

基于BP网络的高压电抗器局部放电模式识别

通过获取高压电抗器特高频局部放电信号，对局部放电波形进行特征向量提取处理，用降维后的向量作为输入对BP分类器进行训练和测试类型识别。识别结果表明，用该方法进行高压电抗器绝缘缺陷类型识别，可以在减少计算量的同时保持较高的识别率，证明其在高压电抗器局部放电模式识别应用中的有效性。

姜国庆 李 璐 李 钊 许东升/河南省电力公司检修分公司



姜国庆/高级工程师

高压并联电抗器是500 kV特高压变电站的重要设备之一，其稳定可靠性将影响电网的安全运行。长期的运行经验表明，高压并联电抗器的问题以绝缘性故障为主。因此，开展500 kV电抗器绝缘性能检测的技术研究，对及时发现和处理电抗器内部存在的绝缘缺陷是十分重要的。

特高频法局部放电检测技术，是最近几年出现的局部放电检测技术，通过特高频信号传感器接收油/纸绝缘中局部放电过程辐射的特高频电磁波信号，实现局部放电的检测，能较好地反映高压设备的绝缘状况。而且，特高频信号频段在300 MHz~3 GHz之间，可以有效地避开高压电气设备现场的干扰，为后续放电类型的分析和识别提供便利。

本文采用特高频法，通过在高压电抗器上安装特高频局部放电传感器获取高压电抗器的局部放电信号，并通过BP网络算法对局部放电信号进行处理分析，实现其绝缘缺陷类型的模式识别。

BP神经网络分类器

1. BP神经网络介绍

BP (Back Propagation) 神经网络由

Rumelhart和McClelland为首的科学家小组在1986年提出，是一种按误差逆传播算法训练的多层前馈网络，也是目前应用广泛的神经网络模型之一。BP网络能学习和存储大量的输入-输出模式映射关系，而无须事前揭示描述这种映射关系的数学方程。其学习规则是使用最速下降法，通过反向传播来不断调整网络的权值和阈值，使网络的误差二次方和最小。

BP神经网络结合Adaboost算法组成改进的算法，较传统单一的BP网络提高了预测准确度。在模型中，Adaboost算法采用BP神经网络作为弱分类器，针对同一个训练集训练不同的弱分类器，然后将这些弱分类器集合起来，构成一个更强的最终分类器。算法本身通过改变数据分布来实现。

BP网络算法是含有一个输入层、一个或者多个隐含层和一个输出层的多层网络。其基本思想是通过多层处理误差反传直到网络输出误差减小来获得有效的分类。主要步骤为：首先给出弱学习算法和输入层节点数，从数据样本中选出 m 组训练数据，每组训练数据赋予的初始权重都是 $1/m$ ；然后使用弱学习算法迭代运算 T 次，将每次运算后的结果按照分类结果来调整权重分布，分类结果错误的训练个体赋予较大权重，下一次迭代运算时着重这些训练个体。弱分类器通过反复迭代运算得到一个分类函数序列 $f_1, f_2, \dots, f_T$ ，每个分类函数赋予一个权重，分类结果误差小的函数，其对应权重也就越大。 T 次迭代之后，最终强分类

关键词/Keywords

高压电抗器 ·
BP分类器 ·
放电类型识别 ·

函数 $h(x)$ 由弱分类函数加权得到。

2. 算法和训练过程

BP网络的算法步骤如下。

第一步：权值初始值。

第二步：重复下述过程直至达到预定要求为止。

1) 由前向后计算各层各单元 θ_j

$$\text{net}_j = \sum_i \omega_{ij} \theta_i \quad (1)$$

$$\theta_j = 1 / (1 + e^{-\text{net}_j}) \quad (2)$$

2) 对输出层计算 δ_j

$$\delta_j = (y - \theta_j) \theta_j (1 - \theta_j) \quad (3)$$

3) 从后向前计算各隐含层 δ_j

$$\delta_j = \theta_j (1 - \theta_j) \sum_k \omega_{jk} \delta_k \quad (4)$$

4) 计算并保存各权值的修正量

$$\Delta \omega_{ij}(t) = \alpha \Delta \omega_{ij}(t-1) + \eta \alpha_j \theta_i \quad (5)$$

5) 修正权值

$$\omega_{ij}(t+1) = \omega_{ij}(t) + \Delta \omega_{ij}(t) \quad (6)$$

可以按每个样本作权值修正或按总误差进行权值修正。

3. BP分类器的识别过程

BP模型即分解使用多个BP神经网络，每个神经网络为一个弱分类器，反复训练BP神经网络，通过算法得到多个BP神经网络弱分类器组成的强分类器。图1为BP算法进行分类识别的流程。




图1 BP算法分类识别流程

算法步骤如下：

1) 初始化。包含选择 m 组测试数据，初始BP网络权值和阈值，确定输入输出维数，初始化测试数据的分布权值 $D_i(i) = 1/m$ 。

2) 弱分类器预测。训练第 t 个弱分类器时，用测试数据训练BP神经网络并且预测数据输出，通过运算得到一个预测序列 $g(t)$ 的预测误差和 e_t ，误

差和 e_t 计算公式为

$$e_t = \sum_i D_i(t) \quad i=1, 2, \dots, m \quad (g(t) \neq y) \quad (7)$$

式中， $g(t)$ 为预测分类结果； y 为期望分类结果。

3) 计算预测序列权重分布。由预测误差和 e_t 计算序列 $g(t)$ 的权重 a_t ，权重计算公式为

$$a_t = \frac{1}{2} \ln \left(\frac{1 - e_t}{e_t} \right) \quad (8)$$

4) 测试数据误差结果权重调整。根据运算分类结果预测序列权重 a_t ，调整下一轮测试样本的权重，调整公式为

$$D_{t+1}(i) = \frac{D_i(t)}{B_t} \exp [-a_t y_i g_t(x_i)] \quad i=1, 2, \dots, m \quad (9)$$

式中， B_t 为归一化因子，可以在权重比例不变的情况下使分布权值总和为1。

5) 强分类函数。训练迭代运算 T 轮后得到 T 组弱分类函数 $f(g_t, a_t)$ ，由 T 组弱分类函数 $f(g_t, a_t)$ 加权组合得到强分类函数 $h(x)$ 。

$$h(x) = \text{sign} \left[\sum_{t=1}^T a_t f(g_t, a_t) \right] \quad (10)$$

局部放电的类型识别

1. 放电类型数据获取

在试验中的高压电抗器实体模型中分别放入针板模型模拟尖端放电、悬浮金属颗粒放电和绝缘体内部缺陷放电三种放电模型。采用特高频传感器采集局部放电信号，采集系统由传感器、高速采集板和主机组成。特高频传感器主要由天线与后置的带宽放大器构成，采集板采用40 Mbit/s的采集率采集信号。试验中先缓慢升高试验电压，当出现较为稳定的放电时，停止加压。由于放电模型的不同，最终统一加压到60 kV，在三种模型中都能检测到稳定放电。其放电图谱如图2所示。每种放电用特高频传感器测得其对应的放电波形150组，具体的训练样本和测试样本数量如表1所示。其中，1代表尖端放电类型；2代表悬浮金属颗粒放电类型；3代表绝缘体缺陷放电类型。

2. 试验数据的降维

局部放电统计特征选择从多个不同角度选




图2 三种类型放电PRPS图谱

表1 分类器样本

	1	2	3
样本个数	130	130	130
训练样本个数	120	120	120
测试样本个数	10	10	10

取能够表征局部放电不同特性的特征，以达到最好的识别效果。本文从信号的时域特性角度考虑，选取特征点。对测得的特高频信号波形提取了最大幅值、波宽、起始角度、上升时间、下降

时间、放电次数、平均值、偏斜度、突出度、局部峰个数、放电不对称度（ Q ）和相位不对称度（ Φ ）12个特征参数，即每个特征向量有12维。为了加快识别速率和避免维数灾难，对三种放电的450个特征向量进行LLE算法降维，在进行LLE算法降维前，必须确定要选择的临近点个数 k 和降维后特征向量组数 m 。本文的试验数据比较密集，同一种放电得出的特征向量之间距离很近，所以不需要太大的 k 值， k 值的增大会增加计算量，最终选择 k 的值为7。对于降维后的组数 m ，维数越低，原始数据丢失的信息越多，不利于类型的识别，所以最后选择 m 为8，这样既减少了计算量和节约了计算时间，又可以保证识别的正确率。

3. BP分类器进行类型识别

输入的特征向量为8维，而输出向量为3维，分别用状态 $[0 \ 0 \ 1]$ 代表1放电， $[0 \ 1 \ 0]$ 代表2放电， $[1 \ 0 \ 0]$ 代表3放电。

在用特征向量进行训练前，先对其进行归一化处理。数据归一化处理是将所有的数据都转化为 $[0, 1]$ 之间的数，其目的是取消各维数据间数量级差别，避免因输入输出数据数量级差别较大而造成网络预测误差较大。本文采用最大最小法，其函数形式表达式为

$$x_k = (x_k - x_{\min}) / (x_{\max} - x_{\min}) \quad (11)$$

式中， $x_{\min}$ 为数据序列中的最小数； $x_{\max}$ 为序列中的最大数。

采用隐含层为1层的BP神经网络，根据数据维数，其训练参数为：学习率0.01，最大学习次数500次，学习准确度0.001，训练函数trainlm。对于BP_Adaboost强分类器，其迭代次数为15，即弱分类器BP神经网络的个数为15。随后，对分类器用训练数据进行训练，训练结束后用测试数据进行放电类型识别的测试，测试结果如表2所示。

表2 分类识别结果

放电类型	1	2	3	识别率 (%)
1	26	4	0	92.7
2	0	25	5	82.7
3	0	2	28	86.0

从识别结果可以看出，分类器对1的识别率最高，这主要是因为1和其余两种放电的放电波形差别较大。

现场数据试验

使用特高频局部放电监测系统对某变电站现场500 kV高压电抗器设备进行局部放电的连续监测。根据实地勘察情况进行特高频局部放电传感器分布点的方案设计，分别在电抗器设备三个不同部位安装特高频传感器。

其中一点在检测过程中发现异常放电信号，其放电数据如图3所示，对该测试点的放电数据进行PRPS和PRPD分析，结果如图4和图5所示。从图谱上可以看出，放电间隔满足 180° 相位特征，可以确定是高压电抗器局部放电，下面采用BP网络对其进行放电类型识别。




图3 高压电抗器局部放电信号




图4 PRPS数据分析

依旧从原始信号选取最大幅值、波宽、起始角度、上升时间、下降时间、放电次数、平均值、偏斜度、突出度、局部峰个数、放电不对称度 (Q) 和相位不对称度 (Φ) 12个特征参数。然后经过降维处理后降为8维。




图5 PRPD数据分析

对分类器用前面训练数据进行训练，训练结束后用现场采集数据对放电类型识别进行分类测试。现场采集50组放电数据进行独立测试，分类结果如表3所示。其中，1代表尖端放电类型；2代表悬浮金属颗粒放电类型；3代表绝缘体缺陷放电类型。

表3 实际数据分类结果

放电类型	1	2	3
放电次数	7	4	39

从分类结果可以看出，对50组数据进行分类，尖端放电的次数为7次，可能概率为14%；悬浮金属颗粒放电次数为4次，可能概率为8%；绝缘体缺陷放电为39次，可能概率为78%。后经停电检修，在现场高压电抗器绝缘支架底部发现裂痕和放电痕迹，可确认为绝缘体缺陷导致的局部放电。导致尖端放电概率偏高的原因从图谱中可以看出，尖端放电和绝缘体缺陷放电的图谱有一定的相似度。

结束语

本文采用特高频传感器检测法对高压电抗器进行了局部放电检测，获取了电抗器的局部放电信号；采用多个BP神经网络作为弱分类器组成的BP分类器，用来进行局部放电类型的识别，通过试验室和现场实际的放电数据验证了识别率较高，说明了该BP分类器在局部放电模式识别应用中的有效性。

(收稿日期：2014-10-21) EA