

文章编号:1000-582X(2006)11-0041-04

基于 Δu 模式和 RBF 网络的局部放电模式识别*

孟延辉, 唐 炬, 周 倩, 李 剑, 谢颜斌

(重庆大学 电气工程学院 高电压与电工新技术教育部重点实验室, 重庆 400030)

摘 要:局部放电(PD)模式识别是诊断高压电气设备内绝缘缺陷的重要方法之一. 采用了一种 Δu 模式参量作为局部放电的图谱特征, 并采用不变矩作为放电特征; 同时, 采用了径向基函数神经网络(RBFNN)对局部放电 Δu 模式参量构成的图谱特征进行识别. 结果表明采用正交最小二乘法(OLS)训练的 RBFNN 对 Δu 模式中的不变矩特征参量进行识别, RBFNN 收敛速度快且稳定性强, 识别率达到 85.7% 以上, 能够很好地识别由 5 种人工绝缘缺陷模型产生的局部放电信号, 在实际应用中具有良好的应用前景.

关键词:局部放电; Δu 模式; 径向基函数神经网络; 模式识别

中图分类号: TM83

文献标识码: A

随着计算机技术的迅速发展, 模式识别作为一种重要的故障诊断方法, 越来越广泛地应用于电气设备局部放电的研究中^[1]. 在模式识别过程中, 特征量的提取是模式识别中的关键. 对于电气设备的局部放电识别, 传统上采用的是从 $\varphi - q - n$ 谱图中提取特征量^[2]. 但由于前一个放电脉冲发生后的剩余空间电荷对下一个放电脉冲的触发条件产生了相当大的影响, 而这种传统的模式分析是对每一个独立的放电脉冲发生的相位和幅值的大小进行的统计分析, 不能对局部放电现象尤其是对固体绝缘放电的物理意义很好地进行解释. 为提高判断的可靠性, 常采用人工神经网络实现局部放电模式自动识别. RBFNN 作为一种多层前馈神经网络, 因结构简单、工作状态稳定、训练速度快、能收敛到全局最优点、可最佳逼近等优点, 并可以解决大多数神经网络面临的问题, 在模式识别和分类上得到了广泛的应用^[3].

笔者提出了一种能够正确反映连续局部放电脉冲信息的 Δu 放电模式. 它能够反映连续局部放电脉冲信息, 并可进行不同局放源的分类, 是一种有效的局部放电模式的构造方法; 并采用了 RBFNN 对基于 Δu 模式的 PD 特征进行识别, 很好地识别了 5 种人工绝缘缺陷模型产生的局部放电信号.

1 局部放电模型试验

1.1 局部放电试验模型

变压器绝缘体系中的放电类型很多, 针对绝缘内部放电形式和外部空气中的放电的特点, 设计了 5 种放电模型^[4]: 1) 空气中电晕放电模型; 2) 固体绝缘内部缺陷模型; 3) 空气中沿面放电模型; 4) 油中电晕放电模型; 5) 油中沿面放电模型.

1.2 局部放电试验的采集系统及实验线路

数据采集仪采样率设置为 3 MS/s, 幅值分辨率为 8 位, 数据存储长度 64 kB, 输入电压范围 $\pm 1\ 000$ mV. 实验在屏蔽实验室中进行, 实验线路如图 1 所示.

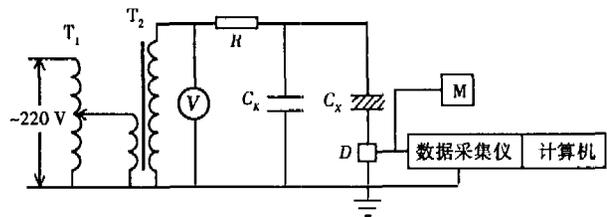


图1 放电模型实验线路

为防止高压引线出现电晕放电, 高压引线均用直径为 10 mm 的铝管. 实验步骤如下:

1) 预加电压. 在未放置模型的情况下连接好实验

* 收稿日期: 2006-07-11

基金项目: 重庆市自然科学基金资助项目(2005-BB3170); 国家电网公司重庆电力公司项目(2004-SGKJ)

作者简介: 孟延辉(1981-), 男, 河南偃师人, 重庆大学硕士研究生, 主要从事电气设备在线检测及故障诊断研究.

线路,逐步升高电压,同时观察示波器,一旦示波器出现放电脉冲就记录当时的电压值,此电压值即为最大允许实验电压 U_{\max} ,这保证了实验电压小于 U_{\max} 时采集到的局部放电信号来自试品。

2)测量起始放电电压.放置模型后,均匀缓慢地升高电压,示波器出现第一个放电脉冲时记录下此时的试验电压,此电压值即为放电模型的起始放电电压。

3)采集局部放电信号.把实验电压升至1.2倍的起始放电电压,调节调幅电路的放电倍数,使在示波器上观测到的最大脉冲电压幅值在500 mV左右,然后开始采样,每次采样采集3 000个工频周期。

4)放电量校正.由于要不断的调节调幅电路的放大倍数,因此在每组实验结束后需按照图2所示的校正回路标定单位幅值放电量,其中 U_0 为标定方波, C_0 为分度电容。

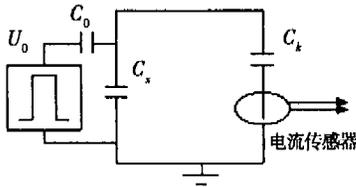


图2 放电量标定回路

2 局部放电 Δu 模式参量特征的提取

2.1 局部放电 Δu 模式的物理意义

如果给固体绝缘介质加交流电压,且这种固体绝缘介质本身具有一定的缺陷,缺陷中的电场强度 E_i 定义为:

$$E_i(t) = E_o(t) + \Delta E_i(t) = g_u u(t) - g_q q_i^+(t), \quad (1)$$

其中 $E_o(t)$ 是由外加电压 $U(t)$ 和表示气隙形状的系数 g_u 决定的; $\Delta E_i(t)$ 是内部电场部分,由空间电荷叠加起来,并依赖于大量的电荷 $q_i^+(t)$ 和表示几何分布系数 g_q . 空间电荷要么是先前放电产生的,要么是电极或缺陷本身的充放电过程所引起的.当电场强度 $E_i(t)$ 超过了原来的场强 E_i ,便产生了放电脉冲,并且由于放电产生的电荷积累使电场强度发生了改变.由于绝缘介质的传导率非常低,假设在连续放电脉冲之间的时间段内的空间电荷对介质的腐蚀可以忽略,然后在局部电场中将产生下一个脉冲,其电场强度为:

$$E_i(t + \Delta t) = g_u u(t + \Delta t) - g_q [q_i^+(t) + \Delta q_n^+]. \quad (2)$$

在第 $n+1$ 个脉冲和第 n 个脉冲的外加电压差,即

Δu 模式参量涉及到放电点内部的参数, Δu 模式参量定义为:

$$\Delta u_n = U_{n+1} - U_n = \frac{1}{g_u} [E_{i(n+1)}^+ - E_{in}^+] + \frac{g_q}{g_u} \Delta q_n^+, \quad (3)$$

其中 E_{in}^+ , $E_{i(n+1)}^+$ 分别是2个连续脉冲的初始电场强度; Δq_n^+ 是第 n 个脉冲的正、负电荷积累; g_u 描述了缺陷处由外加电压 $U(t)$ 所决定的局部场强的几何系数 [$g_u = 1/m$]; g_q 描述缺陷处由前一个脉冲引起空间电荷积累所决定的局部场强的几何系数。

2.2 局部放电 Δu 模式参量谱图的构造

Δu_n 分布是一种 Δu 模式,由局部放电脉冲序列 $q_i[t_i, u(t_i)]$ 得到.根据 $q_i[t_i, u(t_i)]$ 可以得到放电对应的序列 $u(t_i)$,将 $u(t_i)$ 按时间顺序排列,即得到序列 u_n (如图3所示),则 $\Delta u_n = u_{n+1} - u_n$.由式(3)可以计算出多个工频周期内 Δu_n 分布情况.由图3中连续3个放电脉冲 u_{n-1} 、 u_n 、 u_{n+1} 可以计算出 Δu_n 和 Δu_{n-1} ,因此得到右图中 Δu_n (Δu_{n-1}) 图上点 p .根据连续多个工频周期测量结果,可以统计出 Δu 模式参量图谱,即 Δu_n (Δu_{n-1}) 分布.图4表示了5种人工绝缘缺陷放电模型的 Δu 模式参量图谱。

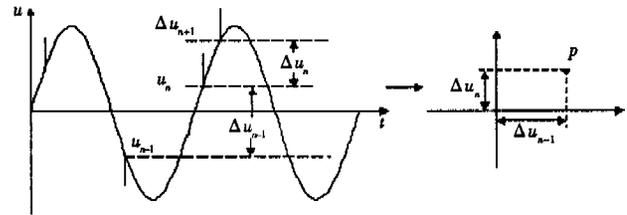


图3 局部放电 Δu 模式构造原理示意图

2.3 提取 Δu 模式参量图谱特征的方法

由图4中所表示的5种人工绝缘缺陷放电模型的 Δu 模式参量图谱可以看出,不同的放电模型其 Δu 模式参量图谱是明显不同的.在图象模式识别中,矩特征是一种被广泛应用的图象形状特征参数.一些最基本的图象形状特征都与矩有直接关系,因此笔者采用不变矩作为 PD 特征。

设 $f(x, y)$ 为数字图形函数,定义 $f(x, y)$ 的 $p+q$ 阶矩为:

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y), \quad (4)$$

定义 $f(x, y)$ 的 $p+q$ 阶中心矩为:

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y), \quad (5)$$

其中 $\begin{cases} \bar{x} = m_{10}/m_{00}, \\ \bar{y} = m_{01}/m_{10}. \end{cases}$

定义 $f(x, y)$ 的归一化中心矩为:

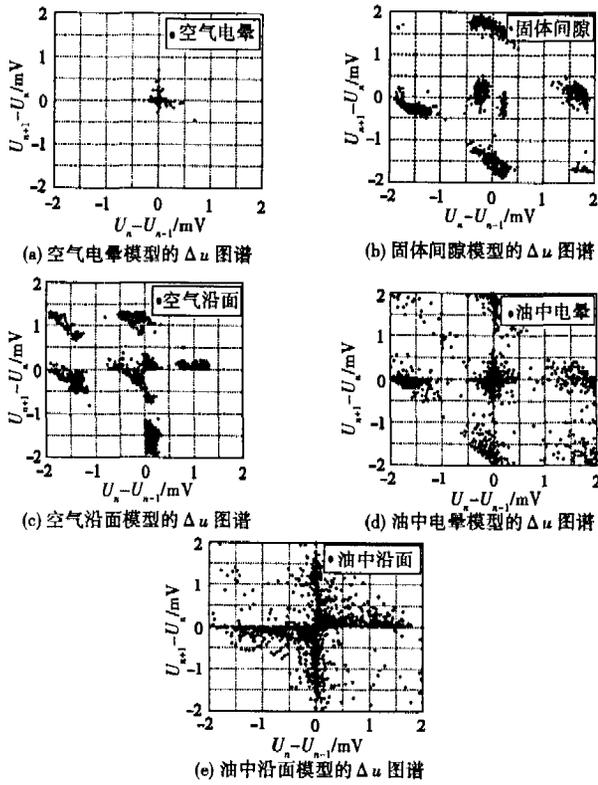


图 4 放电模型典型样本的 Δu 模式图谱

$$\eta_{pq} = \mu_{pq}/u_{00}^r, \quad (6)$$

其中, $r = (p + q)/2 + 1, p + q = 2, 3, \dots$

由归一化的二阶和三阶中心矩可得到以下 7 个对平移、旋转和尺度变换不变的矩^[5]:

$$\left. \begin{aligned} \varphi_1 &= \eta_{20} + \eta_{02}, \\ \varphi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \\ \varphi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \\ \varphi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \\ \varphi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ &\quad (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \\ \varphi_6 &= (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + \\ &\quad 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}), \\ \varphi_7 &= 3(\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ &\quad (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]. \end{aligned} \right\} \quad (7)$$

3 RBFNN 用于局部放电模式识别

3.1 RBFNN 的结构及原理

RBFNN 是一种 3 层前向神经网络, 包括一个输入层, 一个隐层, 一个输出层, 具有非线性可分的模式空间映射到线形状态空间可分的特性^[6-7], 网络结构如图 5 所示. 输入单元只是传递信号到隐层, 隐层的单元是感受野 (receptive field) 单元, 每个感受野单元输

出为:

$$\omega_i = R_i(X) = R_i(\|X - c_i\|/\sigma_i), i = 1, 2, \dots, H, \quad (8)$$

其中 X 是 N 维输入向量, c_i 是与 X 同维数的向量, $R_i(\bullet)$ 具有局部感受的特点. 例如 $R_i(\bullet)$ 取高斯函数, 即 $R_i(X) = \exp(-\|X - c_i\|^2/\sigma_i^2)$, $R_i(\bullet)$ 只有在 c_i 周围的一部分区域内有较强的反应, 这正体现了大脑皮质层的反应特点.

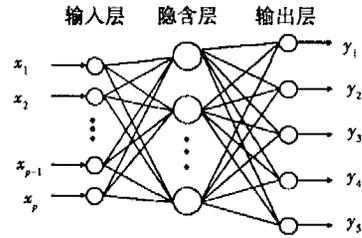


图 5 RBFNN 拓扑结构

RBF 网络的参数确定过程如下:

一般 RBF 网络可以表示成

$$f_n(X) = \sum_{i=1}^n \omega_i \varphi([\|X - c_i\| \Sigma^{-1} \|X - c_i\|]), \quad (9)$$

其中 Σ^{-1} 是控制 RBFNN 感受野大小的矩阵, 由此可知, 对于给定激活函数 $\varphi(r^2)$ 的 RBFNN 来说有 3 类参数需要确定: 1) RBFNN 权值 $\omega_i, i = 1, \dots, n$; 2) 网络基函数中心矢量 $c_i, i = 1, \dots, n$; 3) 控制矩阵 Σ . 如果用参数 Θ 来代替上述 3 种参数, 针对训练样本 $D_N = \{X_i, Y_i\}_1^N$, 则 RBF 网络的学习过程就是寻找 $\hat{\Theta}$ 使下列式子最小化.

$$\epsilon_{\text{RBF}}(D_N, \Theta) = \min_{\Theta} \epsilon_{\text{RBF}}[D_N, f_n(X, \Theta)], \quad (10)$$

$$D_N = \{X_i, Y_i\}_1^N, \quad (11)$$

$$\epsilon_{\text{RBF}}[D_N, f_n(X, \Theta)] = \frac{1}{N} \sum_{i=1}^N |Y_i - f_n(X, \Theta)|^2 \quad (12)$$

可以看出对参数及 c_i 的优化是很复杂的非线性规划问题, 难以有效的解出. 有效的解决方案是: 首先选定 Σ , 其次从训练样本中确定 c_i , 这样 RBFNN 的参数确定问题就转化为只对输出权值的最小化问题. 这是一个线性方程求解的问题, 因此利用各种最小二乘法都可求出 ω_i .

3.2 RBFNN 的训练

RBFNN 学习方法主要有以下 5 种: 1) Poggio 方法; 2) Moody 和 Darken 方法; 3) 局部学习方法; 4) 正交

最小二乘法;5)聚类与 Givens 最小二乘联合迭代法^[8]. 笔者采用正交最小二乘法 OLS (Orthogonal Least Squares) 法, OLS 是目前训练 RBFNN 应用较多的一种方法. 这种方法的优点是简单易行, 运算速度快. RBFNN 的 OLS 方法学习过程如下: 对于具有 N 对学习样本的 RBFNN, 其输入输出方程为:

$$d = p\Theta + E \quad (13)$$

其中 $d = [d(1), \dots, d(N)]^T$ 为期望输出, $p = [p_1, \dots, p_N]$ 是隐含单元输出阵, $p_i = [p_i(1), \dots, p_i(N)]^T$, $\Theta = [\theta_1, \dots, \theta_N]^T$ 为输出权矢量, $E = [\varepsilon(1), \dots, \varepsilon(N)]^T$ 是误差矢量.

由此可知 RBFNN 是线性回归模型的一个特例. 回归因子矢量 p_i 构成了基矢量的集合. 由于不同的回归因子一般是相关的, 因此需要有一个方法来确定各个不同的回归因子对输出能量的贡献, OLS 方法解决了这个问题. OLS 方法的过程是将 p_i 集合变换成正交集, 即 $p = WA$, A 是对角线为 1 的上三角阵, W 是包含正交矢量 ω_i 的矩阵. 因此有方程 $d = Wg + E$, $A\Theta = g$. 由于 A , g 可以在正交化的过程中得到, 因此 Θ 也易求解出来. OLS 法在每步正交过程中, 都要用“新息-贡献”准则进行正交优选. 当 OLS 法满足一定精度后, 算法即终止, 这时的正交矢量数目就是隐含层神经元数目.

3.3 RBFNN 在局部放电模式识别中的应用

将局部放电 Δu 谱图平均分成 16 格, 计算出每格 7 个不变矩参量, 得到 $16 \times 7 = 112$ 的表列数据, 作为局部放电的特征参数. 每类放电样本均有 45 组样本, 从中选择 10 组样本训练, 其余放电样本为待识样本. 学习过程中设定网络的期望目标为均方误差 ≤ 0.0005 , 神经元的输出阈值为 0.8, 即输出大于等于 0.8 时即判断属于该神经元代表的类型. 采用训练好的 RBFNN 对待识放电样本进行分类识别, 识别结果如表 1 所示, 其中识别率定义为正确识别样本数与待识样本数之比. 识别率在 85.7% 以上, 可以看出从 Δu 模式参量提取局部放电不变矩特征, 并采用 RBFNN 的方法是可行的.

表 1 RBFNN 的识别结果 %

放电类型	空气	固体	空气	油中	油中
	电晕	间隙	沿面	电晕	沿面
识别率	97.1	85.7	94.3	97.1	91.4

4 结 论

1) 由于前一个放电脉冲产生后的剩余空间电荷对下一个放电脉冲的触发条件产生了相当大的影响, 故 Δu 模式参量能够正确反映连续局部放电脉冲信息.

2) 不同类型放电的 Δu 模式参量图谱在灰度分布、几何形状上存在差异, 可以据此提取采用不变矩作为 PD 特征, 对不同类型放电进行模式识别.

3) 采用 OLS 法训练的 RBFNN 对 Δu 模式中的不变矩特征参量进行识别, 结果表明, RBFNN 收敛速度快且稳定性强, 识别率达到 85.7% 以上, 在实际应用中具有良好的应用前景.

参考文献:

- [1] 库钦斯基 Г С 著. 高压电气设备局部放电[M]. 徐永禧, 胡维新译. 北京: 水利电力出版社, 1984.
- [2] LAPP A, KRANZ H G. The Use of the CIGRE Data Format for PD Diagnosis Applications[J]. IEEE Trans on Dielectrics and Electrical Insulation, 2000, 7(1): 102-112.
- [3] POGGIO F, GIROSI F. Networks for Approximation and Learning[J]. Proceedings of the IEEE, 1990, 78(9): 1482-1497.
- [4] 唐炬, 王静, 李剑, 等. Weibull 分布在识别变压器局部放电中的应用[J]. 重庆大学学报(自然科学版), 2002, 22(4): 87-90.
- [5] 章毓晋. 图像处理和分析[M]. 北京: 清华大学出版社, 2000.
- [6] MOODY J, DARKEN C. Fast Learning in Networks of Locally-tuned Processing Units [J]. Neural Computation, 1989, 18(1): 281-294.
- [7] 袁曾任. 人工神经网络及其应用[M]. 北京: 清华大学出版社, 1999.
- [8] 王旭东, 邵惠鹤. RBF 神经网络理论及其在控制中的应用[J]. 信息与控制, 1997, 26(4): 272-284.

(下转第 52 页)

- www.globus.org/wsrif/specs/ws-wsrif.pdf, 2005-09-03.
- [4] MARIO C, ANTONIO C, ANDREA P. Distributed Data Mining on Grids: Services, Tools, and Applications [J]. IEEE Transactions on Systems, Man and Cybernetics, 2004, (12): 205-212.
- [5] 侯文国,傅秀芬,谢翠萍. 网格的数据挖掘[J]. 计算机应用研究, 2004, (10): 241-247.
- [6] 陈刚. 基于代理的分布式数据挖掘系统设计[J]. 计算机工程, 2001, 27(9): 66-71.
- [7] RAKESH A, JOHN C. Parallel Mining of Association Rules [J]. IEEE Transactions on Knowledge and Data Engineering, 1996, (12): 101-104.

Distributed Data Mining on the Grid

JIANG Wu-shan, YU Ji-hui

(Key Laboratory of High Voltage Engineering and Electrical New Technology, Ministry of Education, Electrical Engineering College of Chongqing University, Chongqing 400030, China)

Abstract: Distributed data mining (DDM) is widely used in industrial, scientific and commercial applications to analyze large datasets maintained over geographically distributed sites, which makes DDM a major research issue on today's data mining field. This paper discusses the disadvantages of existing DDM systems, puts forward a service-oriented architecture for DDM on the grid and describe the process of mining under this framework. In the proposed, service-oriented, cross-platform framework, the mining algorithm and distributed data sets are packed into the Web Service Resources (WS-Resource) respectively, which can cooperate to perform DDM as required dynamically. Finally, a grid based on local area network was built with Globus Toolkit 4.0 and take an example of association rule mining to illustrate how to work with the proposed architecture.

Key words: distributed data mining; grid computing; web service resource

(编辑 李胜春)

(上接第 44 页)

Partial Discharge Pattern Recognition Based on Voltage-difference Method and Radial Basis Function Neural Network

MENG Yan-hui, TANG Ju, ZHOU Qian, LI Jian, XIE Yan-bin

(Key Laboratory of High Voltage Engineering and Electrical New Technology, Ministry of Education, Electrical Engineering College of Chongqing University, Chongqing 400030, China)

Abstract: Partial discharge (PD) pattern recognition is widely regarded as a significant measure for diagnosis of dielectric defects in electrical equipment. Voltage-difference method, i. e. Δu pattern, as a basis for PD pattern recognition is presented, and the invariant moments are studied as the features of PD in Δu pattern. Furthermore, radial basis function neural network (RBFNN) is applied to PD pattern recognition according to the disadvantages of RBFNN. The results show that RBFNN has faster convergence speed and stronger stability, the performance of RBFNN is up to 85.7% with orthogonal least squares (OLS), and PD signals generated by five kinds of dielectric defects can be classified well with the method, so it is favorite to use in practice.

Key words: partial discharge; Δu pattern parameter; RBFNN; pattern recognition

(编辑 李胜春)