

DOI:10.13296/j.1001-1609.hva.2017.12.032

装备电力系统电能质量复合扰动识别方法研究

尹志勇¹, 陈永光², 刘金宁¹, 桑 博¹

(1. 陆军工程大学石家庄校区, 石家庄 050003; 2. 北京跟踪与通信技术研究所, 北京 100094)

摘要: 为了提高装备电力系统复合电能质量扰动(PQD)识别能力,提出了构建组合特征集用以全面表征装备电力系统电能质量复合扰动的粒子群优化(PSO)极限学习机(ELM)分类新方法。首先,结合S变换和经验模态分解(EMD)两种特征提取手段,构建组合特征向量集,对复合扰动信号特征边界区分更加明显;然后,优化ELM隐含层神经元数目,平衡其分类的实时性和准确性,在PSO适应度函数与ELM训练误差之间建立联系,设置了PSO初始参数,完成了分类器设计。经装备电力系统实测数据验证,该方法对7类典型装备电力系统电能质量复合扰动信号能够准确识别,且对噪声不敏感,相较于单独使用的ELM,显著地减少了训练及分类时间,进一步提高了分类的准确性。

关键词: 装备电力系统;复合扰动;分类识别;粒子群算法;极限学习机;组合特征提取

Complex Disturbances Classification of Equipment Power Quality

YIN Zhiyong¹, CHEN Yongguang², LIU Jinning¹, SANG Bo¹

(1. Shijiazhuang Campus of Army Engineering University, Shijiazhuang 050003, China;

2. Institute of Tracking and Telecommunications Technology, Beijing 100094, China)

Abstract: In improve the recognition ability of equipment power quality complex disturbances, a new approach is proposed to deal with identification and classification of power quality complex disturbances based on Particle Swarm Optimization (PSO) and Extreme Learning Machine (ELM) with combined feature extraction. The combination of S-transform and Empirical Mode Decomposition (EMD) is employed to construct a set of composite feature vectors in order to represent the complex disturbances comprehensively. ELM training error is used as the fitness function of PSO to optimize the hidden layer neuron number. The initial parameters of PSO are set up to complete the classifier design, and the higher classification accuracy is maintained on the basis of improving the classification speed. Test results show that the new approach can accurately recognize seven types of power quality complex disturbances of the equipment power system, and has strong noise immunity. Compared with the non-optimized ELM, the new approach reduces the training and classification time, and improves the recognition accuracy.

Key words: equipment power system; complex disturbances; classification; particle swarm optimization(PSO); extreme learning machine(ELM); combined feature extraction

0 引言

随着信息化程度的不断提高,武器系统全电化趋势逐步加强,装备负荷种类也更加复杂多样^[1],尤其是以电力电子器件为主的非线性负载比例越来越

高,给装备电力系统的用电品质带来了很多问题,对武器系统作战效能产生很大影响。为使装备电力系统安全稳定的运行,大量扰动信息必须能够被实时准确的识别,才能使相应补偿措施发挥应有的效能^[2-3]。因此,装备电力系统电能质量扰动(power quality disturbance, PQD) 分类识别就成为了电能品质监测与分析中的重要一环。

收稿日期:2017-06-05; 修回日期:2017-08-17

基金项目:国家自然科学基金项目资助(51307184)。

Project Supported by National Natural Science Foundation of China(51307184)。

当前,针对装备电力系统的 PQD 扰动识别技术研究较少,但地方大电网在此方面做了诸多研究工作,特别是涉及单一电能质量扰动分类器设计较多,所提分类方法的通用性和准确性较高,文[4-7]分别采用了二叉结构的决策树,支持向量基、Bayes、神经网络等方法,针对单一 PQ 扰动信号,完成了特征向量集构建和分类器设计,获得了预期的识别效果。但实际的电力系统多为复合扰动,近年来也有不少学者对其进行了相应的研究^[8-11],取得了许多成果,但还有大量问题需要解决,如分类算法的适用性不强,分类准确性也有待提高等。装备电力系统与地方大电网相比为典型的有限容量系统,其负荷特性更加敏感,电力母线抗扰动冲击能力更差,负荷暂态扰动更加复杂、频繁,基于此,提出了一种适用于装备电力系统复合扰动信号的分类识别方法。首先,结合 S 变换与经验模态分解(empirical mode decomposition, EMD)提取复合扰动信号的特征值,构建组合特征向量集,能够对复合扰动信号特征进行全面刻画,特征边界区分更加明显,进一步提高了分类识别的准确率;设计了基于粒子群算法(particle swarm optimization, PSO)优化的极限学习机(extreme learning machine, ELM)分类器,进一步改善 ELM 隐含层神经元数目,平衡其分类的实时性和准确性,设置了 PSO 初始参数,完成了分类器构建。最后,经装备电力综合试验系统产生的实测波形验证,该方法对 7 类典型装备电力复合扰动信号具有很高的识别率,抗噪声能力强,相较于单独使用的 ELM,显著地减少了训练及分类时间,进一步提高了分类的准确性。

1 扰动信号组合特征提取

文中重点研究典型的 7 种装备电力系统复合扰动信号,包括 5 种二重扰动和两种三重扰动,具体为:电压瞬升+谐波、电压瞬降+谐波、瞬态振荡+电压波动、电压中断+电压波动、电压瞬降+电压波动、瞬态振荡+电压波动+谐波、电压瞬升+电压波动+谐波,7 种复合扰动信号依次用 $R_1 \sim R_7$ 表示。复合扰动与单一扰动的最大区别在于,其特征空间更加复杂,局部特征细节区分不够清晰,采用单一特征提取方法很难全面刻画多重扰动信号的分类边界^[12]。为全面的表征各类扰动信号的局部特征,文中将 S 变换与 EMD 相结合,分别从时频与能量角度提取并构建组合特征集。

1.1 S 变换特征提取

S 变换是进一步改善了 FFT 与小波变换因窗函数固定而带来的时频聚焦性不足问题,将 Gauss 窗

函数与待分析信号的频率通过函数关联在一起,免去了小波变换小波基选择困难,FFT 暂态信号分析效果差等问题^[13]。设输入信号是 $h(t)$,其一维连续 S 变换表达式见式(1)。

$$S(\tau, f) = \int_{-\infty}^{+\infty} h(t) \nu(\tau - t, f) e^{-i2\pi f t} dt. \quad (1)$$

$$\nu(\tau - t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2}{2\delta^2}}. \quad (2)$$

式(2)中: $\nu(\tau - t, f)$ 是高斯窗函数;参数 τ 是平移因子,用来控制高斯窗口在时间轴 t 上的位置; i 是虚数单位; δ 是待分析频率 f 的倒数。

当 $f \rightarrow n/NT$, $\tau \rightarrow kT$,可得到 S 变换的离散形式

$$\begin{cases} S(kT, \frac{n}{NT}) = \sum_{m=0}^{N-1} P(\frac{m+n}{NT}) Q(m, n) e^{-i2\pi m k / N} & n \neq 0 \\ S(kT, 0) = \frac{1}{N} \sum_{m=0}^{N-1} P(\frac{m}{NT}) & n = 0 \end{cases} \quad (3)$$

式(3)中: N 是信号采样点数; T 是信号采样时间间隔; $k=0, 1, 2, \dots, N$; $P(\cdot)$ 、 $Q(\cdot)$ 分别是信号 $h(t)$ 与 $\nu(\tau, -t, f)$ 的离散 FFT 变换。

应用 S 变换可将装备电力系统 PQD 信号转换为相应的复数矩阵,为数据分析方便,通常对该初始矩阵中的所有元素进行求模处理^[14]。对采集到的装备电力系统实测波形数据做归一化,两类复合扰动信号的 S 变换见图 1。

由信号 S 变换分析可以看出,扰动信号的变化总是体现在频率、幅值以及时间等 3 个方面。因此,对于扰动信号遵循从上述 3 个方面进行特征提取,同时,针对装备电力系统 PQ 复合扰动信号频率分布范围较广,在特征选择上需兼顾 100 Hz 以下,100~400 Hz 及 400 Hz 以上低、中、高 3 个频率段的幅值变化,所选特征见表 1。

1.2 EMD 特征提取

EMD 可将 PQD 信号分解为一系列表征不同频率的固有模态函数(intrinsic mode function, IMF),信号原有的特性可通过各个本征模态分析获得^[15]。部分扰动信号的 EMD 分析,见图 2。

S 变换的特征向量集主要从各频段的幅值、标准差等角度构建的,利用 EMD 从 PQD 信号的 IMF 分量能量变化上对其进行表征,以作为对 S 变换初始特征空间的辅助与补充。因此,计算 EMD 筛分出的各个 IMF 分量能量值,将其作为装备电力系统 PQD 信号 $R_1 \sim R_7$ 的特征向量。由图 2 可见,扰动信号的特征主要集中在前面几个 IMF 分量中,即信号经




图1 部分复合扰动信号的S变换

Fig. 1 Some complex disturbances and its S-transform analysis

表1 S变换特征提取

Table 1 Feature extraction based on S-transform

特征量	说明
S_1	幅值—采样点图;基频幅值均值
S_2	幅值—采样点图;基频幅值标准差
S_3	幅值—采样点图;基频幅值最大值
S_4	幅值—频率图;中频段标准差
S_5	幅值—频率图;高频段标准差
S_6	幅值—频率图;高频段幅值最大值
S_7	幅值—频率图;全频段标准差
S_8	幅值标准差—频率图;全频段标准差
S_9	信号总谐波失真

EMD 筛分出来的高频部分集中了主要特征信息, 基于此, 仅计算前 4 个分量的能量值, 部分 PQD 信号的模态能量谱见图 3。

结合 S 变换与 EMD 构建的装备电力系统 PQD 信号组合特征空间为

$$F_{sl-emd} = (S_1, S_2, \dots, S_8, E_1, E_2, E_4, E_4)。(4)$$

2 基于 PSO-ELM 分类器设计

2.1 ELM 基本原理

ELM 是一种单隐含层前馈神经网络^[16-17]。网络结构见图 4。

图 4 中: ELM 网络的输入层、隐含层、输出层的

神经元个数分别为 n, l, m ; w_{ij}, β_{ij} 是隐含层第 j 个与输入层(输出层)第 $i(k)$ 个元素的连接权值。

设训练用样本数量是 Q , 输入 X 是 $n \times Q$ 矩阵、输出 Y 是 $m \times Q$ 矩阵, 可知

$$T = [t_1, t_2, \dots, t_Q]_{m \times Q}。(5)$$

式(5)中, T 是 Neuron 矩阵; t_{ij} 为

$$t_{ij} = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(w_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(w_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(w_i x_j + b_i) \end{bmatrix}_{m \times 1}。 (6)$$

式(6)等价式为

$$H\beta = T^T。(7)$$

式(6)、(7)中: b 是 Neuron 阈值矩阵; H 是隐含层输出矩阵; $g(\cdot)$ 是激活函数, 且其无穷次数导数存在; w 和 b 初始任意赋值, 训练时不用再采取人为干预。

文[18]得出, 如果训练集合中的样本数量与一致时, 则其能够被 ELM 以趋近于无穷小的误差去拟合。但在实际应用中, 如用于训练的样本过多时, 会增加训练时间, 为此, 当 $l < Q$ 时, ELM 由训练所产生的误差能够无限靠近 $\varepsilon > 0$, 即




图 2 部分复合扰动信号的 EMD 分析

Fig. 2 EMD results of some complex disturbances




图 3 部分扰动信号 EMD 模态能量谱

Fig. 3 EMD mode energy spectrums




图 4 ELM 网络结构

Fig. 4 Structure of ELM network

$$\sum_{i=1}^Q \|t_i - y_i\| < \varepsilon. \quad (8)$$

式(8)中, y_i 是输出矩阵 Y 中第 i 个元素的实际值。由式(8)可以看出, l 的选择对 ELM 的训练准确性及快速性能能够起到决定性作用。

2.2 分类器优化设计

粒子群优化算法^[19]最早由 Kennedy 和 Eberhart 在 1995 年提出用于求解最优化问题的。假设在一个 D 维的搜寻空间中, 存在某种群 $C=(C_1, C_2, \dots, C_n)$, C 中所包含的粒子数量为 n , 其中第 i 个粒子 $C_{id}=(C_{i1}, C_{i2}, \dots, C_{iD})^T$ 在空间中的位置可作为待解决问题的某个可能解。 C_i 所对应的适应度数值能够根据目标函数计算获得, 设 $V_{id}=(V_{i1}, V_{i2}, \dots, V_{iD})^T$ 是第 i 个粒子速度, 其个体的极值表示为 $P_{id}=(P_{i1}, P_{i2}, \dots, P_{iD})^T$, $P_{gd}=(P_{g1}, P_{g2}, \dots, P_{gD})^T$ 是种群的个体极值, 粒子能够在历次

迭代中由 P_{id} 和 P_{gd} 来更替其位置和速度信息^[20-21], 即:

$$V_{id}^{m+1} = \lambda V_{id}^m + s_1 t_1 (P_{id}^m - C_{id}^m) + s_2 t_2 (P_{gd}^m - C_{gd}^m); \quad (9)$$

$$C_{id}^{m+1} = C_{id}^m + V_{id}^{m+1}; \quad (10)$$

式(9)、(10)中: λ 、 m 分别表示惯性权重和迭代次数; 加速因子 s_1 、 s_2 通常可设定为 2; t_1 、 t_2 可在 $[0, 1]$ 内任意取值。

惯性权重 λ 反映了个体粒子延续先前粒子速度的能力, 对于提高 PSO 的搜索能力, 避免搜寻进入局部最优陷阱而无法获得理想优化参数有较大影响, 为进一步改善 PSO 的自调整能力, 将迭代次数 m 与惯性权重 λ 相关联, 针对 ELM 参数 l 的优化, 提出一种改进的动态权重函数 $\lambda(m)$, 表示为

$$\lambda(m) = \lambda_u - (\lambda_u - \lambda_v)(m/R_m)^2. \quad (11)$$

式(11)中: λ_u 、 λ_v 为初始惯性权重, 经实验验证, 一般可设定为 0.9 和 0.4; R_m 是迭代的最高次数。

PSO 的优化对象主要针对 ELM 的 w 、 b 以及 l 这 3 类关键参数。当 l 的个数比训练集中的样本数量少, 且 w 、 b 初始任意赋值时, 由式(8)可知, ELM 由训练所产生的误差能够无限靠近 $\varepsilon > 0$, 可表示为

$$\delta = \frac{F}{W} \times 100\%. \quad (12)$$

式(11)中: δ 是粒子群的适应度函数; W 、 F 分别是训练集中的全部元素数与失败数。

针对第 i 个粒子, 其个体极值 p_i 与个体速度 v_i 分别为

$$p_i = [p_{i1}, p_{i2}, \dots, p_{i(n+1)}]; \quad (13)$$

$$v_i = [v_{i1}, v_{i2}, \dots, v_{i(n+1)}]. \quad (14)$$

在 $(n \times l + 1)$ 维搜寻空间中, 第 i 个粒子的可能最优解为

$$p_{best} = [p_1, p_2, \dots, p_{n(l+1)}]. \quad (15)$$

综上所述, 基于 PSO-ELM 的装备电力系统 PQD 信号分类器优化设计可按如下步骤:

步骤 1)。将 S 变换与 EMD 两种手段融合所构建的装备电力系统 PQD 信号组合特征向量集 F_{st-end} 输入到 ELM 分类器中, 在训练进行时 b 、 w 随机赋值且维持恒定, 初始设定 $l=40$ 。

步骤 2)。惯性权重 $\lambda(m)$ 应用式(11)进行动态调整, 防止在迭代过程中落入局部最优陷阱, 进一步提高全局搜寻能力, 初始化 PSO 参数如下: ①种群数量 $n=180$; ②最高迭代 $R_m=120$; ③最高个体速度 $v_{max}=0.5$; ④最低个体速度 $v_{min}=-0.5$; ⑤最小误差 $\varepsilon=0.01$ 。

步骤 3)。计算粒子适应度值, 对粒子的 p_i 与 v_i 进行搜索, 不断更替其位置及速度相关信息, 并将每次得到的最新 l 值输入到 ELM 分类器中并计算训练误差。

步骤 4)。判断是否满足搜寻结束判据, 即 $R_m=120$ 或 δ 符合最小误差要求, 如满足则停止搜寻, 相反, 重复执行步骤 3), 直至满足结束判据, 此时得到的为最优值。

步骤 5)。最后将得到的最优 l 值输入 ELM 分类器, 完成装备电力系统 PQD 信号分类器设计。

3 实验验证

3.1 PQD 扰动信号模拟

为验证所提方法对装备电力系统扰动信号分类的实际效果, 试验所用波形数据全部从自研的装备电力系统负荷特性试验平台获得, 该平台由发电机组、典型负载、目标仿真机、信号采集系统、单体测量设备以及上位机测控软件等几部分组成。其中发电机组功率为 120 kW, 典型负载包括谐波型负载、脉冲型负载、冲击型负载、常规阻感负载等基本单元及控制开关阵, 通过实时在线调整试验平台的控制参数与负载动作, 可对实际武器系统用电负荷特性进行模拟, 再现装备电力系统母线上的各种电能质量扰动。部分实测波形见图 5。




图 5 实测波形

Fig. 5 Measured waveform

3.2 分类效果实验

为全面分析所提方法对装备电力系统 PQD 信号的实际效果, 笔者从以下 4 个方面进行验证。

3.2.1 随机样本的识别率测试

由装备电力系统负荷特性试验平台实时调整负载的各项参数, 采集 7 类电能质量扰动信号各 150 组, 总计 1050 组试验样本, 分别从每类信号样本中抽取 100 组用于分类器训练, 其余 50 组做识别率测试, 分类器识别准确率统计结果见图 6。




图 6 分类统计结果

Fig. 6 Recognition effect of test set

图 6 中,样本类别号 1~7 分别代表 $R_1 \sim R_7$ 。可以看出,测试集共计 350 组样本 PQ 复合扰动信号仅有 6 个样本出现分类错误,整体分类正确率达到 98.3%,能够看出所构建的组合特征空间与分类器对于装备电力系统 PQ 复合扰动信号的识别具有很高的正确率。

3.2.2 噪声敏感性测试

从装备电力系统负荷特性试验平台随机产生并采集 $R_1 \sim R_7$ 复合扰动信号各 320 组,采样率 3.2 kHz,归一化处理后,分别叠加强度为 15、25、35 dB 的噪声,从每类信号样本中抽取 120 组用于分类器训练,其余 200 组做识别率测试,实验结果见表 2。表 2 中 15、25、35 dB 噪声强度及分类识别率平均分别为 97.6%、97.0%、97.4%。

表 2 噪声敏感性测试结果
Table 2 Test results under different SNR

扰动类型	噪声强度及分类识别率/%		
	15 dB	25 dB	35 dB
R_1	100.0	98.5	99.0
R_2	99.0	100.0	98.5
R_3	99.0	97.5	100.0
R_4	97.5	95.0	94.0
R_5	94.0	93.5	94.5
R_6	98.5	97.5	97.0
R_7	95.0	97.0	98.5

由表 2 可看出,在不同噪声强度下,7 种复合扰动信号的平均识别率均不小于 97%,说明构建的特征空间与分类器对噪声不敏感,可以看出所用的特征提取方法对于复合扰动特征区分度比较高;对于 R_4 (电压中断+电压波动)、 R_5 (电压瞬降+电压波动)两种复合扰动的分类识别率相较于其他 5 种偏低,主要原因是此两种复合扰动波形变化的临界极值非常接近,特征区分不是足够清晰,因此在识别过程中出现了较多次数的分类错误。

3.2.3 训练集样本数改变测试

从装备电力系统负荷特性试验平台采集足够多的 $R_1 \sim R_7$ 复合扰动信号,归一化处理后,从 $R_1 \sim R_7$ 每类信号中均抽取 25、50、100、200、400 数量不等的样本组数作分类器训练使用,从余下 $R_1 \sim R_7$ 中每类信号各抽取 120 组作为分类测试用。 $R_1 \sim R_7$ 在改变训练样本数条件下的识别统计结果见表 3。表 3 中 25、50、100、200、400 训练样本数及分类识别率平均分别为 68.6%、93.7%、97.3%、97.9%、95.1%。

由表 3 统计数据得出,当训练样本数低于 50 组时,分类器的识别率显著降低,仅为 68.6%,而训练

表 3 不同训练样本的测试结果

Table 3 Test results under different training samples					
扰动类型	训练样本数及分类识别率/%				
	25	50	100	200	400
R_1	70.8	95.8	99.2	100	95.0
R_2	70.0	95.0	100	99.2	96.7
R_3	65.8	92.5	97.5	98.3	95.0
R_4	66.7	91.7	95.0	95.8	94.2
R_5	65.0	90.8	95.8	96.7	92.5
R_6	67.5	95.8	96.7	97.5	95.8
R_7	71.7	94.2	97.5	97.5	96.7

样本数高于 200 组时,识别率有下降的趋势,其原因主要是样本数过低,会使得分类器训练不充分,信号的特征学习不全面,而过高情况下可能发生过度学习的问题。训练样本数在 50 组以上即达到较高的识别率,训练样本数 100 组相较于 200 组,其识别率并无明显提高,但会使得训练时间加长,降低训练效率,因此,选择适当的训练样本数对于分类器而言也是非常重要的。

3.2.4 与 ELM 比较

将该分类方法与未经过优化的 ELM 进行比较,其结果见表 4。由表 4 看出,PSO-ELM 无论是在训练速度上还是分类精度上都要优于未经优化的 ELM。

表 4 不同分类方法比较结果

Table 4 Comparison results of different classification methods		
项目	分类方法	
	ELM	PSO-ELM
训练样本数/组	200	200
测试样本数/组	120	120
平均训练时间/s	6.045 6	1.923 5
平均测试时间/s	5.104 6	1.018 4
平均识别率/%	91.700 0	97.500 0

4 结论

装备电力系统相较于地方电网具有负载功率比大,抗扰动能力差,兼有频率波动等特点。针对装备电力系统 PQD 识别进行了以下研究工作:

1)将 S 变换和 EMD 两种特征提取手段相融合,构建了一个新的组合特征向量集,能够对装备电力系统复合扰动信号进行全面刻画,特征边界区分更加明显,是信号扰动准确分类的必要前提。

2)利用 PSO 对 ELM 的隐含层神经元数目进行优化,为避免 PSO 搜寻进入局部最优陷阱而无法获得理想的优化参数,提出了一种改进的实变权重函数,

设计了分类器, 将其应用到装备电力系统电能质量复合扰动识别中, 所提方法的适用性较好, 达到了预期效果。

3) 利用装备电力系统负荷特性试验平台采集的大量 PQD 信号, 分别从随机样本的识别率测试, 不同噪声强度, 改变训练样本数以及与未经优化的 ELM 分类器比较 4 个方面对所提方法进行了全面实验验证; 结果表明, 该分类方法对 7 类典型装备电能质量复合扰动信号具有很高的识别率, 且对噪声不是很敏感, 相较于 ELM, 显著地减少了训练及分类时间, 进一步提高了分类的准确性。

参考文献:

- [1] 袁 东, 魏曙光, 马晓军. 装甲车辆供电系统研究现状与发展趋势[J]. 装甲兵工程学院学报, 2016, 30(6): 68-74.
YUAN Dong, WEI Shuguang, MA Xiaojun. Research status and development trend of power supply system for armored vehicle[J]. Journal of Academy of Armored Force Engineering, 2016, 30(6): 68-74.
- [2] 张 磊, 黄 纯, 江亚群, 等. 应用 HS 改进原子分解的电能质量扰动辨识分析[J]. 电网技术, 2015, 39(1): 194-201.
ZHANG Lei, HUANG Chun, JIANG Yaquin, et al. Identification analysis of power quality disturbances based on harmony search and atom decomposition[J]. Power System Technology, 2015, 39(01): 194-201.
- [3] 李加升, 戴瑜兴, 柴世杰. 基于预测机制的电能质量扰动检测方法研究[J]. 电力系统保护与控制, 2010, 38(17): 96-100.
LI Jiasheng, DAI Yuxing, CHAI Shijie. Research of the power quality disturbance detection method based on forecasting mechanism[J]. Power System Protection and Control, 2010, 38(17): 96-100.
- [4] 黄文清, 戴瑜兴. 电能质量扰动分类的决策树方法[J]. 湖南大学学报(自然科学版), 2007, 34(10): 57-61.
HUANG Wenqing, DAI Yuxing. A decision tree induction approach for power quality disturbances classification[J]. Journal of Hunan University(Natural Sciences), 2007, 34(10): 57-61.
- [5] 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 Haozhong, DING Yifeng, 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.
- [6] 王继东, 王成山. 电能质量扰动分类的贝叶斯方法[J]. 天津大学学报, 2006, 39(s1): 108-114.
WANG Jidong, WANG Chengshan. Bayes method of power quality disturbance classification[J]. Journal of Tianjin University, 2006, 39(s1): 108-114.
- [7] 姚建刚, 郭知非, 陈锦攀. 基于小波和 BP 神经网络的电能扰动分类新方法[J]. 电网技术, 2012, 36(5): 139-144.
YAO Jiangang, GUO Zhifei, CHEN Jinpan. A new approach to recognize power quality disturbances based on wavelet transform and BP neural network[J]. Power System Technology, 2012, 36(5): 139-144.
- [8] FAISAL M F, MOHAMED A, HUSSAIN A, et al. Support vector regression based S-transform for prediction of single and multiple power quality disturbances[J]. European Journal of Scientific Research, 2009, 34(2): 237-251.
- [9] 周维维, 管 春, 卢伟国. 多标签分类法在电能质量复合扰动分类中的应用[J]. 中国电机工程学报, 2011, 31(4): 45-50.
ZHOU Luowei, GUAN Chun, LU Weiguo. Application of multi-label classification method to categorization of multiple power quality disturbances[J]. Proceedings of the CSEE, 2011, 31(4): 45-50.
- [10] RAY P K, MOHANTY S R, KISHOR N, et al. Optimal feature and decision tree-Based classification of power quality disturbances in distributed generation systems[J]. IEEE Transactions on Sustainable Energy, 2014, 5(1): 200-208.
- [11] MASOUM M A S. Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks[J]. Science, Measurement & Technology, IET, 2010, 4(4): 193-205.
- [12] 韩 刚, 张建文, 褚 鑫, 等. 多特征组合及优化 SVM 的电能质量扰动识别[J]. 电力系统及其自动化学报, 2015, 27(8): 71-76.
HAN Gang, ZHANG Jianwen, CHU Xin, et al. Power quality disturbance classification based on multi-features combination and optimizing parameters of SVM[J]. Proceedings of the CSU-EPSA, 2015, 27(8): 71-76.
- [13] 黄南天, 张卫辉, 蔡国伟, 等. 采用改进多分辨率快速 S 变换的电能质量扰动识别[J]. 电网技术, 2015, 39(5): 1412-1418.
HUANG Nantian, ZHANG Weihui, CAI Guowei, et al. Power quality disturbances classification with improved multiresolution fast S-transform[J]. Power System Technology, 2015, 39(5): 1412-1418.
- [14] KUMAR R, SINGH B, SHAHANI D T, et al. Recognition of power-quality disturbances using S-transform-based ANN classifier and rule-based decision tree[J]. IEEE Transactions on Industry Applications, 2015, 51(2): 1249-1258.
- [15] 武荣华, 王天施, 侯宝明. 基于 EMD 的电能质量扰动检测与分类方法[J]. 辽宁石油化工大学学报, 2013, 33(2): 63-66.

(下转第 207 页)

- [5] 焦 瑾. 南京供电公司铁磁谐振事故分析[J]. 高电压技术, 2004, 30(8): 68-69.
JIAO Jin. Nanjing power supply company of ferromagnetic resonance overvoltage accidents and prevention[J]. High Voltage Engineering, 2004, 30 (8): 68-69.
- [6] 刘连睿. 电磁式电压互感器铁磁谐振事故分析及措施[J]. 华北电力技术, 2001(10): 47-49.
LIU Lianrui. Analysis and measures of ferroresonance accident of electromagnetic voltage transformer[J]. North China Electric Power, 2001(10): 47-49.
- [7] 陈树勇, 宋书芳, 李兰欣, 等. 智能电网技术综述[J]. 电网技术, 2009, 33(8): 1-7.
CHEN Shuyong, SONG Shufang, LI Lanxin, et al. Overview of smart grid technology[J]. Power Grid Technology, 2009, 33 (8): 1-7.
- [8] 张文亮, 刘壮志, 王明俊, 等. 智能电网的研究进展及发展趋势[J]. 电网技术, 2009, 33(13): 1-11.
ZHANG Wenliang, LIU Zhuangzhi, WANG Mingjun, et al. Research progress and development trend of smart grid [J]. Power System Technology, 2009, 33(13): 1-11.
- [9] 杜丁香, 徐玉琴. 配电网谐振接地方式的探讨[J]. 电力自动化设备, 2001, 21(12): 54-56.
DU Dingxiang, XU Yuqin. Discussion of resonance grounding mode in distribution network[J]. Electric Power Automation Equipment, 2001, 21(12): 54-56.
- [10] JONSCHER A K. Dielectric relaxation in solids[J]. Journal of Physics D-Applied Physics, 1999, 32(14): 57-70.
- [11] WESTERLUND S, EKSTAM L. Capacitor theory [J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2002, 1(5): 826-839.
- [12] HABA T C, ABLART G, CAMPS T, et al. Influence of the electrical parameters on the input impedance of a fractal structure realised on silicon[J]. Chaos Solitons & Fractals, 2005, 24(2): 479-490
- [13] WAN F Q, MA X K. Transfer function modeling and analysis of the open-loop buck converter using the fractional calculus[J]. Chinese Physics B, 2013, 22(3): 232-239.
- [14] IGOR P. Fractional differential equations[J]. Academic Press Inc San Diego CA, 1999, 28(2): 2.
- [15] MAINARDI F. Fractional calculus[C]//Fractals and Fractional Calculus in Continuum Mechanics. Springer-Verlag, Wien and New York, 1997: 291-348.
- [16] 刘 凡, 孙才新, 司马文霞, 等. 铁磁谐振过电压混沌振荡的理论研究[J]. 电工技术学报, 2006, 21(2): 103-107.
LIU Fan, SUN Caixin, SIMA Wenxia, et al. Theoretical study on chaotic resonance of ferroresonance overvoltage [J]. Transactions of the Electrotechnical Society, 2006, 21 (2): 103-107.
- [17] 惠 萌, 刘盼芝, 白 磷, 等. 非自治铁磁谐振电路过电压脉冲时滞同步抑制方法研究[J]. 西安交通大学学报, 2014, 48(6): 55-59.
HUI Meng, LIU Panzhi, BAI Lin, et al. The non autonomous ferroresonance overvoltage pulse delay circuit synchronous suppression method[J]. Journal of Xi'an Jiaotong University, 2014, 48(6): 55-59.
- [18] YANG Ningning, HAN Yuchao, WU Chaojun, et al. Dynamic analysis and fractional-order adaptive sliding mode control for a novel fractional-order ferroresonance system [J]. Chinese Physics B, 2017, 26(8): 080503.
- [19] YANG N, LIU C. A novel fractional-order hyperchaotic system stabilization via fractional sliding-mode control[J]. Nonlinear Dynamics, 2013, 74(3): 721-732.
- [20] WU C, SI G, ZHANG Y, et al. The fractional-order state-space averaging modeling of the buck-boost DC/DC converter in discontinuous conduction mode and the performance analysis[J]. Nonlinear Dynamics, 2015, 79(1): 689-703.

张勋康(1963—), 男, 高级工程师, 工程硕士, 从事从事电力系统故障分析工作。

(上接第 201 页)

- WU Ronghua, WANG Tianshi, HOU Baoming. The power quality disturbance detection and classification method based on EMD[J]. Journal of Liaoning Shihua University, 2013, 33(2): 63-66.
- [16] 陈晓静, 李开成, 肖 剑, 等. 一种实时电能质量扰动分类方法[J]. 电工技术学报, 2017(32): 45-55.
CHEN Xiaojing, LI Kaicheng, XIAO Jian, et al. A method of real-time power quality disturbance classification [J]. Transactions of China Electrotechnical Society, 2017 (32): 45-55.
- [17] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006(70): 489-501.
- [18] HUANG G B, LEI C K, SIEW C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes[J]. IEEE Transactions on Neural Networks, 2006, 17(4): 879-892.
- [19] KENNEDY J, EBERHART R C. Particle swarm optimization[C]//Proceedings of IEEE International Conference on Neural Networks. Perth, Australia: IEEE, 1995: 1942-1948.
- [20] ROBINSON J, RAHMAT-SAMII Y. Particle swarm optimization in electromagnetics[J]. IEEE Transactions on Antennas and Propagation, 2004, 52(2): 397-407.
- [21] 袁海满, 吴广宁, 高 波. 基于 DGA 的粒子群极限学习机电力变压器故障诊断[J]. 高压电器, 2016, 52(11): 176-180.
YUAN Haiman, WU Guangning, GAO Bo. Fault diagnosis of power transformer using particle swarm optimization and extreme learning machine based on DGA[J]. High Voltage Apparatus, 2016, 52(11): 176-180.
- 尹志勇(1979—), 男, 博士, 讲师, 主要从事装备电力系统电能质量扰动分析等方面的研究工作。