

基于离散小波变换和小波神经网络的电能质量扰动检测与分类方法

改善电能质量的前提和关键是准确迅速地对电能质量各扰动进行检测和分类。提出了一种电能质量检测与分类的新方法。电能质量事件经过采样后采用离散小波变换(DWT)进行去噪,获得高信噪比的信号,然后将信号进行分解并提取出8个最优特征向量。选取sym4小波作为母小波,采用基于小波神经网络的方法对电能质量扰动信号进行辨识,从而实现对电能质量扰动的检测与分类。最后,仿真结果验证了所提出方法的有效性 with 高准确度。

田卫华 庞新富 孟祥斌 于宏涛/沈阳工程学院自动化学院
孙秋野/东北大学信息科学与工程学院

0 引言

近年来,电能质量问题越来越受到人们的广泛关注。改善电能质量的前提和关键是准确迅速地对电能质量各扰动进行检测和分类。目前电能质量扰动检测和识别的主要方法有傅里叶变换、小波变换、模糊推理和神经网络等^[1-2]。鉴于傅里叶变换在识别暂态信号方面的不足,小波变换被越来越多地应用于暂态信号的检测与识别。在文献[3-4]中,分别将小波变换与模糊推理、支持向量机相结合用于暂态电能质量扰动检测与识别。文献[5-7]阐述了基于小波变换的识别技术在电力系统中的应用以及小波神经网络在信号去噪中的应用。文献[8-9]分别提出了利用S变换和改进S变换下的模时频矩阵对电能质量扰动检测与识别

的方法,该方法分类过程简单,可信度高,抗干扰能力强。文献[10]采用决策树和支持向量机设计组合分类器,克服了特征阈值随信噪比变化难以确定的问题。文献[11]针对普通S变换的识别方法计算开销大、不能实时识别电能质量扰动的缺陷,提出利用快速S变换与最小二乘支持向量机相结合的识别电能质量扰动新方法。减小了提取特征向量所用的时间。文献[12]提出基于Euclidean分解算法的db4复小波的提升方案,并应用于暂态电能质量扰动信号的检测,提高了暂态电能质量扰动信号定位的速度和准确度。最近,复合电能质量扰动的识别问题越来越受到相关学者们的重视,S变换、支持向量机等方法分别改进推广应用于复合电能质量识别,一定程度上提高了识别方法的广谱性和准确度^[13-15]。综上所述,现有的大部分文献所提出的方法虽然在电能质量扰动识别问题上均取得了不同程度的进展,但研究的电能质量问题种类相对较少,且对复合电能质量扰动的识别准确度还有待进一步提高,所提出的方法对于广谱的电能质量扰动很难具有较高的识别准确度。在本文中,阐述了一种将离散小波变换(DWT)和小波神经网络(WN)相结合用于对电能质量扰动进行检测和分类的新方法。DWT用于提取特征向量,而小波神经网络用于对电能质量扰动进行辨识。通过对16种电能质量问题的仿真结果验证了所提出方法的高准确度和广谱性。



田卫华/副教授

关键词/Keywords

电能质量 ·
离散小波变换 ·
小波神经网络 ·
检测 ·
分类 ·

国家自然科学基金重点项目(51435009),中国博士后科学基金特别资助项目(2015T80798),辽宁省教育厅科技项目(L2014530, L2015372)。

1 小波神经网络

1.1 小波网络的基础

DWT是特征值提取的基本工具。DWT是与连续小波变换（CWT）相对而言的。一个连续时间信号的小波变换定义为

$$\text{CWT}(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \Psi^* \left(\frac{t-b}{a} \right) dt \quad a,b \in R, a \neq 0 \quad (1)$$

其中

$$\Psi_{a,b}^*(t) = \frac{1}{\sqrt{|a|}} \Psi^* \left(\frac{t-b}{a} \right) \quad (2)$$

式中， $\Psi(t)$ 为母小波；*为复共轭； a 和 b 分别为尺度因子和位移因子。

DWT是 $\text{CWT}(a,b)$ 的离散化，通过使用离散值 $a=2^m$ 和 $b=2^n$ 为尺度因子和位移因子。则

$$\text{DWT}(m,n) = \frac{1}{\sqrt{2^m}} \int_{-\infty}^{+\infty} f(t) \Psi^* \left(\frac{t-2^m n}{2^m} \right) dt \quad m,n \in Z \quad (3)$$

式中， m 和 n 分别为频率和时间。选取适当的小波变换，再通过多分辨率分析（MRA），信号 $f(t)$ 可分解为近似项低频部分 $\varphi_{m,n}(t)$ 和细节项高频部分 $\Psi_{m,n}(t)$ ，即

$$\varphi_{m,n}(t) = 2^{-(m/2)} \varphi(2^{-m}t - n) \quad (4)$$

$$\Psi_{m,n}(t) = 2^{-(m/2)} \Psi(2^{-m}t - n) \quad (5)$$

模函数与低通滤波器（滤波器系数 $\{g_0(n)\}$ ）相关联，而小波函数与高通滤波器（滤波器系数 $\{g_1(n)\}$ ）相关联。其关系如下

$$\varphi(t) = \sum_n g_0(n) \sqrt{2} \varphi(2t - n) \quad (6)$$

$$\Psi(t) = \sum_n g_1(n) \sqrt{2} \varphi(2t - n) \quad (7)$$

信号分解过程开始时，传递一个信号通过这些滤波器。近似值由低通滤波器输出，而细节项由高通滤波器输出。

1.2 小波神经网络的结构

在小波算法中，逼近任意非线性函数需要两个过程：网络构建和误差最小化。

网络构建就是用一组由母小波生成的子小波

的线性组合去逼近一个信号 $\hat{y}(t)$ 。 $\hat{y}(t)$ 可以写为

$$\hat{y}(t) = \sum_{i=1}^{N_w} I(t) \omega_i \Psi \left(\frac{t-b_i}{a_i} \right) \quad (8)$$

式中， N_w 为小波数； ω_i 为权重系数。图1为一个小波网络的结构。




图1 小波神经网络的结构

小波神经网络参数 ω_i 、 b_i 和 a_i 通过一种自适应最小均方算法来优化，以使 t 时刻的能量函数最小。令

$$e(t) = y(t) - \hat{y}(t) \quad (9)$$

式中， $y(t)$ 为期望的输出。目标函数定义为

$$E = \frac{1}{2} \sum_{t=1}^T e^2(t) \quad (10)$$

为了最大限度地减少 E ，在本文中，应用最速下降法，这需要梯度值 $\partial E / \partial \omega_i$ 、 $\partial E / \partial a_i$ 和 $\partial E / \partial b_i$ ，用来为每个小波更新参数 ω_i 、 a_i 和 b_i 。

E 对这些网络参数的梯度分别为

$$\frac{\partial E}{\partial \omega_i} = - \sum_{t=1}^T e(t) \Psi \left(\frac{t-b_i}{a_i} \right) \quad (11)$$

$$\frac{\partial E}{\partial b_i} = - \sum_{t=1}^T e(t) \omega_i \frac{\partial \Psi[(t-b_i)/a_i]}{\partial b_i} \quad (12)$$

$$\frac{\partial E}{\partial a_i} = - \sum_{t=1}^T e(t) \omega_i \left(\frac{t-b_i}{a_i} \right) \frac{\partial \Psi[(t-b_i)/a_i]}{\partial b_i} = \left(\frac{t-b_i}{a_i} \right) \frac{\partial E}{\partial b_i} \quad (13)$$

于是，各网络参数 a 、 b 和 ω 的更新采用下面的关系式

$$a^{i+1} = a^i + \mu_a \Delta a \quad (14)$$

$$b^{i+1} = b^i + \mu_b \Delta b \quad (15)$$

$$\omega^{i+1} = \omega^i + \mu_\omega \Delta \omega \quad (16)$$

式中， μ 为学习速率。

2 主要结果

2.1 去噪

通过监测设备采集到的信号往往含有噪声，为了避免噪声的不利影响并且提高基于小波的性能监测系统，这里展现了一种基于小波变换的去噪方法。重建后的信号几乎是无噪声的，且具有相同的能量。一般的去噪过程包括三个步骤：①分解；②阈值选择；③重建。

在本文中，采用的阈值计算公式为

$$\gamma = \left(\frac{\sum_{i=1}^{N_{dj}} |d_j(i)|}{0.6745 \times 2^j N_{dj}} \right) \sqrt{2 \log N_{dj}} \quad (17)$$

式中， N_{dj} 为对于预期分解级数为 j 时的细节系数的个数。

经过去噪后重建的信号几乎不含噪声，并且与原信号具有相同的能量。

2.2 电能质量扰动检测

在本文中，用于电能质量扰动检测的母小波的选择主要是根据对于低幅值、短时及迅速衰减的振荡信号检测中的实际应用情况，并且考虑谱宽度和平滑性。在目前应用较好的Daubechies小波和Symlets小波中经过多次筛选，选择了sym4小波作为母小波。电压暂降、电压暂升、电压瞬态和电压陷波信号及其三级小波分解的细节系数波形分别如图2~图5所示。

电能质量扰动信号经过DWT进行多级分解，





图2 电压暂降及其三级小波分解的细节系数




图3 电压暂升及其三级小波分解的细节系数




图4 电压瞬态及其三级小波分解的细节系数

并与小波系数频率相关。电能质量事件分解后的




图5 电压陷波及其三级小波分解的细节系数

信号, 需要进行评估, 以检测电能质量扰动。要做到这一点, 定义以下辨识判据 C_r

$$C_r = \sqrt{\frac{\sum_{j=1}^N 2^j \sum_{i=1}^{N_{dj}} d_j^2(i)}{2^N \sum_{i=1}^{N_{cN}} c_N^2(i)}} \quad (18)$$

式中, N 为分解的最高级数 (本文中, $N=12$); N_{dj} 为第 j 级细节系数的个数; c_N 为第 N 级的近似系数。注意, 式 (18) 是小波域内总谐波失真的一般定义。

在本文中, 式 (18) 将被用于检测和丢弃非扰动事件。对于 $C_r > 1\%$, 得到相应的小波系数, 并且训练小波神经网络。但是, 如果 $C_r < 1\%$ (对应于非扰动事件), 分类程序将不会启动。辨识判据的应用可以加速程序运行的进程, 避免额外的计算。

这种检测方法的一个显著优势是其能广泛地辨识出单个和混合电能质量扰动事件。

2.3 电能质量扰动最佳特征的提取

DWT 是一种信号处理工具, 提供了一个易于理解对应时-频平面的瞬态信号表示。平面给出被分析信号时间和频率相关的信息。该信号被分解成一系列分级的近似项和细节项。一旦对信号进行了小波变换, 就可以获得每一级的小波系

数, 它们被用于分析或识别信号。

本文中从失真信号 $S(t)$ 分解出的近似项系数和细节项系数中提取出 8 个特征向量, 表征一组有广泛代表性的电能质量扰动。在采样频率 20 kHz 的情况下, 特征向量建立如下

$$x_1 = \frac{S_{td1}(t)}{A_1(t)} \quad (19)$$

$$x_2 = \frac{S_{td2}(t)}{A_2(t)} \quad (20)$$

$$x_3 = \frac{S_{td3}(t)}{A_3(t)} \quad (21)$$

$$x_4 = \frac{S_{td4}(t)}{A_4(t)} \quad (22)$$

式中, $S_{tdl}(t)$ 和 $A_l(t)$ 分别为由失真信号 $S(t)$ 进行分解时的细节系数计算出来的标准偏差和平均值 ($l=1$ 时为 1、2 和 3 级分解; $l=2$ 时为 4、5 和 6 级分解; $l=3$ 时为 7、8 和 9 级分解; $l=4$ 时为 10、11 和 12 级分解)。而第 5~8 个特征向量分量则定义为

$$x_5 = M_2(t) \quad (23)$$

$$x_6 = M_5(t) \quad (24)$$

$$x_7 = M_8(t) \quad (25)$$

$$x_8 = M_{d_{12}}(t) \quad (26)$$

式中, $M_p(t)$ 为第 p (本文 p 分别取 2, 5, 8) 级分解的细节系数绝对值的最大值。 $A_{d_{12}}(t)$ 为 12 级分解的近似项绝对值的平均值。 $x_1 \sim x_8$ 为特征相量的 8 个分量。 x_8 代表小波神经网络检测出的直流偏置。

引入特征向量之后, 下面讨论其计算问题。

假设输入信号经 DWT 进行 N 级分解如下

$$S(t) = S_{c1}(t) + S_{d1}(t) + S_{d2}(t) + \dots + S_{dN}(t) \quad (27)$$

式中, $S_{c1}(t)$ 为近似项; $S_{dj}(t)$ ($j=1, 2, \dots, N$) 为细节项。由 MRA 可得

$$S_{c1}(t) = \sum_i c_1(i) \varphi(t-i) \quad (28)$$

$$S_{dj}(t) = \sum_i \sum_{j=1}^N d_j(i) 2^{j/2} \Psi(2^j t - i) \quad (29)$$

所以

$$S(t) = \sum_i c_1(i) \varphi(t-i) + \sum_i \sum_{j=1}^N d_j(i) 2^{j/2} \Psi(2^j t - i) \quad (30)$$

式中， $\varphi, \Psi \in R$ 。

于是，信号 $S(t)$ 在第 j 级分解时的细节系数绝对值的平均值为

$$A_{sdj}(t)=\frac{1}{2^jN_{dj}}\sum_id_j(i)$$

(31)

式中， j 为分解级数； d_j 为第 j 级分解的细节系数； N_{dj} 为第 j 级分解的细节系数的个数。

相应地，由失真信号 $S(t)$ 在不同分辨率近似项系数和细节系数绝对值得到的平均值

$$A_l(t)=\left[A_{sc1}(t)|A_{sd1}(t)|\cdots|A_{sdN}(t)\right]$$

(32)

式中， A_{sc1} 和 A_{sdj} ($j=1,2,\cdots,N$) 分别为 $S(t)$ 在不同分辨率近似项系数和细节系数绝对值。于是，第 j 级分解细节系数绝对值标准差计算如下

$$S_{dj}(t)=\sqrt{\frac{1}{2^jN_{dj}}\sum_i\left(d_j(i)-A_{sdj}(t)\right)^2}$$

(33)

同理，由失真信号 $S(t)$ 在不同分辨率近似项系数和细节系数绝对值标准差得到的平均值

$$S_{dl}=\left[S_{c1}(t)|S_{d1}(t)|\cdots|S_{dN}(t)\right]$$

(34)

2.4 小波神经网络训练

本文实施一种基于小波神经网络的分类方法，能够识别典型的电能质量事件以及复合，WN离线训练如下。

1) 第1阶段。生成16种电能质量的电压扰动如下表第2列所示，其扰动持续时间、幅值是变化的。每个事件的信号都添加噪声，并以20 kHz的频率采样。对于每个数据，sym4用于提取特征向量并作为输入，用于训练WN。

表 电能质量扰动及其分类算法的准确度

序号	电能质量扰动	扰动数	正确识别数	CA(%)
1	直流偏置	110	108	98.18
2	电压闪变	110	109	99.09
3	短时中断	110	107	97.27
4	电压暂降	110	108	98.18
5	电压暂升	110	109	99.09
6	电压陷波	110	108	98.18
7	谐波	110	109	99.09
8	瞬态（现象）	110	107	97.27
9	电压暂降+瞬态	40	39	97.5
10	电压暂升+瞬态	40	39	97.5
11	谐波+瞬态	40	39	97.5

(续)

序号	电能质量扰动	扰动数	正确识别数	CA(%)
12	电压闪变+瞬态	40	39	97.5
13	电压暂降+谐波	40	39	97.5
14	电压暂升+谐波	40	39	97.5
15	电压暂降+闪变	40	38	95
16	电压暂升+闪变	40	38	95
总计		1 200	1 174	97.92

2) 第2阶段。通过反复进行第1阶段，训练输入数据。用于训练的输入信号的总数是2 480。对WN，除了输入向量，需要相应的目标（输出）训练表中的向量。因此，WN的第一层有8个输入，输出层有4个输出。

2.5 基于WN的电能质量检测和分类算法

所提出的基于WN的电能质量检测和分类算法的流程图如图6所示。主要步骤如下。




图6 基于小波神经网络的电能质量检测和分类算法流程图

- 1) 取样。窗口选取10个周波的失真电压信号，取样频率为20 kHz。
- 2) 信号去噪。
- 3) 应用sym4母小波将信号进行12级分解。
- 4) 计算判别判据 C_r 。
- 5) 小波神经网络分类。最佳特征值提取，小波神经网络训练，电能质量扰动分类。

3 仿真结果

将提出的基于WN的算法用于对16种电能质量扰动进行检测和分类。

上表中所列的前8种扰动为单一的电能质量扰动。采用110个随机产生的任意幅值和相位的失真信号对这些事件进行测试；第9~16种扰动均为由两种电能质量事件复合而成的，采用40个随机产生的失真信号对其进行测试。

仿真结果如上表中第3~5列所示。分类准确度定义如下

$$\text{分类准确度CA} = \frac{\text{正确分类的事件数}}{\text{总事件数}} \times 100\% \quad (35)$$

4 结束语

本文提出了一种基于DWT和小波神经网络的电能质量扰动检测与分类的新方法。通过DWT提取最优特征向量，然后利用小波神经网络实现对电能质量扰动的辨识。与基于传统的神经网络和模糊神经网络的方法相比，避免了后者可能会收敛于局部最优点的不足，也防止了过度拟合和欠拟合情况的发生。仿真结果验证了所提出的方法对于绝大多数电能质量事件进行检测和分类是有效的，具有较高的准确度。

参考文献

- [1] 曾庆辉, 刘晓华, 麦洪. 电能质量在线监测系统的数据分析与应用 [J]. 电气应用, 2012, 31 (6) : 26-30.
- [2] 张惠娟, 郑文龙, 张海强, 等. 基于虚拟仪器技术的电能质量监测系统研发 [J]. 电气应用, 2015, 34 (17) : 100-105.
- [3] Hu G S, Xie J, Zhu F F. Classification of power quality disturbances using wavelet and fuzzy support vector machines [C]. IEEE Proceedings of The Fourth International conference on Machine Learning and Cybernetics, 2005, 7 : 3981-3984.
- [4] Tong W, Song X, Lin J, et al. Detection and classification of power quality disturbances based on wavelet packet decomposition and support vector machines [C]. Proceedings of ISCP 2006, 2006 (4) : 121-125.
- [5] 秦代春, 周林, 郭珂, 等. 一种小波神经网络的电能质量信号去噪新方法 [J]. 电力系统保护与控制, 2010, 38 (13) : 88-93.
- [6] Avdakovic S, Nuhanovic A, Kusljagic M, et al. Wavelet transform application in power system dynamics [J]. Electric Power Systems Research, 2012 (4) : 237-245.
- [7] Rueda J L, Juarez C A, Erlich I. Wavelet-based analysis of power system low-frequency electromechanical oscillations [J]. IEEE Transactions on Power Systems, 2011 (26) : 1733-1743.
- [8] 孙楚平, 杨旭. 基于S变换模时频矩阵的电能质量扰动检测与识别 [J]. 电力系统保护与控制, 2013, 41 (8) : 68-72.
- [9] 徐方维, 杨洪耕, 叶茂清, 等. 基于改进S变换的电能质量扰动分类 [J]. 中国电机工程学报, 2012, 32 (4) : 77-84.
- [10] 陈华丰, 张葛祥. 基于决策树和支持向量机的电能质量扰动识别 [J]. 电网技术, 2013, 37 (3) : 1272-1278.
- [11] 满蔚仕, 张志禹, 康青, 等. 利用快速S变换的电能质量扰动识别方法 [J]. 西安交通大学学报, 2013, 47 (8) : 133-140.
- [12] 曲正伟, 王婷婷, 郗宏伟, 等. 基于提升db4复小波暂态电能质量扰动检测与分类 [J]. 电测与仪表, 2014, 51 (8) : 26-31.
- [13] 陈华丰, 杨志刚, 曾涛. 基于S变换和规则基的复合电能质量扰动识别 [J]. 电测与仪表, 2015, 52 (12) : 122-128.
- [14] 郭俊文, 李开成. 基于改进S变换和复合特征量的多级支持向量机的电能质量扰动分类 [J]. 电测与仪表, 2014, 51 (8) : 19-25.
- [15] 杨宁霞, 孙皓, 公政, 等. 基于S变换和规则基的复合电能质量扰动识别 [J]. 电测与仪表, 2014, 51 (16) : 17-20.

(收稿日期: 2015-12-24) EA