

DOI: 10.7667/PSPC180062

# 基于并行隐马尔科夫模型的电能质量扰动事件分类

谢善益<sup>1</sup>, 肖斐<sup>2</sup>, 艾芊<sup>2</sup>, 周刚<sup>1</sup>

(1. 广东电网有限责任公司电力科学研究院, 广东 广州 510600; 2. 上海交通大学电气工程系, 上海 200240)

**摘要:** 为满足电能质量扰动准确分类的需求, 提出了一种基于极大重叠离散小波变换(Maximal Overlap Discrete Wavelet Transform, MODWT)和并行隐马尔科夫模型(Parallel Hidden Markov Model, PHMM)的电能质量扰动分类方法。首先利用 MODWT 提出一种实用的电能质量扰动检测算法, 该算法无需设定检测阈值, 可准确获取扰动时段的起止时刻。接着提取扰动时段的电压谐波成分并组成特征向量。然后用 PHMM 分类器对扰动信号进行分类识别。PHMM 方法克服了人工神经网络方法收敛性较差、训练时间较长的缺陷, 使分类器性能大大提升。通过应用于现场实测扰动数据表明, 所提出的方法适用于多种类型的电能质量扰动检测, 分类正确率高, 训练速度快, 具有良好的应用价值。

**关键词:** 电能质量; 极大重叠离散小波变换; 并行隐马尔科夫模型; 分类识别

## Parallel hidden Markov model based classification of power quality disturbance events

XIE Shanyi<sup>1</sup>, XIAO Fei<sup>2</sup>, AI Qian<sup>2</sup>, ZHOU Gang<sup>1</sup>

(1. Electric Power Research Institute of Guangdong Power Grid Co., Ltd., Guangzhou 510600, China;

2. Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

**Abstract:** In order to meet the requirements of accurately classifying power quality disturbances, a method for power quality disturbance classification is proposed based on Maximal Overlap Discrete Wavelet Transform (MODWT) and Parallel Hidden Markov Model (PHMM). Initially, a practical power quality disturbance detection algorithm is proposed by using MODWT. This algorithm can obtain the disturbance beginning and ending time accurately without setting detection threshold, from whose results the voltage harmonic components of power quality disturbance are extracted and used to form feature vector. Then, PHMM, as a classifier, is used to identify power quality disturbances. PHMM method solves the problem of poor convergence and longer training time for Artificial Neural Network (ANN) method, and thus the performance of the classifier is greatly improved. The test results based on power grid field data show that the proposed method is suitable for detecting various types of power quality disturbances, and it is characterized by high recognition correctness and less training time, and it will find extensive application.

This work is supported by Science and Technology Project of Guangdong Power Grid Company (No. GDKJXM20162540) and National High-tech R & D Program of China (863 Program) (No. 2015AA050404).

**Key words:** power quality; maximum overlapping discrete wavelet transform; parallel hidden Markov model; classification and identification

## 0 引言

近年来, 电能质量问题一直受到电网公司和电力用户的共同关注。随着电能质量监测系统在各省逐步建设推广, 如何有效利用数据分析技术从数据

中提取信息, 建立起事件的因果关系, 以达到决策支持的目的是电能质量研究中值得关注和有价值的发展趋势之一<sup>[1]</sup>。通过对电力扰动进行检测、分析, 并在整个电力系统范围内建立相关知识, 电网运检人员可对系统及设备当前以及未来的运行状态做出准确判断。

电能质量扰动的分类识别研究主要包括特征量提取和分类器选择问题。常用的扰动特征检测和提

**基金项目:** 广东电网公司科技项目资助 (GDKJXM20162540); 国家 863 计划课题项目资助 (2015AA050404)

取方法有小波变换<sup>[2-5]</sup>、傅里叶变换<sup>[6]</sup>、S 变换<sup>[7]</sup>、Volterra 级数<sup>[8]</sup>方法等。其中, 小波变换又分为离散小波<sup>[2-4]</sup>和连续小波变换<sup>[5]</sup>两种。由于小波变换具有多分辨率分析的特点, 该方法在电能质量扰动检测中有着十分广泛的应用。但小波变换易受噪声影响, 而且不同尺度的小波基对信号进行变换, 将得到不同尺度上的能量分布。因此, 近几年国内外专家学者又提出了改进的小波变换方法, 包括小波包分解<sup>[9]</sup>、提升小波<sup>[10]</sup>、平稳小波<sup>[11]</sup>、可调品质小波<sup>[12]</sup>和极大重叠离散小波(MODWT)<sup>[13-14]</sup>。其中, MODWT 具有小波系数和尺度系数的平移不变性, 所有分解层数都保持相同的时间分辨率、无相位扭曲等优点, 适合非平稳信号的处理<sup>[14]</sup>。

对于分类器设计, 人工神经网络(ANN)方法<sup>[15-18]</sup>使用最为广泛。文献[15]提出了一种基于小波变换和 ANN 的电能质量扰动检测和分类方法。文献[16]利用离散小波变换和 kohonen 自组织神经网络检测和分类电能质量扰动事件。文献[18]利用小波变换和多标签径向基神经网络对电能质量复合扰动类型进行预测。神经网络具有较强的自学习和非线性模式识别能力, 但也存在一些缺陷, 如收敛性较差、训练时间较长、可靠性有限。文献[19]提出一种基于隐马尔科夫模型(HMM)和矢量量化的电能质量扰动分类方法。矢量量化可以较好地保留扰动的局部特征。但该方法直接对小波变换结果进行矢量量化, 观测序列过长, HMM 计算量增大, 其收敛性和分类准确性都受到影响。

综合以上分析, 本文首先基于 MODWT 提出一种实用的扰动事件检测算法, 获取故障开始和故障切除时刻。为突出扰动特征, 将故障时段的电压谐波成分归一化和矢量量化处理。最后采用 K-means 算法将扰动事件聚类, 利用并行隐马尔科夫模型(PHMM)对扰动事件特征值进行训练, 实现扰动模式提取和分类。

## 1 电能质量扰动事件实时检测

### 1.1 极大重叠离散小波变换

设  $X = \{X_t\} \quad t = 0, \dots, T-1$  是长度为  $T$  的时间序列, MODWT 的第  $j$  层小波滤波器和尺度滤波器分别为  $\{\tilde{h}_{j,t}\}$  和  $\{\tilde{g}_{j,t}\}$ , 利用 Mallat 算法求得在尺度  $j$  下的小波变换和尺度变换系数, 可表示为

$$\tilde{W}_{j,t} = \sum_{l=0}^{T-1} \tilde{h}_{j,t}^o X_{t-l \bmod T} \quad (1)$$

$$\tilde{V}_{j,t} = \sum_{l=0}^{T-1} \tilde{g}_{j,t}^o X_{t-l \bmod T} \quad (2)$$

式中:  $j$  为小波分解的层数, 且  $j = 1, 2, \dots, J_0$ ;  $\{\tilde{h}_{j,t}^o\}$  和  $\{\tilde{g}_{j,t}^o\}$  是  $\{\tilde{h}_{j,t}\}$  和  $\{\tilde{g}_{j,t}\}$  以  $T$  为周期进行周期化后得到的滤波器; mod 表示两数相除取余数。由式(1)、式(2)可得  $J_0$  个 MODWT 的小波变换系数和尺度变换系数分别为

$$\tilde{W}_j = \{\tilde{W}_{j,0}, \tilde{W}_{j,1}, \dots, \tilde{W}_{j,T-1}\}, \quad j = 1, 2, \dots, J_0 \quad (3)$$

$$\tilde{V}_j = \{\tilde{V}_{j,0}, \tilde{V}_{j,1}, \dots, \tilde{V}_{j,T-1}\}, \quad j = 1, 2, \dots, J_0 \quad (4)$$

按照谱分解理论, 小波系数  $\tilde{W}_1$  和尺度系数  $\tilde{V}_1$  与采样频带  $[f_s/4, f_s/2]$  和  $[0, f_s/4]$  相关。因此,  $\tilde{W}_1$  适用于检测电能质量扰动数据中的高频分量, 可用于识别故障开始和故障切除时刻。

本文利用移动时间窗技术, 窗口长度为一周波的采样数  $T=128$ 。在采样时刻  $k$ , 选取  $k-T+1$  至  $k$  采样时段内的录波数据, 实时求解小波系数能量  $\varepsilon$  和尺度系数能量  $\tilde{\varepsilon}$ , 可表示为

$$\varepsilon(k) = \sum_{t=k-T+1}^k (\tilde{W}_{1,t})^2 \quad (5)$$

$$\tilde{\varepsilon}(k) = \sum_{t=k-T+1}^k (\tilde{V}_{1,t})^2 \quad (6)$$

利用实际电压录波数据计算的系数能量如图 1 所示。由图 1 可知, 在故障开始和故障切除时刻, 小波变换系数能量会出现较大幅度的突增。

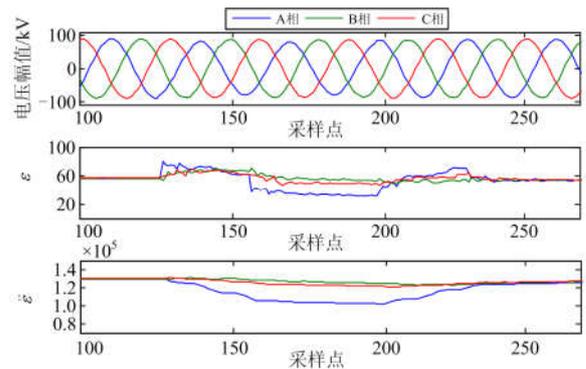


图 1 小波系数能量和尺度系数能量

Fig. 1 Wavelet and approximation coefficient energies

### 1.2 基于小波系数能量差值的扰动检测算法

由 1.1 节的分析可知, 通过识别小波系数能量突增点, 可确定故障开始和切除时刻<sup>[13]</sup>。本文首先计算小波系数能量差值  $\Delta\varepsilon(k)$ , 如式(7)所示。在此基础上, 提出一种实用的扰动事件检测算法。具体检测步骤如图 2 所示。

$$\Delta\varepsilon(k) = \varepsilon(k) - \varepsilon(k-1) \quad (7)$$

式中,  $\varepsilon(k)$  和  $\varepsilon(k-1)$  分别为采样时刻  $k$  和采样时刻  $k-1$  的小波系数能量值。

为展示本文方法的可行性,以图1所示的电压电流扰动数据为例,如果只用波形对比法检测<sup>[20]</sup>,会因暂降开始和结束时都存在相邻周波波形差异而将一个电压暂降扰动误判为2个。其次,波形对比法需要对检测波形划分区段并设定阈值,准确度难以保证<sup>[20]</sup>。因此本文结合重合闸动作时间,将小波系数能量变化极大值作为故障开始和故障切除时刻。对于图1所示的电压暂降事件,由式(7)计算的小波系数能量差值如图3所示。由本文的检测算法流程可知,故障开始时刻和故障切除时刻分别由暂态电压波形和暂态电流波形得到。随着扰动数据采样频率增大,本文方法的检测准确度相应提升,并且无需设定判断阈值。

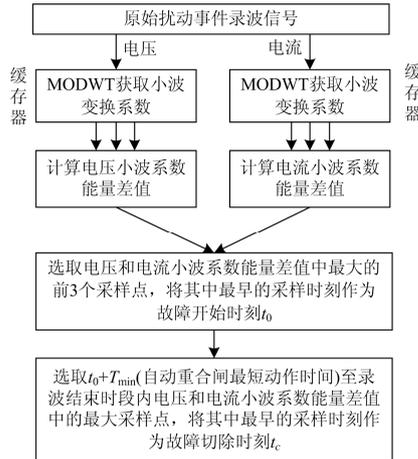


图2 基于小波系数能量差值的扰动检测流程

Fig. 2 Flow chart of disturbance detection method based on wavelet coefficient energy difference

相对于现场应用的电压波形对比检测方法,本文方法的优势主要体现在以下两个方面。

- 1) 同时对电压和电流数据进行检测,提取的故障开始和故障切除时刻信息更加准确。
- 2) 无需提前设定判断阈值,适用于检测电压暂降、电压暂升、长时过电压等多种类型的扰动事件,普适性较强。

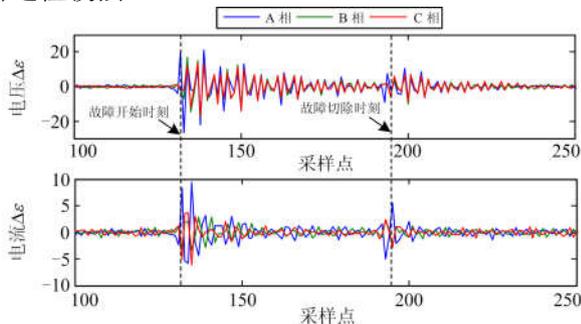


图3 小波系数能量差值

Fig. 3 Wavelet coefficient energy difference

## 2 电能质量扰动事件聚类

### 2.1 扰动事件特征提取

本文将扰动时段的电压谐波成分组成特征向量,用于聚类和分类研究。扰动事件特征向量如式(8)所示。

$$\mathbf{F} = [f_A(1), \dots, f_A(10), f_B(1), \dots, f_B(10), f_C(1), \dots, f_C(10)] \quad (8)$$

式中:  $\mathbf{F}$  表示电能质量扰动特征向量;  $f_A(n)$ 、 $f_B(n)$  和  $f_C(n)$  分别表示 A 相、B 相和 C 相电压中第  $n$  次谐波的成分。为便于分析扰动特征模式,对特征值进行归一化和矢量量化处理。

K-means 方法是非监督学习中一种实用的聚类算法。该算法的基本思想是将大量的高维数据点按照其数据特性划分为多个簇,将簇的中心点作为数据原型。计算每个样本距离簇中心点的距离,根据距离最近的原则,将样本划分给相应的簇中心<sup>[21]</sup>。

### 2.2 扰动事件聚类指标

鉴于聚类数量难以客观确定,本文利用分区指标(SC)、Xie and Beni 指标(XB)、Dunn 指标(DI)选择合适的聚类数<sup>[22]</sup>,指标定义如下所示。

1) SC 指标用于衡量簇内样本的聚合程度和簇中心间的分散程度。SC 幅值越小说明样本分类效果越好。

$$V_{SC}(c) = \sum_{i=1}^c \frac{\sum_{j=1}^Q \mu_{ij} \|x_j - v_i\|^2}{Q_i \sum_{k=1}^c \|v_k - v_i\|^2} \quad (9)$$

式中:  $V_{SC}(c)$  表示样本聚合为  $c$  类时 SC 指标取值;  $Q_i$  表示第  $i$  类样本的数量;  $Q$  表示所有样本的数量;  $\mu_{ij}$  表示第  $j$  个样本是否隶属于第  $i$  类簇中心,若  $\mu_{ij}=1$  则说明第  $j$  个样本隶属于第  $i$  类簇中心,若  $\mu_{ij}=0$  则说明第  $j$  个样本不属于第  $i$  类簇中心;  $x_j$  表示第  $j$  个样本;  $v_k$  和  $v_i$  分别表示第  $k$  类和第  $i$  类簇中心。

2) XB 指标与 SC 指标相似,用于衡量簇内样本的聚合程度, XB 幅值越小说明样本分类效果越好。

$$V_{XB}(c) = \frac{\sum_{i=1}^c \sum_{j=1}^Q \mu_{ij} \|x_j - v_i\|^2}{Q \min_{i,j} \|x_j - v_i\|^2} \quad (10)$$

式中,  $V_{XB}(c)$  表示样本聚合为  $c$  类时 XB 指标取值。

3) DI 指标表示任意两个簇内样本的最短距离与单一簇中样本的最大距离比值, DI 幅值越大说明样本分类效果越好。

$$V_{DI}(c) = \min_{i \in c} \left\{ \min_{j \in c, i \neq j} \left\{ \frac{\min_{x \in C_i, y \in C_j} d(x, y)}{\max_{k \in c} \left\{ \max_{x, y \in C_k} d(x, y) \right\}} \right\} \right\} \quad (11)$$

式中:  $V_{DI}(c)$  表示样本聚合为  $c$  类时 DI 指标取值;  $d(x, y)$  表示样本  $x$  和样本  $y$  之间的距离;  $C_i$  和  $C_j$  分别表示隶属于第  $i$  类和第  $j$  类簇中心的样本集合。

### 3 基于 PHMM 的电能质量扰动事件分类

#### 3.1 HMM 定义

隐马尔科夫模型根据参数的不同, 分为离散和连续 HMM 两类。在提取扰动特征向量的基础上, 本文采用离散 HMM。HMM 模型由五元参数组来描述。

$$\lambda = (N, M, \mathbf{A}, \mathbf{B}, \boldsymbol{\pi}) \quad (12)$$

式中:  $N$  为状态数, 记  $N$  个隐状态为  $\theta_1, \theta_2, \dots, \theta_N$ , 则  $t$  时刻马尔科夫状态为  $S_t$ ,  $S_t \in \{\theta_1, \theta_2, \dots, \theta_N\}$ ;  $M$  为每个隐状态对应的观测值数, 记  $M$  个观测值为  $V_1, V_2, \dots, V_M$ , 则  $t$  时刻的观测值为  $O_t$ ,  $O_t \in \{V_1, V_2, \dots, V_M\}$ ; 状态转移概率矩阵  $\mathbf{A} = (a_{ij})_{N \times N}$ , 其中  $a_{ij} = P(S_{t+1} = \theta_j | S_t = \theta_i)$ ; 观测值概率矩阵  $\mathbf{B} = (b_{jk})_{N \times M}$ , 其中  $b_{jk} = P(O_t = V_k | S_t = \theta_j)$ ; 初始概率分布向量  $\boldsymbol{\pi} = (\pi_1, \pi_2, \dots, \pi_N)$ 。HMM 对  $L$  个观测序列的训练公式进行实用化推导, 如式(13)一式(16)所示<sup>[23]</sup>。

$$\bar{\pi}_i = \frac{1}{L} \sum_{q=1}^L \alpha_1^{*(q)}(i) \beta_1^{*(q)}(i), \quad 1 \leq i \leq N \quad (13)$$

$$\bar{a}_{ij} = \frac{\sum_{q=1}^L \sum_{t=1}^{T_q-1} \alpha_t^{*(q)}(i) a_{ij} b_{j, O_{t+1}^{(q)}} \beta_{t+1}^{*(q)}(j) / \varphi_{t+1}}{\sum_{q=1}^L \sum_{t=1}^{T_q-1} \alpha_t^{*(q)}(i) \beta_t^{*(q)}(j)}, \quad (14)$$

$$1 \leq i \leq N, 1 \leq j \leq N$$

$$\varphi_{t+1} = \sum_{j=1}^N \left[ \sum_{i=1}^N \alpha_t^{*(q)}(i) a_{ij} \right] b_{j, O_{t+1}^{(q)}} \quad (15)$$

$$\bar{b}_{jk} = \frac{\sum_{q=1}^L \sum_{t=1}^{T_q} \alpha_t^{*(q)}(j) \beta_t^{*(q)}(j)}{\sum_{q=1}^L \sum_{t=1}^{T_q} \alpha_t^{*(q)}(j) \beta_t^{*(q)}(j)}, \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (16)$$

式中:  $\bar{\pi}_i$  为初始状态向量;  $\alpha_t^{*(q)}$  和  $\beta_t^{*(q)}$  分别为第  $q$  个训练序列由比例处理后的前向和后向变量;  $\bar{a}_{ij}$  和  $\bar{b}_{jk}$  分别为训练后的状态转移概率矩阵  $\mathbf{A}$  和观测值概率矩阵  $\mathbf{B}$  中的元素;  $T_q$  为第  $q$  个训练序列的长度;  $b_{j, O_{t+1}^{(q)}}$  和  $\varphi_{t+1}$  为中间算子, 且满足  $b_{j, O_{t+1}^{(q)}} = b_{jk} |_{O_{t+1}^{(q)}=V_k, S_{t+1}=\theta_j}$ , 其中  $O_{t+1}^{(q)}$  为第  $q$  个训练序列  $t+1$  时刻的观测值。

#### 3.2 扰动事件分类流程

当 HMM 应用于电能质量扰动事件分类时, 分布在各处的电能质量监测装置将多地的量测值以特征向量的形式发送到分析模块, 单一的 HMM 模型难以将各类扰动事件的扰动特征描述清楚。因此引入 PHMM, 该方法的主要过程如图 4 所示。

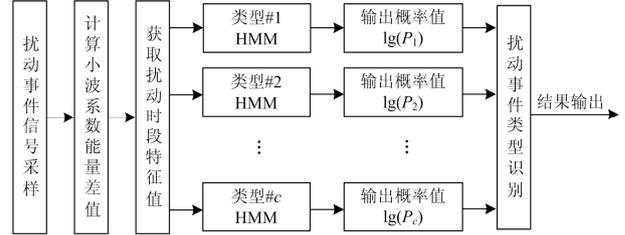


图 4 基于 PHMM 的电能质量扰动事件识别

Fig. 4 Power quality disturbance events classification based on PHMM

通过对扰动事件量测值进行特征提取和聚类, 形成独立的特征向量集。每个特征向量集对应唯一的 HMM 模型, 多个 HMM 呈现“并行”关系。通过综合  $c$  个 HMM 的输出结果, 识别扰动事件类型。

基于上述分析, 本文提出的扰动事件分类方法详细步骤如下。首先基于 MODWT 系数能量差值  $\Delta \varepsilon(k)$  获取故障开始和切除时刻。其次由归一化后的三相电压谐波含量组成特征向量, 利用 K-means 方法进行聚类分析。然后训练每类扰动事件对应的 HMM 模型。最后将 PHMM 分类器用于电能质量扰动识别。上述步骤中, 采用 Forward-Backward 算法计算扰动事件样本在不同 HMM 下的对数似然概率, 按概率值最大的原则判断事件类型。

#### 4 实例分析

本文基于 2016 年 7 月 1 日—2017 年 6 月 30 日南方某省的电能质量监测系统记录的线路跳闸事件, 选取其中线路合闸成功的事件共 86 起, 相关的暂态事件记录 374 条, 包含的暂态事件类型为: 电压暂降、电压暂升、长时过电压。实验环境为: Matlab 2014a, 64-bit win7 系统, Intel(R) Core(TM) 2.40 GHz。

为体现本文扰动检测方法的普适性, 将该方法与文献[13]提出的阈值判断方法进行对比。由自动重合闸动作时间, 判断本文算法准确检测故障开始和故障切除时刻的扰动记录共 330 条, 利用文献[13]方法准确判断的扰动记录共 218 条。两种方法的正确判断率分别为 88.24%和 58.29%。

将正确获取故障开始和故障切除信息的 330 条扰动记录作为分析样本, 计算故障时段的电压谐波成分。利用式(9)一式(11)求得聚类指标如图 5 所



为进一步验证 PHMM 分类模型的有效性, 本文还使用 ANN 方法对相同的训练样本进行扰动事件分类测试。为保证测试结果的可比性, 每类扰动事件对应一个 ANN 模型<sup>[15]</sup>, 分类结果和平均训练时间如表 3 所示。由表 3 可知, 本文方法的分类正确率为 91.18%, 平均训练时间为 2.23 s, 两类指标结果均优于 ANN 方法。这是由于扰动事件类型 6、类型 8、类型 9 的训练样本数量较少, 利用 ANN 方法分类测试样本的准确率较低。相反, PHMM 方法仅误判其中的扰动事件类型 9 有 1 次。由此可知, 在训练样本数量较少的情况下, 本文方法的识别准确率更高, 训练时间更短。

表 3 不同算法性能对比

Table 3 Performance comparison between different algorithms

算法	测试样本	正确分类 样本	正确率/%	平均训练 时间/s
MODWT+PHMM	68	62	91.18	2.23
ANN <sup>[15]</sup>	68	60	88.24	7.37

## 5 结论

为实现电能质量扰动事件的自动识别, 本文提出一种基于 MODWT 和 PHMM 的扰动事件检测和分类方法。通过应用于现场实测扰动数据, 得出以下结论:

1) 利用 MODWT 提出电力扰动事件检测方法, 该方法无需提前设定判断阈值, 适用于多种类型的扰动事件检测, 普适性较强;

2) 基于并行隐马尔科夫模型构建扰动事件分类器, 适用于多种扰动事件的特征模式提取;

3) 与常用的人工智能算法(如 ANN)相比, 在训练样本数量较少的情况下, 本文方法具有更高的识别准确率和更短的训练时间。

本文所述的扰动检测方法只是面向单一故障扰动事件, 对于实际电网连锁故障引起的复杂电能质量扰动事件检测还存在不足, 有待后续工作的进一步开展。

## 参考文献

- [1] 徐文远, 雍静. 电力扰动数据分析学—电能质量监测数据的新应用[J]. 中国电机工程学报, 2013, 33(19): 93-101.  
XU Wilsun, YONG Jing. Power disturbance data analytics— new application of power quality monitoring data[J]. Proceedings of the CSEE, 2013, 33(19): 93-101.
- [2] 任子晖, 刘昊岳, 徐进霞. 基于小波变换和改进 Prony 方法的电能质量扰动分析[J]. 电力系统保护与控制, 2016, 44(9): 122-128.

- REN Zihui, LIU Haoyue, XU Jinxia. Power quality disturbance analysis based on wavelet transform and improved Prony method[J]. Power System Protection and Control, 2016, 44(9): 122-128.
- [3] 剧高峰, 罗安. 离散小波变换用于电能质量扰动数据实时压缩[J]. 电力系统自动化, 2002, 26(19): 61-63.  
JU Gaofeng, LUO An. DWT application to real-time compression of power quality disturbance data[J]. Automation of Electric Power Systems, 2002, 26(19): 61-63.
- [4] 李正明, 徐敏, 潘天红, 等. 基于小波变换和 HHT 的分布式并网系统谐波检测方法[J]. 电力系统保护与控制, 2014, 42(4): 34-39.  
LI Zhengming, XU Min, PAN Tianhong, et al. A harmonic detection method for distributed connected grid system by using wavelet transform and HHT[J]. Power System Protection and Control, 2014, 42(4): 34-39.
- [5] 张宇辉, 陈晓东, 王鸿懿. 基于连续小波变换的电能质量测量与分类[J]. 电力自动化设备, 2004, 24(3): 17-21.  
ZHANG Yuhui, CHEN Xiaodong, WANG Hongyi. Continuous wavelet-based measuring and classification of short duration power quality disturbance[J]. Electric Power Automation Equipment, 2004, 24(3): 17-21.
- [6] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.  
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [7] 覃星福, 龚仁喜. 基于广义 S 变换与 PSO-PNN 的电能质量扰动识别[J]. 电力系统保护与控制, 2016, 44(15): 10-17.  
QIN Xingfu, GONG Renxi. Power quality disturbances classification based on generalized S-transform and PSO-PNN[J]. Power System Protection and Control, 2016, 44(15): 10-17.
- [8] RAHUL, KAPOOR R, TRIPATHI M M. Detection and classification of multiple power signal patterns with Volterra series and interval type-2 fuzzy logic system[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 92-101. DOI: 10.1186/s41601-017-0039-z.
- [9] 陈伟根, 谢波, 龙震泽, 等. 基于小波包能量熵的油纸绝缘气隙放电阶段识别[J]. 中国电机工程学报, 2016, 36(2): 563-569.  
CHEN Weigen, XIE Bo, LONG Zhenze, et al. Stage identification in air-gap discharge of oil-impregnated paper insulation based on wavelet packet energy entropy[J]. Proceedings of the CSEE, 2016, 36(2): 563-569.

[10] 何巨龙, 王根平, 刘丹, 等. 基于提升小波和改进 BP 神经网络的配电网系统电能质量扰动定位与识别[J]. 电力系统保护与控制, 2017, 45(10): 69-76.  
HE Julong, WANG Genping, LIU Dan, et al. Localization and identification of power quality disturbance in distribution network system based on lifting wavelet and improved BP neural network[J]. Power System Protection and Control, 2017, 45(10): 69-76.

[11] 黄建明, 李晓明, 瞿合祚, 等. 考虑小波奇异信息与不平衡数据集的输电线路故障识别方法[J]. 中国电机工程学报, 2017, 37(11): 3099-3107.  
HUANG Jianming, LI Xiaoming, QU Hezuo, et al. Method for fault type identification of transmission line considering wavelet singular information and unbalanced dataset[J]. Proceedings of the CSEE, 2017, 37(11): 3099-3107.

[12] 唐贵基, 王晓龙. 可调品质因子小波变换在滚动轴承微弱故障特征提取中的应用[J]. 中国电机工程学报, 2016, 36(3): 746-754.  
TANG Guiji, WANG Xiaolong. Application of tunable Q-factor wavelet transform to feature extraction of weak fault for rolling bearing[J]. Proceedings of the CSEE, 2016, 36(3): 746-754.

[13] COSTA F B, SOUZA B A, BRITO N S D. Real-time detection of voltage sags based on wavelet transform[C] // Transmission and Distribution Conference and Exposition: Latin America, November 8-10, 2010, Sao Paulo, Brazil: 537-542.

[14] COSTA F B, DRIESEN J. Assessment of voltage sag indices based on scaling and wavelet coefficient energy analysis[J]. IEEE Transactions on Power Delivery, 2012, 28(1): 336-346.

[15] SANTOSO S, POWERS E J, GRADY W M. Power quality disturbance waveform recognition using wavelet-based neural network classification-part 2: application[J]. IEEE Transactions on Power Delivery, 2000, 15(1): 229-235.

[16] CESAR D G, VALDOMIRO V G, GABRIEL O P. Automatic power quality disturbances detection and classification based on discrete wavelet transform and artificial intelligence[C] // Transmission and Distribution Conference and Exposition: Latin America, August 15-18, 2006, Caracas, Venezuela: 1-6.

[17] 秦英林, 田立军, 常学飞. 基于小波变换能量分布和神经网络的电能质量扰动分类[J]. 电力自动化设备, 2009, 29(7): 64-67.  
QIN Yinglin, TIAN Lijun, CHANG Xuefei. Classification of power quality disturbance based on wavelet energy distribution and neural network[J]. Electric Power Automation Equipment, 2009, 29(7): 64-67.

[18] 管春, 周维维, 卢伟国. 基于多标签 RBF 神经网络的电能质量复合扰动分类方法[J]. 电工技术学报, 2011, 26(8): 198-204.  
GUAN Chun, ZHOU Luwei, LU Weiguo. Recognition of multiple power quality disturbances using multi-label RBF neural networks[J]. Transactions of China Electrotechnical Society, 2011, 26(8): 198-204.

[19] ABDEL-GALIL T K, EL-SAADANY E F, YOUSSEF A M, et al. Disturbance classification using hidden Markov models and vector quantization[J]. IEEE Transactions on Power Delivery, 2005, 20(3): 2129-2135.

[20] 朱珂, 倪建, 刘颖英, 等. 面向电力扰动数据分析的暂态扰动检测[J]. 电工技术学报, 2017, 32(3): 35-44.  
ZHU Ke, NI Jian, LIU Yingying, et al. Detect transient power disturbance for power disturbance data analytics[J]. Transactions of China Electrotechnical Society, 2017, 32(3): 35-44.

[21] 周翔, 王丰华, 傅坚, 等. 基于混沌理论和 K-means 聚类的有载分接开关机械状态监测[J]. 中国电机工程学报, 2015, 35(6): 1541-1548.  
ZHOU Xiang, WANG Fenghua, FU Jian, et al. Mechanical condition monitoring of on-load tap changers based on chaos theory and K-means clustering method[J]. Proceedings of the CSEE, 2015, 35(6): 1541-1548.

[22] XIE X L, BENI G A. A validity measure for fuzzy clustering[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1991, 13(13): 841-847.

[23] 唐飞, 王波, 查晓明, 等. 基于双阶段并行隐马尔科夫模型的电力系统暂态稳定评估[J]. 中国电机工程学报, 2013, 33(10): 90-97.  
TANG Fei, WANG Bo, ZHA Xiaoming, et al. Power system transient stability assessment based on two-stage parallel hidden Markov model[J]. Proceedings of the CSEE, 2013, 33(10): 90-97.

收稿日期: 2018-01-13; 修回日期: 2018-03-14

作者简介:

谢善益(1971—), 男, 硕士, 教授级高级工程师, 研究方向为电网自动化系统研究开发及技术监督管理; E-mail: kways@126.com

肖斐(1991—), 男, 通信作者, 博士研究生, 研究方向为电能质量、大数据在电力系统中的应用; E-mail: xiaofeisjtu@163.com

艾芊(1969—), 男, 博士, 教授, 博导, 研究方向为电能质量、人工智能、大数据及在电力系统中的应用、电力系统建模、分布式发电与微电网。E-mail: aiqian@sjtu.edu

(编辑 许威)