

# 电力变压器励磁涌流判别的 自适应小波神经网络方法

李海锋, 王 钢, 李晓华, 胡少鹏

(华南理工大学电力学院, 广东省 广州市 510640)

## DISTINGUISH BETWEEN INRUSH AND INTERNAL FAULT OF TRANSFORMER BASED ON ADAPTIVE WAVELET NEURAL NETWORK

LI Hai-feng, WANG Gang, LI Xiao-hua, HU Shao-peng

(Dept. of Electrical Engineering, South China University of Technology,  
Guangzhou 510640, Guangdong Province, China)

**ABSTRACT:** Inrush identification is always a key problem in power transformer current differential protection. A novel technique using adaptive wavelet neural network is presented to distinguish between inrush and internal fault currents. Based on the characteristics of inrush and internal faults, the architecture of a four-layer adaptive wavelet neural network is given and the implementation details are discussed. ATP-EMTP is used to generate the training samples and testing samples. The test results show the presented technique can make reliable discrimination between inrush and fault currents.

**KEY WORDS:** Power transformer; Magnetizing inrush; Adaptive; Wavelet Neural Network

**摘要:** 励磁涌流识别一直是电力变压器差动保护中比较关注的问题。文中提出了一种基于自适应小波神经网络实现变压器励磁涌流判别的新方法。结合励磁涌流和内部故障电流的特点, 构建了一个四层的自适应小波神经网络模型, 并对其具体的实现方法进行了详细的分析; 利用 ATP-EMTP 程序进行仿真计算生成训练样本和测试样本, 对所构建的网络进行了训练和测试, 结果表明自适应小波神经网络能准确、可靠地识别出变压器的励磁涌流状态。

**关键词:** 电力变压器; 励磁涌流; 自适应; 小波神经网络

## 1 引言

电流差动保护由于其快速性、明确选择性以及高灵敏性, 一直以来都是电力变压器保护的主要形

式。而正确区分内部故障电流和励磁涌流则是其中最为关键也最难解决的问题。传统的变压器励磁涌流判别方法通常是利用涌流的某些波形特征<sup>[1-3]</sup>加以判别, 如直流分量、间断角和二次谐波等, 其中又以二次谐波制动原理应用最为广泛。然而, 在实际电力系统中, 变压器励磁涌流和内部故障电流波形受诸多因素的影响, 如系统参数、运行方式等。传统的判别原理在实际应用中都存在一定的局限性。随着我国经济建设和电力工业的迅速发展, 电力系统变得越来越庞大和复杂, 并向大规模交直流混合互联大电网的方向发展, 使影响变压器保护的因素变得更多、更复杂, 这也将大大增加励磁涌流识别的难度。因此, 运用新的原理和方法实现变压器励磁涌流的判别具有现实迫切性。

故障状态识别属于模式识别的范畴。神经网络具有自组织、自学习和自适应能力, 可以自适应地提取待分类模式中的特征信息, 是一种新兴的模式识别技术, 已被应用于电力变压器保护中<sup>[4-6]</sup>。但在这些应用中, 神经网络的模式识别空间仅限于单纯的时域或频域空间, 而不是基于信号的时频域特征。这必然导致某些重要信息的丢失, 不利于神经网络对内部故障和励磁涌流的准确识别。小波分析作为傅立叶变换的突破性进展, 具有良好的时频局部化特性, 可以有效地分析、提取变压器励磁涌流与故障电流的时频特征<sup>[7-9]</sup>。

小波神经网络则将小波分析技术和神经网络技术结合起来, 兼具两者的优点。小波分析与神经

基金项目: 国家自然科学基金重点项目 (50337010)。

Project Supported by National Natural Science Foundation of China(NSFC)(50337010).

网络有两种结合方式，一种是以小波为基底的新型前馈神经网络，小波函数作为前馈网络的神经元激励函数；另一种则是利用小波分析对信号进行预处理，即以小波空间作为神经网络模式识别的特征空间，通过小波变换来实现信号的时频特征提取，然后将提取的特征向量送入神经网络处理。

文[10]中采用的小波神经网络属于前者，但在进行励磁涌流识别时同样仅利用了频域信息。文[11]则是利用小波变换对信号进行预处理，提取其不同时频段内的能量形成前馈神经网络的输入来实现励磁涌流的识别。但其小波变换的时频特征提取与神经网络分类器之间完全独立，小波参数是基于待分类对象特征的认识而给定的，即神经网络分类器的输入是预先给定的时频域特征，在神经网络学习过程中不作任何修正。而在实际系统中，三相变压器空载合闸励磁涌流的波形特征（谐波成分、间断角等）非常复杂，预先给定的小波参数很难保证所提取的时频特征包含了区分励磁涌流和内部故障电流的最本质特征。

Szu H提出了自适应小波神经网络并将其应用在语音、声纳的识别中<sup>[12-13]</sup>。自适应小波神经网络在学习过程中能自适应调整小波的尺度因子和位移因子，最大限度地对信号进行特征提取，具有一定的抗干扰性，而且学习算法简单，收敛速度快。为此，本文引入自适应小波神经网络应用于电力变压器励磁涌流的判别。

## 2 自适应小波神经网络

自适应小波神经网络由两部分组成，第一部分是小波层，用作特征提取。第二部分是一个前馈神经网络，用作对信号的分类。

图 1 给出了一个含有一个隐层的自适应小波神经网络结构，它是Szu所提模型的扩展，即在输入和输出层之间加入了隐层。这一结构能用于处理更为复杂的信号分类问题，更具实用性。其中 $x(k)$ 为输入层第 $k$ 个输入值， $o_p$ 为输出层第 $p$ 个输出值， $w_{ji}$ 为连接隐层节点 $i$ 和小波层节点 $j$ 的权重， $w_{ip}$ 为连接隐层节点 $i$ 和输出层节点 $p$ 的权重， $a_j$ 和 $b_j$ 分别为小波层第 $j$ 个节点的尺度、位移因子； $K$ 为输入层节点数， $J$ 为小波层节点数， $I$ 为隐层节点数， $P$ 为输出层节点数。小波层采用母小波函数 $h(x)$ ，网络的输出层、隐层传递函数均采用sigmoid函数 $\sigma(x)$ 。

因此，自适应小波神经网络的输出可以写成下

面的关系式

$$o_p = \sigma\left(\sum_{i=1}^I w_{ip} \sigma\left(\sum_{j=1}^J w_{ji} \sum_{k=1}^K x(k) \cdot h\left(\frac{k-b_j}{a_j}\right)\right)\right) \quad (1)$$

对于自适应小波神经网络的学习，可以采用BP算法。下面给出其批处理的学习算法。

若设 $d_p^{(n)}$ 为第 $n$ 个输入模式的网络期望输出值， $o_p^{(n)}$ 、 $y_i^{(n)}$ 、 $z_j^{(n)}$ 分别为第 $n$ 个输入模式的网络实际输出、隐层节点输出和小波层节点输出值，则可以定义误差函数为

$$\xi = \frac{1}{2N} \sum_{n=1}^N \sum_{p=1}^P (o_p^{(n)} - d_p^{(n)})^2 \quad (2)$$

因此可以推导出自适应小波神经网络各权值及小波参数的修正值为

$$\Delta w_{ip} = \frac{\partial \xi}{\partial w_{ip}} = -\frac{1}{N} \sum_{n=1}^N (d_p^{(n)} - o_p^{(n)}) o_p^{(n)} (1 - o_p^{(n)}) y_i^{(n)} \quad (3)$$

$$\Delta w_{ji} = \frac{\partial \xi}{\partial w_{ji}} = -\frac{1}{N} \sum_{n=1}^N \sum_{p=1}^P (d_p^{(n)} - o_p^{(n)}) \cdot o_p^{(n)} w_{ip} y_i^{(n)} (1 - y_i^{(n)}) z_j^{(n)} \quad (4)$$

$$\Delta a_j = \frac{\partial \xi}{\partial a_j} = -\frac{1}{N} \sum_{n=1}^N \sum_{p=1}^P (d_p^{(n)} - o_p^{(n)}) o_p^{(n)} (1 - o_p^{(n)}) \cdot \sum_{i=1}^I w_{ip} y_i^{(n)} w_{ji} \sum_{k=1}^K x^{(n)}(k) \cdot \frac{\partial h_{a_j, b_j}}{\partial a_j} \quad (5)$$

$$\Delta b_j = \frac{\partial \xi}{\partial b_j} = -\frac{1}{N} \sum_{n=1}^N \sum_{p=1}^P (d_p^{(n)} - o_p^{(n)}) o_p^{(n)} (1 - o_p^{(n)}) \cdot \sum_{i=1}^I w_{ip} y_i^{(n)} w_{ji} \sum_{k=1}^K x^{(n)}(k) \cdot \frac{\partial h_{a_j, b_j}}{\partial b_j} \quad (6)$$

## 3 励磁涌流识别的自适应小波神经网络构造

### 3.1 概述

对于三相变压器的励磁涌流识别，可以利用三个自适应小波神经网络实现分相判别，网络结构采用如图 1 所示的 4 层自适应小波神经网络。由于三个自适应小波神经网络的构建和训练过程完全相同，下面只针对一相（A 相）进行详细论述。

### 3.2 输入层和输出层

自适应小波神经网络的输入是待识别信号的采样值，因此选取变压器一相差动电流的采样值作为自适应小波神经网络的输入。选择数据窗的长度为一个周波（20ms），当采样频率为 2400Hz 时，网络的输入节点数为 48 个。而网络的输出层则采用单节点形式，分别用 1 和 0 代表变压器励磁涌流和内部故障。




图1 自适应小波神经网络的结构

Fig.1 Structure of adaptive wavelet neural network

3.3 小波层

小波层结构的确定包括了母小波的选择、小波节点数的确定及小波参数的初始化。它是构建自适应小波神经网络的关键所在。

(1) Morlet 小波

对于小波函数的选择，目前还没有普遍适用的原则。小波函数的性质是相互制约的，不可能同时达到最佳，一般可结合待分析信号的特点和小波变换的具体应用折衷处理。利用自适应小波神经网络对励磁涌流的波形进行识别，其本质是通过尺度因子和位移因子的修正，寻找一组最适合表征待分类信号特征的超小波。因此，对母小波函数的正交性、分频特性等要求并不很严格，但其必须是连续小波，且有较简洁的时域解析式。此外，保护的实时性要求母小波具有较好的时域紧支性。

本文选择了 Morlet 小波作为自适应小波神经网络的母小波，其常用的形式为

$$h(t) = \cos \omega_0 t e^{-\frac{t^2}{2}} \quad (7)$$

Morlet 小波是 Morlet 等为了使 Gaussian 函数满足小波函数的定义，对高斯函数加以调制所构造的小波。Morlet 小波具有良好的时频局部化特性。式(7)所对应的形式并不满足容许条件，因为  $H(\omega=0) \neq 0$ ，但当  $\omega_0$  选择合适时（如  $\omega_0 \geq 5$ ），在工程上便近似满足条件。图 2 所示为 Morlet 小波（ $\omega_0 = 5$ ）所对应的时域和频域波形。




图2 Morlet 小波的时域、频域波形

Fig.2 Morlet wavelet in time and frequency domain

(2) Morlet 小波的参数选择

Morlet 小波所对应的小波族为

$$h_{a,b}(t) = \cos(\omega_0 \frac{t-b}{a}) \cdot e^{-\frac{(t-b)^2}{2a^2}} \quad (8)$$

其时频窗为

$$[b - \frac{a}{\sqrt{2}}, b + \frac{a}{\sqrt{2}}] \times [\frac{\omega_0}{a} - \frac{1}{a\sqrt{2}}, \frac{\omega_0}{a} + \frac{1}{a\sqrt{2}}] \quad (9)$$

下面结合本文的具体应用讨论 Morlet 小波参数的选择。

1) 尺度因子 a

利用计算机进行小波变换时需要对小波函数离散化。由 Nyquist 条件可知，其采样频率必须满足  $f_{\text{Sampling}} \geq 2f_{\text{max}}$ ， $f_{\text{max}}$  为小波函数的最高频率。以  $\omega_0 = 5$  的 Morlet 小波为例，由图 2(b)可知，当  $a = 1$  时，可以取  $f_{\text{max}} \approx 1.25\text{Hz}$ （即  $\omega_{\text{max}} = 7.85\text{rad}$ ），则有  $f_{\text{Sampling}} \geq 2.5\text{Hz}$ 。因此，对应不同的  $a$ ，必须满足

$$f_{\text{Sampling}} \geq \frac{2.5}{a} \quad (10)$$

在自适应小波神经网络中，Morlet 小波的采样率等效于  $f_{\text{Sampling}} = 1\text{Hz}$ ，因此必须取

$$a \geq 2.5 \quad (11)$$

图 3(a)给出了长数据窗（480 个采样点）时， $\omega_0 = 5$  的 Morlet 小波对应不同  $a$  值的幅频响应。由图可见，当  $a = 1$  时，不满足式(11)，其幅频响应出现了严重的混迭现象；图 3(b)则为  $\omega_0 = 10$  时的 Morlet 小波幅频响应，同样当  $a = 2$  时，由于不满足 Nyquist 条件，幅频响应也出现了混迭现象。




图3 长数据窗时，Morlet 小波的幅频响应

Fig.3 Amplitude-frequency response for long data window

由式(9)可知，随着  $a$  增大，小波函数的频窗向低频的方向移动，且频窗的宽度变窄，但其时窗宽度则随之变宽。图 3(a)和图 3(b)给出了随着  $a$  增大，Morlet 小波的幅频响应。然而在实际应用时，由于被分析信号的数据窗长度（采样点数）是一定的，当小波函数的时窗宽度大于数据窗长度时，必然会造成一定的能量损失，因此， $a$  值不可以随意增大。

当给定Morlet小波的时窗宽度 $\Delta t$ 时，可以给出

$$a\Delta t \leq K - 1 \quad (12)$$

式中  $K$  为待分析信号的数据窗长度。

对于数据窗长度  $K = 48$ ，当  $\Delta t = 8$  时， $a \leq 5.875$ ，此时能量的损失率为  $1.538 \times 10^{-8}$ ，已经可以看成没有能量损失。在本文的应用中并不需要如此严格的要求，当取  $\Delta t = 2.5$  时，时窗中的能量已经集中了时域的主要能量（92.3%），此时有  $a \leq 18.8$ 。

图 4(a)、(b)给出了短数据窗时（ $K = 48$ ），随着  $a$  的增加 Morlet 小波所对应的幅频响应。比较图 3 和图 4 可以看出，短数据窗跟长数据窗相比，大部分 Morlet 小波幅频响应都能保持相似的波形，但都有不同程度的能量损失，而且  $a$  越大能量损失越严重；当  $a$  增大到一定程度时，幅频响应波形会出现严重的畸变，如图 4(a)中的  $a = 24$  时的幅频响应。




图 4 短数据窗时，Morlet 小波的幅频响应  
Fig.4 Amplitude-frequency response for short data window

应该指出的是，这里讨论的  $a$  取值范围并不是  $a$  的严格定义域，网络的小波参数  $a$  和  $b$  最终还是要通过网络的训练决定的，但是这对参数的初始化有指导意义。

2) 中心频率  $\omega_0$

由式(9)可知，随着  $\omega_0$  的增大，小波函数的频窗将向频率的正方向移动，但频窗的宽度不变。因此， $\omega_0$  越大，Morlet 函数的频域分辨率将更好。由图 4(a)、(b)可见，跟  $\omega_0 = 5$  时相比， $\omega_0 = 10$  时 Morlet 小波具有更好的频域局部性，几乎不产生频域混迭。然而，其频域局部性能的改善是以增加时窗宽度为代价的，因此对于给定的数据窗长度， $\omega_0$  越大其对应的能量损失将越严重，对比图 3 和图 4 能明显看出这一点。因此，对于  $\omega_0$  的选取并不是越大越好。在这里取  $\omega_0 = 10$ 。

(3) 小波节点数及参数的初始化

小波层节点数目与所选择的小波函数及待分类信号的特征相关。一个小波节点对应一个时频

窗，确定小波节点的数目相当于确定用多少个时频窗才能最大限度地表征信号的特征。本文采用的方法是：先根据信号的幅频特性确定小波函数的  $S$  个尺度因子  $a_s$ ，然后结合每一尺度下小波函数的时域特性，确定每一尺度因子  $a_s$  所对应的  $g_s$  个位移因子  $b_g$ 。因此小波层节点数目为

$$J = \sum_{s=1}^S g_s \quad (13)$$

当要获取中心频率为 100Hz（二次谐波）的频带信息时，对于 2400Hz 的采样频率，结合 Morlet 小波的幅频特性知，尺度因子应该取  $a = 38.1$ 。考虑到所对应 Morlet 函数时域特性，取 3 个平移因子为  $b_1 = 12$ 、 $b_2 = 24$  和  $b_3 = 36$ 。根据上述原则，本文选取的小波节点数为 15。

3.4 隐层

对于神经网络隐层节点数的确定并没有很明确的方法。适当地增加隐层节点，虽然计算量会增加，却扩大了搜索空间，提供了一些有利于造成良好分类界面的非线性信息，有利于神经网络收敛。当隐层节点增加到一定程度，已找到良好的分类界面时再增加隐层节点却不一定取得更好的收敛效果。在这里选取隐层节点数为 15。

因此，所构建的自适应小波神经网络结构为 48-15-15-1。

4 自适应小波神经网络的训练

4.1 训练样本的选取

小波神经网络对于信息识别效果的好坏，完全取决于训练样本集的数量和质量，如果选取的样本缺乏所要分类信息的典型特征，则网络的存储和记忆功能就起不到相应的作用。样本的选取不当最终可能导致网络收敛速度慢或是根本无法收敛。

本文利用 ATP-EMTP 程序仿真生成自适应小波神经网络的训练样本。仿真的系统结构如图 5 所示。所采用的训练样本尽可能地包括变压器各种情况的内部故障和励磁涌流。



图 5 仿真系统图  
Fig.5 Simulated power system

变压器内部故障包括了变压器内部绕组的匝间短路、匝地短路及变压器引出线的短路故障。对

于变压器内部绕组的匝间、匝地短路仿真,本文采用了文献[14]所介绍的方法,对不同位置的匝地短路和不同匝数的匝间短路进行了仿真。而变压器引出线的短路故障则考虑了各种故障类型:单相接地短路、两相短路、两相接地短路、三相接地短路。结合不同的故障初始角,共生成内部故障样本 250 个。每一样本取故障发生后一周差流的 48 个采样值,即数据窗长度为 20ms。

励磁涌流样本包括了空载合闸和外部故障切除两种情况。变压器空载合闸时的励磁涌流波形跟变压器三相的剩磁及合闸初相角有关,在仿真生成训练样本时,考虑了上述两种因素对励磁涌流的影响。由于变压器采用了 $\Delta/Y_0$ 接法,因此励磁涌流样本实际上包括了各种情况下的单向涌流和对称涌流。此外,随着数据窗的移动,其所包含的励磁涌流波形将有所不同(见图6)。对于同一个励磁涌流波形,数据窗平移一个点将生成一个样本,考虑平移一周,则对应一种励磁涌流情况将生成 48 个样本(一周采样 48 个点)。这样 30 种励磁涌流情况共生成励磁涌流样本 1440 个。

因此,训练样本总数为 1690 个。




图6 数据窗的移动  
Fig.6 Moving data window

#### 4.2 样本的预处理

自适应小波神经网络是基于 BP 算法的,神经元的输出范围在 0 到 1 之间,如果神经元输入的绝对值过大,会导致神经元饱和。同时本文主要是基于波形特征进行分析,而不考虑波形的大小。因此,对原始数据进行如下预处理

$$i'_k = \frac{i_k}{\text{Max}(|i_1|, |i_2|, \dots, |i_K|)} \quad k=1, 2, \dots, K \quad (14)$$

式中  $i_k$  为数据窗的第  $k$  个采样值;  $i'_k$  为网络的第  $k$  个输入值。

显然经过这样的处理,各个样本的数据都限制在  $[-1, 1]$  的范围内,但它们的波形特征并没有改变。

#### 4.3 网络的训练

利用训练样本集对所构造的自适应小波神经网络进行训练,设定网络的训练目标为所有训练样

本的输出与各自的目标值之间误差小于限定值,这里取 0.1。对于小波参数(包括  $a$  和  $b$ )的初始化前面已有论述,而其他权参数  $\omega$  的初始值则随机给定。网络的学习误差曲线如图 7 所示,由图可见,所建立的小波神经网络具有快速收敛能力。




图7 学习过程的误差曲线  
Fig.7 Errors during learning process

### 5 自适应小波神经网络的测试

#### 5.1 网络的测试

对于训练好的自适应小波神经网络,还需利用其他的非训练样本,来检验网络对变压器励磁涌流和故障电流的识别能力。本文同样利用 ATP-EMTP 仿真生成小波神经网络的测试样本。对于内部故障,根据不同的故障条件生成了 42 个测试样本;而励磁涌流,则取 30 种不同涌流条件下的励磁涌流作为测试样本。考虑到数据窗的移动,对于每种情况,随着时序的推移各取了 480 个样本(对应 10 个周期)。

自适应小波神经网络测试过程中,励磁涌流闭锁的判据为:

输出  $o > 0.5$ , 则判为励磁涌流;

输出  $o < 0.5$ , 则为内部故障。

表 1 给出了测试的结果,对于所有的测试样本,训练好的小波神经网络都能作出正确的判断,误判率为 0。对于励磁涌流,网络输出与目标值的最大误差为 0.059,略大于内部故障时的情况(0.04),这说明所训练的自适应小波神经网络具有良好的推广能力。图 8 是发生励磁涌流时,随着时序的推移自适应小波神经网络的输出。由图可见,对于所有时刻网络都能作出正确的响应,不会受到数据窗移动的影响。这说明所建立的小波神经网络能准确、可靠地识别出变压器的励磁涌流状态。

表 1 自适应小波神经网络的测试结果  
Tab.1 Test results of adaptive wavelet neural network

变压器状态	测试样本数	识别率/%	最大误差
内部故障	42	100	0.040
励磁涌流	14400	100	0.059




图 8 励磁涌流所对应的网络输出  
Fig.8 Network output of inrush

5.2 进一步的分析

表 2 给出了相同网络结构 (48-15-15-1) 和相同的初始化条件下, 小波层参数不相同时的计算结果。其中, 自适应小波分别取  $\omega_0=10$  和  $\omega_0=5$  两种情况; 而非自适应小波取  $\omega_0=10$ , 但其小波参数在网络学习过程中不进行修正。由表 2 可见,  $\omega_0=10$  的自适应小波神经网络的训练收敛速度和测试的最大误差都要优于  $\omega_0=5$  时的结果, 说明选择  $\omega_0=10$  是正确的; 而对于非自适应小波, 网络尽管能够收敛, 但是收敛速度很慢, 而且训练好的网络对测试样本并不能够达到 100% 的识别率, 其性能显然不如自适应小波神经网络。

表 2 不同小波参数的自适应小波神经网络比较  
Tab.2 Comparison among adaptive wavelet neural networks with different wavelet parameters

小波神经网络	小波参数	训练周期	识别率/%	测试的最大误差
自适应	$\omega_0=10$	852	100	0.059
	$\omega_0=5$	1090	100	0.158
非自适应	$\omega_0=10$	2503	96.7	-

自适应小波神经网络推广能力的好坏直接关系到其是否具有实用性。对多层前馈神经网络而言, 提高网络推广能力的一个公认原则是: 为了提高推广能力, 应选择能反映例子隐含规律的最简单 (隐层节点数最小的) 的网络<sup>[15]</sup>。此外, 隐层节点数少还能减少网络的计算量, 这对于在继电保护中的应用极为关键。为此, 本文对不同隐层节点数的自适应小波神经网络进行了计算, 其结果见表 3。根据表 3 的结果, 最终可以选择自适应小波神经网络的结构为 48-15-5-1。

表 3 不同结构的自适应小波神经网络比较  
Tab.3 Comparison among adaptive wavelet neural networks with different configuration

网络结构	训练周期	识别率/%
48-15-15-1	852	100
48-15-10-1	1090	100
48-15-5-1	1397	100
48-15-4-1	不收敛	-

6 结论

自适应小波神经网络将小波分析和神经网络结合起来, 并在学习过程中自适应地调整小波参数, 更有利于信号特征的提取。本文建立了一个用于区分变压器励磁涌流和内部故障电流的自适应小波神经网络, 对训练后的网络进行了训练和测试, 其结果表明: 该方法能准确、可靠地识别出变压器的励磁涌流状态。尽管在理论和工程实现中还有很多方面需要进一步研究、完善, 但本文的工作已经充分证明了自适应小波神经网络完全可以作为一种可选方案用于变压器励磁涌流和内部故障电流的识别。

参考文献

- [1] 王维俭. 电气主设备继电保护原理与应用[M]. 北京: 中国电力出版社, 2002.
- [2] 何奔腾, 徐习东. 波形比较法变压器差动保护原理[J]. 中国电机工程学报, 1998, 18(6): 395-398.  
He Benteng, Xu Xidong. Protection based on wave comparison [J]. Proceedings of the CSEE, 1998, 18(6): 395-398.
- [3] 焦劭华, 刘万顺. 区分变压器励磁涌流和内部短路的积分型波形对称原理[J]. 中国电机工程学报, 1999, 19(8): 1-5.  
Jiao Shaohua, Liu Wanshun. A novel scheme to discriminate inrush current and fault current based on integrating the waveform[J]. Proceedings of the CSEE, 1999, 19(8): 1-5.
- [4] Bastard P, Meunier M, Regal H. Neural-network- based algorithm for power transformer differential relays [J]. IEE Proc., Generation, Transmission and Distribution, 1995, 142(4): 386-392.
- [5] Perez L G, Flechsig A J, Meador J L *et al.* Training an artificial neural network to discriminate between magnetizing inrush and internal faults [J]. IEEE Transactions on Power Delivery, 1994, 9(1): 434-441.
- [6] 段玉倩, 贺家李, 贺继红. 基于神经网络方法的微机变压器保护[J]. 中国电机工程学报, 1998, 3(18): 190-194.  
Duan Yuqian, He Jiali, He Jihong. Computerized transformer protection based on artificial neural network[J]. Proceedings of the CSEE, 1998, 3(18): 190-194.
- [7] 焦绍华, 刘万顺, 刘建飞, 等. 用小波理论区分变压器的励磁涌流与短路电流的新原理[J]. 中国电机工程学报, 1999, 19(7): 1-5, 76.  
Jiao Shaohua, Liu Wanshun, Liu Jianfei *et al.* A new principle of discrimination between inrush current and fault current of transformer based on wavelet[J]. Proceedings of the CSEE, 1999, 19(7): 1-5, 76.
- [8] 林湘宁, 刘沛, 程时杰. 基于小波包变换的变压器励磁涌流识别新方法[J]. 中国电机工程学报, 1999, 19(8): 14-19, 38.  
Lin Xiangning, Liu Pei, Cheng Shijie. A wavelet packet based new algorithm used to identify the inrush[J]. Proceedings of the CSEE, 1999, 19(8): 14-19, 38.
- [9] 李贵存, 刘万顺, 贾清泉, 等. 一种利用小波原理防止变压器差动保护误动的新算法[J]. 电网技术, 2001, 25(7): 48-52.  
Li Guicun, Liu Wanshun, Jia Qingquan *et al.* A new algorithm to

- prevent misoperation of transformer differential protection based on principle of wavelet transform[J]. Power System Technology, 2001, 25(7): 48-52.
- [10] 王莉丽, 荣雅君. 基于小波神经网络的变压器励磁涌流和内部故障电流识别[J]. 继电器, 2003, 7(15): 20-23.  
Wang Lili, Rong Yajun. Discrimination between inrush current and internal fault current based on wavelet neural network[J]. Relaying, 2003, 7(15): 20-23.
- [11] Mao P L, Aggarwal R K. A novel approach to the classification of the transient phenomena in power transformer using combined wavelet transform and neural network [J]. IEEE Trans. on Power Delivery, 2001, 16(4): 654- 660.
- [12] Szu H H, Telfer B, Kadambe S. Neural network adaptive wavelets for signal representation and classification [J]. Opt. Eng., 1992, 31(9): 1907- 1916.
- [13] Telfer B A, Szu H H, Dobeck G J *et al.* Adaptive wavelet classification of acoustic backscatter and imagery [J]. Opt. Eng, 1994, 33(7): 2190-2203
- [14] Bastrard P, Bertrand P, Meunier M. A transformer model for winding fault studies[J]. IEEE Transactions on Power Delivery, 1998, 13(3): 738 -744.
- [15] 阎平凡. 人工神经网络的容量、学习与计算复杂性[J]. 电子学报, 1995, 23(4): 63-67.  
Yan Pingfan. Capacity, learning and computational complexity of artificial neural networks[J]. ACTA Electronica Sinica, 1995, 23(4): 63-67.
- 
- 收稿日期: 2004-09-03。  
作者简介:  
李海锋(1976-), 男, 博士, 研究方向为电力系统继电保护及自动化;  
王 钢(1966-), 男, 博士, 教授, 博士生导师, 主要研究方向为电力系统继电保护及自动化、电力电子;  
李晓华(1975-), 女, 博士, 讲师, 主要从事电力系统继电保护的教学科研工作。