

# 基于 S 变换和扩张神经网络的电能质量扰动分类

何为, 杨洪耕

(四川大学电气信息学院, 四川 成都 610065)

**摘要:** 提出了一种基于 S 变换和扩张神经网络的电能质量扰动分类方法。首先使用 S 变换对扰动信号进行时频分析, 研究了在有多种扰动同时发生的情况下, 从 S 变换的结果中提取扰动特征量的方法, 得到了由基频特征矢量、高频特征矢量、相位特征矢量组成的特征矢量组。最后, 将提取出来的扰动特征矢量组送入由扩张神经网络构建的分类器中, 完成对扰动的分类。扩张神经网络以扩张距离代替欧氏距离来衡量测试数据与聚类中心的相似度, 分类正确率高、结构简单、训练快速。仿真结果表明, 该方法能准确地对扰动进行分类, 对噪声不敏感。

**关键词:** 电力系统; 电能质量扰动; S 变换; 扩张神经网络; 扰动分类

## Power quality disturbances classification based on S-transform and extension neural network

HE Wei, YANG Hong-geng

(School of Electric Engineering & Information, Sichuan University, Chengdu 610065, China)

**Abstract:** A new approach combining S-transform and Extension Neural Network (ENN) to classify power quality disturbances is proposed in this paper. At first, power quality disturbance signals are decomposed with S-transform time-frequency analysis. Then, the paper studies the results of S-transform in order to extract power quality disturbances' feature matrixes which are composed of fundamental frequency vector, high frequency vector and phase vector. At the same time, some concurrent disturbances are also analyzed. At last, the feature matrixes are input into the classification machine based on ENN to identify power quality disturbance types. ENN uses extension distance instead of Euclidean distance to measure similarities between tested data and cluster centers, so it has high classification correct ratio, simple structure, and short learning times. Numerical simulation results show that the proposed method has an excellent performance on correct ratio and is insensitive to noise.

**Key words:** power system; power quality disturbances; S-transform; extension neural network; disturbances classification

中图分类号: TM711

文献标识码: A

文章编号: 1003-4897(2007)05-0063-05

## 0 引言

随着非线性和冲击性负荷的快速增长以及敏感设备的广泛应用, 电能质量问题正日益受到电力部门和用户的关注。对各种电能质量扰动进行准确的辨识是控制和治理电能质量问题的前提<sup>[1]</sup>。

目前, 小波变换凭借其良好的时频特性被广泛用于电能质量扰动的特征提取<sup>[2,3]</sup>。但小波变换的结果缺乏直观性<sup>[4]</sup>, 且存在频谱泄露和易受噪声影响的问题。S 变换<sup>[5]</sup>作为小波变换的一种发展, 已经被用于电能质量扰动的分类<sup>[4,6,7]</sup>。信号 S 变换的结果为一个复时频矩阵, 其中包含了信号幅值、相位随时间和频率的分布信息, 适合从中提取电能质量扰动的特征。由于电能质量扰动涉及的特征量太多, 分类判据复杂易错, 因此多数情况下需要借助

人工智能的方法完成对扰动的分类。人工神经网络 (ANN) 在扰动的分类中使用最为广泛, 但传统的 ANN 存在收敛性较差, 训练时间较长, 可靠性有限的问题<sup>[7]</sup>。支持向量机是一种统计学习算法, 所需训练样本少, 对特征矢量维数的限制少, 但其识别能力易受自身参数的影响<sup>[8]</sup>。文献[9]提出了一种基于扩张理论的神经网络, 扩张神经网络 ENN (Extension Neural Network)。ENN 使用扩张距离代替欧氏距离来衡量测试数据与聚类中心的相似度, 分类准确率高, 上限连接权和下限连接权的使用使得训练更加快速, 且该网络仅由输入层和输出层组成, 结构简单。ENN 已经被用于变压器的故障诊断以及电流互感器的局部放电诊断<sup>[10,11]</sup>, 取得了较理想的效果。

本文使用 S 变换得到扰动信号的复时频矩阵,

求模后便得到与之对应的模时频矩阵。研究了在有多种扰动同时发生<sup>[12]</sup>的情况下,从这两个矩阵中提取扰动特征量的方法,得到了由基频特征矢量、高频特征矢量、相位特征矢量组成的特征矢量组,且该矢量组中的特征矢量不受扰动发生时刻及频率的影响。在此基础上,使用 ENN 构建了一个由基频子网、高频子网以及相位子网组成的分类器。该分类器结构紧凑,易于扩容和修改,训练时间短,不仅能对基本扰动进行准确地分类,对几种常见的多种扰动同时发生时的扰动分类也有较理想的效果。仿真结果证明了本文所提分类方法的有效性。

## 1 S 变换基本原理

S 变换是由 Stockwell 等学者于 1996 年首次提出的一种时频可逆的分析方法,是连续小波变换和短时傅立叶变换的一种发展。S 变换中高斯窗口的高度和宽度随频率而变化,这就克服了短时傅立叶变换窗口高度和宽度固定的缺陷。信号  $h(t)$  的一维连续 S 变换定义如下。

$$S(\tau, f) = \int_{-\infty}^{\infty} h(t)w(\tau-t, f)\exp(-i2\pi ft)dt \quad (1)$$

$$w(\tau-t, f) = \frac{|f|}{\sqrt{2\pi}} \exp\left[-\frac{f^2(\tau-t)^2}{2}\right] \quad (2)$$

式中:  $w(\tau-t, f)$  为高斯窗口,  $\tau$  为时间,  $f$  为频率,  $i$  为虚数单位。S 变换的离散表示形式为

$$S[m, n] = \sum_{k=0}^{N-1} H[n+k] \exp\left(-\frac{2\pi^2 k^2}{n^2}\right) \exp\left(\frac{i2\pi km}{N}\right) \quad (n \neq 0) \quad (3)$$

$$\text{式中: } H[n] = \frac{1}{N} \sum_{k=0}^{N-1} h[k] \exp\left(\frac{-i2\pi kn}{N}\right) \quad (4)$$

当  $n=0$  时的离散 S 变换定义为

$$S[m, n] = \frac{1}{N} \sum_{k=0}^{N-1} h[k] \quad (5)$$

式中:  $h[k]$  是对连续时间信号  $h[t]$  进行采样得到的离散时间序列。S 变换可以由 FFT 实现快速计算。 $h[k]$  经 S 变换过后得到一个复时频矩阵,对矩阵中的各个元素求模值后便得到与之对应的模时频矩阵。从 S 变换结果的行向量中,可以方便地提取该行向量对应频率上信号的幅值或相位等随时间变化的特征,因而非常适合分析电能质量扰动信号。

## 2 提取扰动特征

扰动信号 S 变换的结果为一个时频矩阵,如果

不经过处理直接用来对扰动进行分类,会导致分类系统过于庞大,且容易湮没扰动的特征,使分类正确率受到影响,因而有必要对 S 变换的结果进行后处理。通过从 S 变换的结果中提取出扰动特征量,可以去除大量的冗余信息,突出扰动特征,简化分类系统的结构,从而提高分类正确率。

对于特征集中在基频的扰动如:电压凹陷、电压突起、电压中断等,较容易从 S 变换模时频矩阵的基频行向量中提取扰动特征量。但对于特征集中在高频的扰动如振荡暂态、谐波等,要从 S 变换的模时频矩阵中提取出简单、可靠的特征量就比较困难。这是因为此类扰动的特征分布频带很广,要从 S 变换的模时频矩阵中提取出扰动特征量,就需要处理模时频矩阵中的大量行向量,且相当一部分行向量对提取扰动特征并无作用。故考虑先对模时频矩阵中的高频行向量进行搜索,选定扰动特征最明显的行向量再提取特征。当考虑了多种扰动同时发生的情况时,针对其中某一类扰动提取的特征量必须能准确反映该类扰动的特征,避免其他扰动特征的干扰。根据以上原则,确定本文的特征矢量组  $v = \{v_1, v_2, v_3\}$ , 其中,  $v_1$  为基频特征矢量,  $v_2$  为高频特征矢量,  $v_3$  为相位特征矢量。各特征矢量的具体定义如下:

1) 基频特征矢量  $v_1 = \{v_{11}, v_{12}, v_{13}, v_{14}\}$ , 其中,  $v_{11}$ 、 $v_{12}$ 、 $v_{13}$ 、 $v_{14}$  依次为模时频矩阵的基频行向量中幅值小于 0.1 的元素个数(正弦信号基频幅值为 1),幅值在 0.1~0.95 之间的元素个数,幅值在 0.95~1.05 之间的元素个数以及幅值大于 1.05 的元素个数。 $v_{11}$ 、 $v_{12}$ 、 $v_{14}$  分别用来反映中断、凹陷、突起的特征,  $v_{13}$  用来反映扰动信号在基频无明显幅值变化。得到特征矢量  $v_1$  过后,再用公式  $v_1 = v_1/N$  进行归一化处理,  $N$  为扰动信号长度。由于相位跳变的基频特征矢量有时会体现出凹陷的特征,因此当出现电压凹陷和相位跳变同时发生的扰动时,很难将其与相位跳变区分开。相位跳变及凹陷的基频幅度时间曲线如图 1 所示。

因此,需要对  $v_{12}$ 、 $v_{13}$  进行适当地修正。首先利用公式(6)计算得到  $d$ 。 $d$  能准确地反映相位跳变持续时间内的基频幅值上升,如图 1 所示,故利用  $d$  的计算结果能将相位跳变与凹陷区分开。

$$d = d_{\max} - d_{\min 1} \quad (6)$$

设  $d_{\min 1}$  和  $d_{\min 2}$  分别为  $v_{12}$  的极值点中,幅值最小的两个点,  $d_{\min 1} < d_{\min 2}$ , 根据这两个点在基频行向量中的位置,便可确定其间的最大值  $d_{\max}$ 。当

$d > 0.03$ , 且  $v_{12}$  的极值点个数大于等于 3 时, 先后使用公式  $v_{13} = v_{12} + v_{13}$  及  $v_{12} = 0$ , 对  $v_{13}$ 、 $v_{12}$  进行修正。

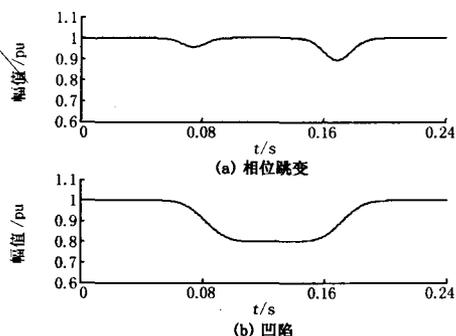


图 1 相位跳变及凹陷的基频幅度时间曲线

Fig.1 Fundamental frequency amplitude curve of phase angle jump and sag

2) 高频特征矢量  $v_2 = \{v_{21}, v_{22}, v_{23}\}$ , 首先利用公式(7)、(8)计算得到  $mv1$ 、 $mv2$ , 分别用来反映振荡暂态在模时频矩阵高频行向量中幅值的局部突起以及谐波在高频行向量中的幅值平均值。

$$mv1(m - M_{150}) = \frac{1}{6} \sum_{n=g}^{g+5} x[m, n] \quad M_{150} \leq m \leq M \quad (7)$$

$$mv2(m - M_{150}) = \frac{1}{N} \sum_{n=0}^{N-1} x[m, n] \quad M_{150} \leq m \leq M \quad (8)$$

式中:  $x$  为模时频矩阵,  $M_{150}$  为  $x$  中 150 Hz 对应的行号,  $M$  为  $x$  的行数,  $g$  为  $x$  第  $m$  行的最大值所对应的采样点序号。由公式  $v_{21} = \max(mv1)$ 、 $v_{22} = \max(mv2)$  便可计算得到  $v_{21}$ 、 $v_{22}$ 。当凹陷或突起的幅值较大时, 其模时频矩阵的高频部分会出现两条明显的“隆起”, 如图 2 所示。

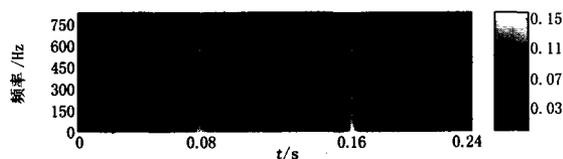


图 2 模时频矩阵图像

Fig.2 Module time-frequency matrix image

因此, 在考虑了多种扰动同时发生的情况下, 仅根据  $v_{21}$ 、 $v_{22}$  往往会误判凹陷或突起在高频部分有扰动发生, 本文通过引入特征量  $v_{23}$  来消除其影响。 $v_{23}$  由公式(9)计算得到。由于凹陷在高频的“隆起”峰值随频率的变化很小, 凹陷的  $v_{23}$  值明显小于振荡暂态和谐波的  $v_{23}$  值, 故引入特征量  $v_{23}$  能消除提取扰动高频特征时凹陷所带来的干扰。

$$v_{23} = \left( v_{21} - \frac{1}{M - M_{150} + 1} \sum_{m=M_{150}}^M mv1(m - M_{150}) \right) / v_{21} \quad (9)$$

3) 相位特征矢量  $v_3$ , 首先由公式(10)计算出相位偏移值  $paj$ 。

$$\begin{cases} paj(1) = |ma - \max(ang)| \\ paj(2) = |ma - \min(ang)| \end{cases} \quad (10)$$

于是, 得到  $v_3 = \max(paj)$ 。 $v_3$  不仅有效地提取了相位跳变的特征, 而且不受扰动信号初始相位的影响。式中,  $ang$  为基频的相位行向量,  $ma$  为  $ang$  中位置在  $0 \sim n_{max}$  之间的元素的平均值,  $n_{max}$  为相邻两点相位变化率  $c_n$  首次大于 0.001 时所对应的序号。如果前两个周期内未出现  $c_n > 0.001$  的点, 则  $ma$  为  $ang$  中位置在  $0 \sim 2N_T$  之间的元素的平均值,  $N_T$  为单个周期的采样点数。

$$c_n = |(ang(n) - ang(n+1)) / ang(n)| \quad (11)$$

### 3 基于扩张神经网络的分类器

#### 3.1 扩张神经网络的基本原理

ENN 使用扩张距离代替欧氏距离来衡量测试数据与聚类中心的相似度, 不需要隐含层, 因此具有结构简单、不易受参数影响的特点。此外, 上限连接权和下限连接权的使用, 使得 ENN 的训练时间极短。ENN 在变压器的故障诊断以及电流互感器的局部放电诊断的应用, 已取得了较理想的效果。ENN 的具体结构如图 3 所示。

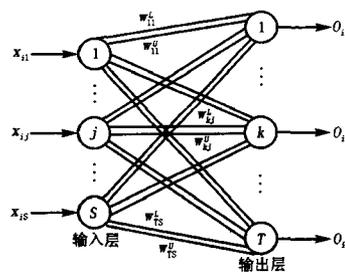


图 3 ENN 结构图

Fig.3 The structure of ENN

从图 3 中可以看出, ENN 由输入层和输出层组成, 输入节点  $j$  与输出节点  $k$  之间由两个权值连接, 分别为: 上限连接权  $w_{kj}^u$ , 下限连接权  $w_{kj}^l$ 。在 ENN 中, 输出层即为竞争层, 由输出非零的节点决定输入矢量的所属类别。设训练样本为  $\{X_1, L_1\}, \{X_2, L_2\}, \dots, \{X_Q, L_Q\}$ ,  $Q$  为训练样本的总数,  $X_i$  为第  $i$  个样本,  $L_i$  为其对应的类别编号, 训练步骤如下:

1) 使用公式(12)、(13)初始化连接权。

$$w_{kj}^L = \min\{x_{ij}\} \quad (12)$$

$$w_{kj}^U = \max\{x_{ij}\} \quad (13)$$

$i=1,2,\dots,Q; j=1,2,\dots,S; k=1,2,\dots,T.$

2) 读取第  $i$  个样本  $X_i$ 。

3) 使用公式(14)计算  $X_i$  与第  $k$  个聚类中心的扩张距离。式中,  $\beta$  为比例因子, 本文取 0.002。

$$\begin{cases} ED_{ik} = \sum_{j=1}^S \left( \frac{x_{ij} - (w_{kj}^U + w_{kj}^L)/2}{(w_{kj}^U - w_{kj}^L)/2} \right) & w_{kj}^U - w_{kj}^L \neq 0 \\ ED_{ik} = \sum_{j=1}^S \left( \frac{x_{ij} - (w_{kj}^U + w_{kj}^L)/2}{\beta} \right) & w_{kj}^U - w_{kj}^L = 0 \end{cases} \quad (14)$$

4) 由式  $ED_{iq} = \min\{ED_{ik}\}$  确定  $X_i$  的类别号, 如果  $q = p$ , 其中  $p = L_i$ , 转到步骤 6), 否则转步骤 5)。

5) 使用公式(15)、(16)更新权值。 $\eta$  为学习率, 本文取 0.01。

$$\begin{cases} w_{pj}^{L(new)} = w_{pj}^{L(old)} + \eta \left( x_{ij} - \frac{w_{pj}^{L(old)} + w_{pj}^{U(old)}}{2} \right) \\ w_{pj}^{U(new)} = w_{pj}^{U(old)} + \eta \left( x_{ij} - \frac{w_{pj}^{L(old)} + w_{pj}^{U(old)}}{2} \right) \end{cases} \quad (15)$$

$$\begin{cases} w_{qj}^{L(new)} = w_{qj}^{L(old)} - \eta \left( x_{ij} - \frac{w_{qj}^{L(old)} + w_{qj}^{U(old)}}{2} \right) \\ w_{qj}^{U(new)} = w_{qj}^{U(old)} - \eta \left( x_{ij} - \frac{w_{qj}^{L(old)} + w_{qj}^{U(old)}}{2} \right) \end{cases} \quad (16)$$

6) 重复步骤 2)~5), 直到所有训练样本处理完毕。

7) 如果满足收敛条件或超过了预定的迭代次数, 那么停止训练; 否则转到步骤 3)。

当 ENN 训练完毕过后, 先输入扰动的特征矢量, 再利用式  $ED_{iq} = \min\{ED_{ik}\}$  计算得到  $q$ , 将输出  $O_{iq}$  置为 1, 其余输出均为 0。该扰动即被判定为第  $q$  个输出节点所对应的扰动类型。

### 3.2 分类器结构

本文的分类器由 3 个 ENN 子网组成, 分别用来处理基频、高频、相位特征, 其结构如图 4 所示。

当以“输入节点数-输出节点数”的形式来表示 ENN 的网络结构时, 基频子网、高频子网、相位子网的网络结构依次为: 4-4、3-3、1-2。基于 ENN 的分类器采用子网结构过后, 有效地缩短了分类器的训练时间, 且便于对其进行修改和扩充。尤其当

考虑了多种扰动同时发生的情况时, 可根据各个子网输出结果的组合对其扰动类型进行判断, 故分类器的规模得到了有效地控制, 结构更加紧凑。由于电压中断的幅值在 0.1 附近且持续时间很短的情况下, 易被基频子网误判为凹陷, 故对判定为凹陷的扰动信号还需要进一步确认。当某一扰动信号被基频子网判定为凹陷时, 计算其归一化均方根值<sup>[3]</sup>, 如果计算结果中幅值小于 0.1 的点大于等于 1 个时, 便将该扰动信号改判为中断, 否则维持原来的判定。

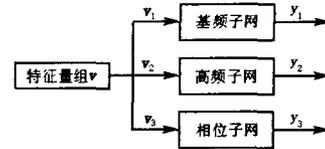


图 4 基于 ENN 的分类器结构

Fig.4 Structure of classifier based on ENN

## 4 仿真结果

本文采用 Matlab 生成扰动信号, 长度取 12 个周期。采样频率为 1.6 kHz。考虑的基本扰动有电压凹陷、电压中断、电压突起、谐波、振荡暂态、相位跳变。训练样本集中, 除了每类基本扰动的 50 个训练样本外, 还加入了“凹陷+振荡暂态”和“凹陷+谐波”的训练样本各 30 个, 但只参加高频子网的训练; 测试样本集中, 每类扰动的测试样本均为 200 个。由于电压中断由基频子网便可完成识别, 且未考虑电压中断和其他扰动同时发生的情况, 故不参加高频子网和相位子网的训练。训练完毕后, 将待分类扰动的基频特征矢量  $v_1$ 、高频特征矢量  $v_2$ 、相位特征矢量  $v_3$  送入对应的子网当中, 根据每个子网的输出结果, 综合判断该扰动的类型。详细的分类结果如表 1 所示。

表 1 电能质量扰动分类结果

Tab.1 Classification results of power quality disturbance

扰动类型	信噪比		
	40 dB	30 dB	20 dB
凹陷	99.5%	99.5%	98%
中断	100%	100%	99.5%
突起	100%	99.5%	99%
谐波	100%	99%	99%
振荡暂态	98%	98.5%	94.5%
相位跳变	100%	99%	97.5%
凹陷+谐波	99.5%	99.5%	97%
突起+谐波	100%	99.5%	98.5%
凹陷+振荡暂态	92.5%	91%	88%
凹陷+相位跳变	99.5%	99%	96%
凹陷+谐波+相位跳变	99.5%	99%	93.5%
凹陷+振荡暂态+相位跳变	90%	90%	87.5%
平均正确率	98.2%	97.8%	95.6%

由表 1 的结果可以看出, 本文的分类方法在各种噪声环境下均有较高的分类正确率, 证明了本文的特征提取方法即使在多种扰动同时发生的情况下, 仍能够准确地提取其中每一类扰动的特征; 由 3 个 ENN 子网组成的分类器不仅能对基本的扰动进行分类, 对于多种扰动同时发生的情况同样有效。对于其他类型的扰动及可能的组合可通过引入新的特征量以及修改对应子网的输入或加入新的子网来实现分类。表 2 给出了分类器采用不同的神经网络, 信噪比为 30 dB 时, 分类效果的比较。

表 2 ENN 与其他神经网络分类效果比较

Tab.2 Comparison of classification results between ENN and other neural networks

子网类型	神经网络类型	神经网络结构	连接权数量	训练迭代次数	分类正确率/(%)
基频子网	ENN	4-4	32	1	99.5
	BP	4-9-4	72	51	99.3
	PNN	4-300-4	2 400	1	96.8
高频子网	ENN	3-3	18	4	98.2
	BP	3-7-3	42	27	98.6
	PNN	3-310-3	1 860	1	93.9
相位子网	ENN	1-2	4	1	100
	BP	1-3-2	9	5	100
	PNN	1-250-2	750	1	99.2

需要说明的是表 2 中 BP 网络的迭代次数为 10 次重复试验中, 识别率最高时的迭代次数。三类神经网络中, BP 网络和 ENN 的分类效果较为接近, 均优于 PNN。但 BP 网络的训练时间较长, 且由于初始连接权的确定具有随机性, 故训练过程不稳定, 使用同样的样本进行训练时, 迭代次数差异明显, 网络的性能也有区别。而 ENN 的上、下限连接权可以由训练样本直接确定, 只要训练样本不改变, 训练过程以及得到的结果就不会改变。PNN 虽然不需要训练, 但分类性能有限, 且隐含层节点数为训练样本个数, 给硬件实现带来了困难。可见, 综合考虑分类准确率及训练速度, ENN 有最好的效果, 且 ENN 的网络结构最简单, 不易受参数影响。

## 5 结论

1) 本文研究了从 S 变换的结果中提取扰动特征的方法。该方法提取的扰动特征矢量不受扰动发生时刻及频率的影响, 通用性强, 维数低。不仅能准确地反映基本扰动的特征, 在多种扰动同时发生的情况下仍有较理想的效果。

2) 基于 ENN 的分类器结构简单, 训练快速, 分类效果好, 且由于采用了子网的结构, 易于扩展

和修改, 在处理多种扰动同时发生的情况时, 该分类器具有更紧凑的结构。仿真结果表明, 本文所提的分类方法对噪声不敏感, 分类正确率高, 是一种有效的分类方法。

3) 接下来的工作将根据实际测量数据, 对本文所提分类方法的有效性做进一步地验证。

## 参考文献

- [1] 郑岗, 石梅香, 刘丁, 等. 基于时域、多分辨率分析和规则基的电能质量扰动分类[J]. 电网技术, 2004, 28(3): 65-68.  
ZHENG Gang, SHI Mei-xiang, LIU Ding, et al. Power Quality Disturbance Classification based on Time-domain, Rule Base and Wavelet Multi-resolution Decomposition[J]. Power System Technology, 2004, 28(3): 65-68.
- [2] 陈祥训. 采用小波技术的几种电能质量扰动的测量与分类方法[J]. 中国电机工程学报, 2002, 22(10): 1-6.  
CHEN Xiang-xun. Wavelet-based Measurements and Classification of Short Duration Power Quality Disturbances[J]. Proceedings of the CSEE, 2002, 22(10): 1-6.
- [3] 赵凤展, 杨仁刚. 基于时域、小波变换和 FFT 的电能质量扰动识别[J]. 继电器, 2006, 34(8): 50-55.  
ZHAO Feng-zhan, YANG Ren-gang. Power Quality Disturbances Classification Based on Time-domain, Wavelet Transform and FFT[J]. Relay, 2006, 34(8): 50-55.
- [4] 刘守亮, 肖先勇, 杨洪耕. 基于 S 变换模时频矩阵相似度的短时电能质量扰动分类[J]. 电网技术, 2006, 30(5): 67-71.  
LIU Shou-liang, XIAO Xian-yong, YANG Hong-geng. Classification of Short Duration Power Quality Disturbance Based on Module Time-frequency Matrixes Similarity by S-transform[J]. Power System Technology, 2006, 30(5): 67-71.
- [5] Stockwell R G, Mansinha L, Lowe R P. Localization of the Complex Spectrum: the S Transform[J]. IEEE Trans on Signal Processing, 1996, 44(4): 998-1001.
- [6] Chilukuri M V, Dash P K. Multiresolution S-Transform-Based Fuzzy Recognition System for Power Quality Events[J]. IEEE Trans on Power Delivery, 2004, 19(1): 323-330.
- [7] 占勇, 程浩忠, 丁屹峰, 等. 基于 S 变换的电能质量扰动支持向量机分类识别[J]. 中国电机工程学报, 2005, 25(4): 51-56.  
ZHAN Yong, CHENG Hao-zhong, DING Yi-feng, et al. S-transform-based Classification of Power Quality Disturbance Signals by Support Vector Machines[J]. Proceedings of the CSEE, 2005, 25(4): 51-56.

(下转第 71 页 continued on page 71)

据出现错误; 然后通过电流、有功、无功数据联合判断出某间隔出现问题, 即利用电路中的功率计算公式  $S^2 = P^2 + Q^2$ ,  $P = UI \cos \phi$ ,  $Q = UI \sin \phi$  ( $\cos \phi$  如采集不到可以按照 0.85 粗略计算)。

#### 4 运行定岗、培训、考核时应将上述新技术涵盖进去

运行工定岗、日常培训、考核中应包含上述新技术方面的知识, 不能只考核常规变电运行知识。从事变电运行管理的部门一定要高度重视运行工综合素质的培养。变电运行有关规程也应及时修编。

#### 5 结束语

变电站综合自动化系统涵盖专业面广, 技术含量较高。变电运行人员一定要高度重视对新技术、新知识的学习, 才能适应新形势下的变电运行岗位。本文只在通用层面上阐述了综合自动化变电运行人员需掌握的新知识, 探讨的问题也未作更深入分析。通过本文“抛砖引玉”, 运行人员可以查阅具体的专业书籍, 逐步提高业务水平。

本文对相关专业的维护人员也有一定的借鉴价值。

#### 参考文献

- [1] 唐涛, 诸伟楠, 杨仪松, 等. 发电厂与变电站自动化技术及其应用[M]. 北京: 中国电力出版社, 2005.  
TANG Tao, ZHU Wei-nan, YANG Yi-song, et al.

(上接第 67 页 continued from page 67)

- [8] HE Hai-bo, Starzyk J A. A Self-organizing Learning Array System for Power Quality Classification Based on Wavelet Transform[J]. IEEE Trans on Power Delivery, 2006, 21(1): 286-295.
- [9] Wang M H. Extension Neural Network[A]. In: Int Joint Conf Neural Networks[C]. 2003. 399-403.
- [10] Wang M H. Extension Neural Network for Power Transformer Incipient Fault Diagnosis[J]. IEE Proc on Gener, Transm, and Distrib, 2003, (150)6, 679-685.
- [11] WANG Mang-hui. Partial Discharge Pattern Recognition of Current Transformers Using an ENN[J]. IEEE Trans on Power Delivery, 2005, (20)3, 1984-1990.
- [12] 张秀娟, 徐永海, 肖湘宁. 基于  $dq$  变换与小波变换的

Automation Technique of Power Plant and Transformer Substation and Its Applications[M]. Beijing: China Electric Power Press, 2005.

- [2] 丁书文, 黄训诚, 胡启宙. 变电站综合自动化原理及应用[M]. 北京: 中国电力出版社, 2003.  
DING Shu-wen, HUANG Xun-cheng, HU Qi-zhou. Integrated Automation Principle and Its Applications[M]. Beijing: China Electric Power Press, 2003.
- [3] 王鸿滨. 光纤通信基础[Z]. 深圳: 华为公司, 1998.  
WANG Hong-bin. Optical Fiber Communication Principle[Z]. Shenzhen: Huawei Company, 1998.
- [4] 毕胜春. 电力系统运动及调度自动化[M]. 北京: 中国电力出版社, 2000.  
BI Sheng-chun. Power System Telecontrol and Dispatching Automation[M]. Beijing: China Electric Power Press, 2000.
- [5] 沈金官. 电网监控技术[M]. 北京: 中国电力出版社, 1997.  
SHEN Jin-guan. Power Grid Supervisory Control Technique[M]. Beijing: China Electric Power Press, 1997.

收稿日期: 2006-10-27

作者简介:

马建国 (1968-), 男, 本科, 工程师, 从事电力调度、变电运行和自动化专业管理工作; E-mail: majg9819@126.com

李启林 (1971-), 男, 本科, 工程师, 从事自动化和保护专业工作;

刘卫华 (1967-), 男, 本科, 高级工程师, 从事调度专业管理工作。

电能质量扰动检测与识别方法[J]. 电力自动化设备, 2005, (25)7, 1-5.

ZHANG Xiu-juan, XU Yong-hai, XIAO Xiang-ning. Power Quality Disturbance Detection and Identification Based on  $dq$  Conversion and Wavelet Transform[J]. Electric Power Automation Equipment, 2005, 25(7):1-5.

收稿日期: 2006-07-31; 修回日期: 2006-10-31

作者简介:

何 为 (1981-), 男, 硕士研究生, 研究方向为动态电能质量扰动辨识与分析; E-mail: scu\_hewei@163.com

杨洪耕 (1949-), 男, 教授, 博士生导师, 从事电能质量分析与控制、电力市场等方面的教学和科研工作。