式中:  $C_j$  表示隐含层第  $j$  个神经元的中心值。

3) 输出计算

输出层输出值  $y_k$  计算如式 (19) 所示。

$$y_k = \sum_{j=1}^p w_{kj} \varphi_j \quad (19)$$

式中:  $k = 1, 2, \dots, m$ 。

### 3 信号仿真与特征提取

#### 3.1 局部放电信号建立

为了验证本文提出的识别方法普遍性, 下文对开关柜典型局部放电类型的气隙放电、表面金属污秽放电和金属突出物放电模型 3 类故障进行数学模型建立, 对应信号波形如图 2 所示。

设定信号模型的采样频率为 10 MHz, 每个局放信号包 10 000 个采样点, 每个采样点间时间间隔为 0.1  $\mu$ s。为模拟真实的现场采集局放信号, 在每个局放信号中加入信




图 2 典型局放信号波形

噪比为 10 dB 的白噪声, 和 25 k、60 k、120 k、180 k、200 k 的窄带干扰。接下来利用 MATLAB 软件随机生成每类局放信号 200 组, 一共 600 组局放信号矩阵, 对应信号波形如图 3 所示。




图 3 混合噪声局放信号波形

#### 3.2 信号去噪

本文对于局部放电去噪的方法采用小波软阈值去噪法, 其去噪过程为主要分为 3 个部分:

- 1) 分解: 选择特定小波对信号进行小波分解。
- 2) 小波系数估计: 对分解的各层系数进行阈值处理, 获得估计小波系数。
- 3) 重构: 对去噪后的小波系数进行小波重构, 获得去噪后的信号。

在对信号进行小波分解时需要选择合适的小波基, 通常选择 db 小波和 Sym 小波, 同时需要确定合适的分解层数, 分解的层数取得越大, 则噪声和信号表现的不同特性越明显, 越有利于二者的分离。但是分解的层数越大, 经过重构的信号失真也会越大, 在一定程度上会对信号去噪的效

果产生较差的影响。最后是阈值的选择,在小波域,有效信号对应的系数很大,而噪声对应的系数很小并且仍满足高斯分布。因此可以通过设定阈值将信号在小波域某段区间内的系数置零,就能最大程度的抑制噪声,同时只是稍微损伤有效信号。

基于以上的分析,最终确定本次实验采用db4小波,进行3层小波分解采用软阈值函数。

当小波系数的绝对值大于给定阈值时,令小波系数减去阈值;小于阈值时,小波系数置0,公式如下:

$$w_{is} = \begin{cases} [\text{sgn}(w)](|w| - thr), & |w| \geq thr \\ 0, & |w| < thr \end{cases} \quad (20)$$

去噪后的对应信号波形如图4所示。

### 3.3 信号特征提取

绝缘缺陷引起的局放信号具有明显的随机性,本文一共提取了局部放电信号的30个特征,以用于后面的特征向量降维,分别提取了信号时域特征、频域特征以及小波分解后提取小波分解特征,其中时域特征包括平均值、有效值、峰值、峰值因子、峭度、波形因子、脉冲因子、裕度因子,频域特征包括平均频率、重心频率、频率均方根、频率标准差,小波分解特征包括8个子带的小波能量比和它们之间的小波




图4 局放信号去噪波形

能量熵、8个子带的小波熵和它们之间的小波奇异熵。

其部分信号特征,时域特征的脉冲因子  $I$ ,裕度因子  $L$ ,频域特征的平均频率  $F_{RMSF}$ ,频率标准差  $F_{RVF}$ ,小波分解系数的小波能量熵  $E$ ,小波奇异熵  $Q$  这些信号特征如表1所示。

表1 部分信号特征

识别类型	$I$	$L$	$F_{RMSF}$	$F_{RVF}$	$E$	$Q$
气隙放电	19.273	25.698	$9.453 \times 10^4$	$7.154 \times 10^4$	0.285 1	0.931 4
表面金属污秽放电	21.805	30.277	$7.328 \times 10^4$	$5.936 \times 10^4$	0.161 7	1.083 9
金属突出物放电	45.688	49.049	$6.187 \times 10^4$	$6.598 \times 10^4$	0.514 0	1.155 1

## 4 算法性能测试

### 4.1 基于LDA的特征提取

利用LDA对提取的30个特征矩阵进行降维处理,将

数据降维为5维,包含原来的95%以上的特征,经LDA降维后信号特征如表2所示。

表2 LDA降维信号特征

识别类型	$Fea1$	$Fea2$	$Fea3$	$Fea4$	$Fea5$
气隙放电	$5.484 \times 10^{-13}$	0.878 8	$-4.991 \times 10^1$	$-1.121 \times 10^1$	$-9.968 \times 10^3$
表面金属污秽放电	$1.288 \times 10^{-12}$	1.783 0	$-1.012 \times 10^3$	$-2.275 \times 10^1$	$-1.400 \times 10^1$
金属突出物放电	$-3.735 \times 10^{-12}$	$-4.493 2$	$2.552 \times 10^3$	$5.733 \times 10^4$	$5.096 \times 10^4$

### 4.2 基于RBF的局部放电模式识别

本文采用RBF神经网络构建分类模型。首先,选取3类每类150个样本作为输入的训练样本进行训练,每次随机打乱实验数据投入模式识别模型,进行局部放电类型的分类训练。每一轮训练随机产生数据中心值和宽度计算隐含层输出值,将实际输出与期望值的差值作为计算误差,将计算误差与提前设定的标准误差  $\epsilon$  进行比较。如果不满足设定的误差需求,则进行下一轮训练,直到找到最佳的模型参数,将模型参数进行保存,以备测试时使用。

测试数据中3类局部放电数据各取50个样本,测试每类样本局部放电模式识别的准确性。首先,对局部放电测试数据进行归一化,随机打乱实验数据投入模式识别模型进行局部放电类型的分类实验,读取训练保存的模型参数,并对归一化的数据进行分类判别,找出判断错误个体所属的类别。然后,输出每类局部放电数据的判别准确率。其识别结果如图5所示。

### 4.3 识别结果对比

将本文局部放电识别方法与BP神经网络、支持向量机识别方法进行比较,实验结果如表3和4所示。




图 5 识别结果

表 3 识别准确率对比

局放信号类型	正确率/%		
	BP 识别	SVM 识别	LDA 降维 RBF 识别
气隙放电	90	84	90
表面金属污秽放电	86	90	90
金属突出物放电	88	86	94

表 4 识别速率对比

局放信号类型	识别时间 t/s	
	未降维 RBF 识别	LDA 降维 RBF 识别
气隙放电	1.241 7	0.582 45
表面金属污秽放电	1.398 2	0.546 28
金属突出物放电	1.971 2	0.551 48

由实验结果可以看出采用 LDA 降维后的识别准确率相比原始特征数据识别结果有一定程度改善且识别速率更快。运用 RBF 模式识别与 LDA 特征降维结合实现了开关柜局放信号在线高效、可靠的识别。

### 5 结 论

本文通过对开关柜局放信号进行特征提取,通过 LDA 进行局放特征降维,由降维后的局放特征组成 RBF 神经网络模式识别算法的训练样本,最后通过 RBF 算法验证识别的准确度。结果表明 LDA 降维效果十分优良,不仅可以很好地保留局放特征,同时可以极大缩减局部放电模式识别的时间。相比于未降维的特征通过 BP 神经网络和支持向量机的,降维后的局放特征通过 RBF 神经网络算法可以准确地识别 3 种不同绝缘缺陷类型,识别准确率有一定的提高,且准确率均在 90% 以上,为开关柜绝缘缺陷类型识别提出了参考依据。

### 参考文献

[1] 徐卫东,聂一雄,周文文,等. 固体绝缘开关柜局部放电模式识别优化算法[J]. 高压电器, 2019, 55(5): 100-107.  
 [2] 郑祥,管鹏,田伟. 基于超声波局部放电信号的开关

柜绝缘缺陷类型识别[J]. 电子测量技术, 2020, 43(16): 124-127.  
 [3] 白鹭,李小婧,董理科,等. 基于超声波法识别环网柜的局部放电类型研究[J]. 电测与仪表, 2020, 57(11): 42-48.  
 [4] 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(5): 130-133.  
 [5] 阮羚,李成华,宿磊,等. 基于奇异值分解的局部放电模式识别方法[J]. 电工技术学报, 2015, 30(18): 223-228.  
 [6] 唐志国,唐铭洋,李金忠,等. GIS 设备局部放电类型表观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.  
 [7] 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.  
 [8] 刘凡,张响,姚晓,等. 基于 K 近邻算法的换流变压器局部放电模式识别[J]. 电力自动化设备, 2013, 33(5): 89-93.  
 [9] 司良奇,钱勇,白万建,等. 基于支持向量机的 GIS 超高频局部放电模式识别[J]. 高压电器, 2014, 50(11): 1-6.  
 [10] 王保义,杨韵洁,张少敏. 改进 BP 神经网络的 SVM 变压器故障诊断[J]. 电测与仪表, 2019, 56(19): 53-58.  
 [11] GUILLERMO R, EMILIO P, JORGE A, et al. Multiple partial discharge source discrimination with multiclass support vector machines [J]. Expert Systems With Applications, 2016, 55:417-428.  
 [12] 褚鑫,张建文,韩刚. 统计特征参数及多分类 SVM 的局部放电类型识别[J]. 电测与仪表, 2015, 52(7): 35-39,96.  
 [13] 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.  
 [14] 赵建利,刘海峰,刘婷,等. 变压器局部放电信号检测与类型识别[J]. 现代电子技术, 2016, 39(6): 166-170.  
 [15] 廖瑞金,段炼,汪可,等. 基于时频分析和 2DNMF 的局部放电模式识别[J]. 电力自动化设备, 2013, 33(3): 20-25.  
 [16] 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.

### 作者简介

王卓,硕士,主要研究方向为高压电器测试及其控制技术。  
 E-mail:1642350883@qq.com