

基于改进 EWT 的模拟电路故障诊断研究

王 宁 李志华 窦修超

(河海大学 能源与电气学院 江苏 南京 211100)

摘 要: 针对模拟电路故障信号非线性、非平稳性、容差性的特点,提出了一种基于经验小波变换(EWT)的模拟电路故障诊断方法。但信号分解需要设定分割模态个数,为实现经验小波变换中 Fourier 谱的自适应分割,提出了自适应无参的经验小波变换(APEWT)方法。经验小波变换能有效分离信号的调幅调频成分,将改进方法对 Leapfrog benchmark 电路不同故障的输出信号进行模态分解以及时频能量谱分析,采取人工智能算法进行实验分析,结果表明其分解的各分辨率模态具有相应的时域特征。并与希尔伯特黄变换的方法进行对比,表明所提出的方法不仅能有效地提取模拟电路软故障特征,诊断正确率高于后者,而且具有完备小波理论支撑,计算速度快,不存在虚假分量的特点。这为模拟电路故障在线诊断提供了新思路。

关键词: 模拟电路; 故障诊断; 经验小波分解; 人工智能; 信号分离

中图分类号: TN108.7

文献标识码: A

文章编号: 1673-629X(2019)03-0154-05

doi: 10.3969/j.issn.1673-629X.2019.03.032

Research on Analog Circuit Fault Diagnosis Based on Improved EWT

WANG Ning, LI Zhi-hua, DOU Xiu-chao

(School of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: Aiming at the nonlinearity, non-stationary and poor component tolerances in extracting analog circuit fault signals features, we propose a new method based on EWT. However, it is difficult to set the number of modes in separating Fourier spectrum. To fulfill an adaptive separation of Fourier spectrum, we put forward an adaptive nonparametric EWT (APEWT) which can separate the amplitude modulation-frequency modulation components effectively. It has been applied to analyze the output signals of different faults in the Leapfrog benchmark circuit to perform modal decomposition and time-frequency energy spectrum analysis. The experimental analysis carried by artificial intelligence algorithm shows that the resolution modes obtained by EWT have the corresponding time domain signal characteristics. By comparing with the method of HHT, the proposed method can not only extract features of soft fault features in analog circuit effectively, diagnose more accuracy than the latter, but it has complete wavelet theory, high calculation speed without no false mode. This will help to provide a new idea in extracting features in analog circuit soft fault diagnosis online.

Key words: analog circuit; fault diagnosis; empirical wavelet transform; artificial intelligence; signal decomposition

0 引 言

随着大规模集成电路的广泛应用,模拟电路的发展趋向于更加复杂化。其具体表现为电路元件的容差性、非线性和故障的多样性等特点,而模拟电路故障诊断的重点是在有限的输出节点提取有效的故障特征,这大大增加了故障诊断的难度。20 世纪 90 年代,基于规则的人工智能技术得到了不断发展并成为故障诊断的主要方向,目前主要基于信号分析的故障特征提取方法为傅里叶变换^[1-2]和小波变换等^[3-5]。

文献[6]采用傅里叶变换来提取构成样本空间的

电路输出电压特征,根据决策树定位故障。该方法的缺点是精度不理想,没有研究软故障类型,而且傅里叶变换的条件苛刻,不适用于非平稳信号。文献[7]结合小波理论和神经网络的特点对非线性电路进行诊断,但小波变换的方法易受到选取的小波函数的影响,选取不同的小波基对计算的结果影响很大,目前还缺少准确地选取小波基的系统方法。文献[8]将改进的希尔伯特黄变换应用到非线性电路中,并针对 EMD 的缺点进行改进,虽然诊断正确率有提升,但是 EMD 算法仍存在理论支撑不足的情况。

收稿日期: 2018-05-02

修回日期: 2018-09-05

网络出版时间: 2018-12-20

基金项目: 江苏省自然科学基金(BK20151500)

作者简介: 王 宁(1994-),男,硕士研究生,研究方向为人工智能与模拟电路故障诊断;李志华,教授,硕导,研究方向为复杂系统故障诊断等。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20181219.1553.090.html>

经验小波变换(EWT)是一种新型的自适应信号处理方法^[9],以小波变换为基础,是一种建立自适应小波提取信号的幅频分量的信号分析方法^[10-13]。EWT通过对信号频谱进行自适应划分,构造正交小波滤波器组,将待处理的信号在频域上进行经验小波变换得到若干具有紧支撑 Fourier 频谱信息的模态分量,从而实现信号的特征提取。针对 EWT 实现需要设定分割模态个数的问题,提出自适应无参 EWT 的改进方法,实现了信号的自适应分解,分解后的数据用改进后的 EWT 进行处理,计算分解模态的能量以及边际谱总能量,构成特征向量。

1 EWT 方法

基于传统的 EMD 方法由于采用三次样条插值、终止条件不合理、欠包络问题造成模态混叠、虚假分量、数学理论支撑不足的现象,其改进方法 EEMD 在一定程度上解决了频率混叠的问题,但是出现了新的

$$\hat{\phi}_m(\omega) = \begin{cases} 1, & |\omega| \leq (1-\gamma)\omega_m \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_m}(|\omega| - (1-\gamma)\omega_m)\right)\right], & (1-\gamma)\omega_m \leq |\omega| \leq (1+\gamma)\omega_m \\ 0, & \text{其他} \end{cases} \quad (2)$$

$$\hat{\psi}_n(\omega) = \begin{cases} 1, & (1+\gamma)\omega_m \leq |\omega| \leq (1-\gamma)\omega_{m+1} \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_{m+1}}(|\omega| - (1-\gamma)\omega_m)\right)\right], & (1-\gamma)\omega_{m-1} \leq |\omega| \leq (1+\gamma)\omega_{m+1} \\ \sin\left[\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_m}(|\omega| - (1-\gamma)\omega_m)\right)\right], & (1-\gamma)\omega_m \leq |\omega| \leq (1+\gamma)\omega_m \\ 0, & \text{其他} \end{cases} \quad (3)$$

其中, $\gamma < \min_m\left(\frac{\omega_{m+1} - \omega_m}{\omega_{m+1} + \omega_m}\right)$, $\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3)$ 。

通过类比小波变换的构造方法计算 EWT,其细节函数 $W_f^e(n, t)$ 和近似函数 $W_f^e(0, t)$ 的具体公式分别为:

$$W_f^e(n, t) = \langle f(t), \psi_n(t) \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau = F^{-1}[f(\omega) \hat{\psi}_n(\omega)] \quad (4)$$

$$W_f^e(0, t) = \langle f(t), \phi_1(t) \rangle = \int f(\tau) \overline{\phi_1(\tau - t)} d\tau = F^{-1}[f(\omega) \hat{\phi}_1(\omega)] \quad (5)$$

其中, $\psi_n(t)$ 为 EWF; $\hat{\psi}_n(\omega)$ 和 $\hat{\phi}_1(\omega)$ 分别为 $\psi_n(t)$ 和 $\phi_1(t)$ 的 Fourier 变换; $\overline{\psi_n(t)}$ 和 $\overline{\phi_1(t)}$ 分别为 $\psi_n(t)$ 和 $\phi_1(t)$ 的复共轭函数; $\langle \cdot, \cdot \rangle$ 表示内积运算。

单模态个数 N 估算—APEWT:

经验小波变换中首先要预先估算模态的个数 N ,如果 N 过大,分解得到的模态能量过小,特征频率不明显,如果 N 过小,则信号分解不彻底,单分量模态复杂,不利于分析。因此,选取合适的模态个数 N 对后

计算量增大、模型复杂性增高的弊端。为解决此问题, Gilles 结合小波分析以及 EMD 的自适应性提出了经验小波分解方法。将原始信号 $f(t)$ 分解为 N 个模态分量 $f_i(t)$ 之和,即为:

$$f(t) = \sum_{i=1}^N f_i(t) \quad (1)$$

其中, $f_i(t)$ 为调幅调频信号(AM-FM)。

计算信号 $f(t)$ 的 Fourier 变换 $F(\omega)$ 。需要在 Fourier 频谱范围 $[0, \pi]$ 切割为 N 个区间,除去边界 0 和 π ,还有 $N-1$ 个边界需要确定。定义 ω_n 为区分边界,以搜索频谱的极大极小值方法作为边界,则每段可表示为: $\Lambda_n = [\omega_{n-1}, \omega_n]$, $n = 1, 2, \dots, N$, 且有 $\bigcup_{n=1}^N \Lambda_n = [0, \pi]$ 。

经验小波定义在区间 Λ_n 上的带通滤波器,基于 Littlewood-Paley 和 Meyer 小波^[14]的构造思想,尺度函数 $\phi_m(\omega)$ 和小波函数 $\psi_n(\omega)$ 定义如下:

续的分析影响重大。EWT 未能解决此问题,只能通过试凑的方法。结合低通滤波器电路的输出信号特点,提出了估算模态分量个数 N 的方法,实现了数据的自适应性驱动,即自适应无参经验小波变换(APEWT)解决模态分离个数的问题。

APEWT 包括两部分,分别是 Fourier 谱的自适应分割以及建立基于滤波器组的小波变换,其核心是自适应地分割 Fourier 谱。首先计算函数的尺度空间表达形式的 Fourier 谱,然后分离尺度空间直方图即找到尺度空间直方图的模态分量。寻找需要的模态分量即为一个二类聚类问题,常见的方法有概率论方法和 K-means 方法。其次,类似于小波变换,构造动态滤波器组,并用于给定信号的自适应分解。因此,通过应用 APEWT 方法,一个复合信号可以分解为若干个本征模态函数,相应地可以用 Hilbert 变换计算信号的时频信息。

文献[15]将函数的 Fourier 谱转换成尺度空间表示,将 Fourier 谱的自适应划分转化成在尺度空间上找到“有意义”的模态,文中方法的详细步骤如下:

对于函数 $f(x)$, 其傅里叶频谱表示为 $F(x)$, 其尺度空间表示为 $L(x, t)$ [16-17]。在尺度参数 t 或者尺度步长 s ($s = \sqrt{t/t_0}$, $s = 1, 2, \dots$) 上, 函数 $L(x, t)$ 关于其参数 x 的极小值是递减函数, 并且随着 t 增大, 不会有其他新的极小值出现。每个初始极小值在尺度空间平面产生一条曲线, 如果定义初始极小值为 N_0 , 这些局部极小值定义了一个长度为 L_i 的尺度空间曲线 C_i ($i \in [1, N_0]$), 其中长度 L_i 定义为 $L_i = \max\{s/i - \text{th minimum exits}\}$ 。基于此, 直方图含有较大信息量的模态定义如下:

如果直方图的模态边界关于 t , 局部极小值产生长尺度空间曲线为一致极小值, 其才有意义。相应地, 寻找有意义的直方图的模态等价于寻找一个阈值 T , 使得那些尺度空间曲线的长度大于 T 的相应曲线对应一致极小值。因此, 原始问题转换为在集合 $\{L_i\}_{i=1, N_0}$ 的二类聚类问题。

电路不同故障元件产生的输出信号不同, 其特点是具有紧致支撑的傅里叶频谱。分离出不同的故障类型就等同于分割信号傅里叶谱并将其在对应检测到的支撑频谱进行滤波。基于此, 文中将这种新的特征提取方法应用于模拟电路故障诊断中。

2 EWT 故障诊断策略与步骤

假设电路的唯一可测节点为输出节点, 基于 APEWT 的模拟电路故障诊断步骤如下:

Step1: 利用 PSpice 对电路施加激励信号并进行蒙特卡洛分析, 并将数据导入到 MATLAB 中。

Step2: 计算各故障信号的 EWT 分量, 根据式 6 计算各阶 EWF 与原始信号的相关系数为 r_j ($j = 1, 2, \dots, N$) [18]。

$$r_j = \frac{\text{cov}(f, e_j)}{\sigma_f \sigma_{e_j}} = \frac{\sum_{i=1}^n (f_i - \bar{f})(e_{ji} - \bar{e}_j)}{\sqrt{\sum_{i=1}^n (f_i - \bar{f})^2} \sqrt{\sum_{i=1}^n (e_{ji} - \bar{e}_j)^2}} \quad (6)$$

其中, e_j 为 EWF 与原始信号 f 的标准差; n 为 EWF 包含元素的个数; \bar{f} 为信号均值; e_{ji} 为第 j 个 EWF 的第 i 个元素; \bar{e}_j 为第 j 个 EWF 分量的均值。

由于信号分解得到的 EWF 含有部分微弱信息的分量, 其对分类结果产生的影响不大, 选择将其删去, 以减少计算的量, 文中取出满足 $r_j \geq 0.3$ 的 EWF 分量 [19]。

Step3: 计算 EWF 分量的能量, 第 j 个 EWF 的能量计算如下:

$$E_j' = \frac{1}{n-1} \sum_{i=1}^n e_{ji}^2 \quad (7)$$

Step4: 用各阶 EWF 与总能量的比值作为归一化能量的计算, 第 j 个 EWF 的归一化能量为:

$$E_j = \frac{E_j'}{\sum_{i=1}^n E_i} \quad (8)$$

Step5: 原始信号 $f(t)$ 经过 EWT 处理得到 $f_i(t)$,

满足 $f(t) = \sum_{i=1}^n f_i(t)$, $f_i(t)$ 按式 9 进行 Hilbert 变换得到 Hilbert 谱 $\hat{f}_i(w, t)$ 。

$$\hat{f}_i(w, t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{f_i(\tau)}{t - \tau} d\tau \quad (9)$$

构造解析信号, 计算单个 EWF 的幅值函数 $a_i(w, t) = \sqrt{\hat{f}_i^2(w, t) + \hat{f}_i'^2(w, t)}$ 和相位函数 $\phi_i(t) = \arctan \frac{\hat{f}_i'(t)}{\hat{f}_i(t)}$, 进一步求出单个 EWF 的瞬时频率 $\text{fr}_i(t)$ 。

$$\text{fr}_i(t) = \frac{1}{2\pi} \cdot \frac{d\phi_i(t)}{dt} \quad (10)$$

将信号幅度表示为时间和频率的函数 Hilbert 幅值谱, 即:

$$H(w, t) = \text{Re} \sum_{i=1}^n a_i(t) \cdot e^{j\phi_i(t)} \quad (11)$$

Hilbert 边际谱表示不同频率幅度或能量的贡献程度, 适合对原信号特征解释和提取, Hilbert 边界谱能量计算如下:

$$E_{\text{bjp}} = \int_0^T \hat{H}(w, t) dt \quad (12)$$

将 EWF 的归一化能量与 Hilbert 边际谱总能量 E_{bjp} 构成联合特征 $T = [E_1, E_2, \dots, E_p, E_{\text{bjp}}]$, 其中 p 为满足 $r_j \geq 0.3$ 的 EWF 分量的个数。

3 EWT 模拟电路故障诊断实例

文中选取覆盖较多经典电路结构的 Leapfrog benchmark 电路作为诊断样本电路, 其具有代表性和普遍性。实际上, Leapfrog benchmark 电路是一个低通滤波器, 如图 1 所示。

设定输入信号为调幅调频信号, 幅值解调和频率解调方法能够避免传统 Fourier 频谱中的复杂边带分析, 有效识别故障特征频率。因此选取仿真信号 $x(t)$ 作为输入信号, 其中 $x(t)$ 由 2 种信号组成, 分别为调频信号 $x_{11}(t)$ 和调幅信号 $x_{12}(t)$, 如下式所示。

$$\begin{cases} x_{11}(t) = \cos(400\pi t + \sin(200\pi t)) \\ x_{12}(t) = 2\cos(100\pi t) \cos(1000\pi t) \end{cases} \quad (13)$$

电阻和电容的值如图 1 所示, 文中将电阻和电容的正常容差范围设置在 $\pm 5\%$, 经过灵敏度分析, 主要有 8 种故障模式, 分别为 $R_1 \downarrow, R_2 \uparrow, R_7 \downarrow, C_1 \downarrow, C_2 \uparrow, C_5 \downarrow, R_1 \downarrow, R_4 \uparrow, R_3 \uparrow, C_4 \uparrow$, 分别用 $F_1 \sim F_8$ 表

示, F_0 为正常状态。其中, \uparrow 和 \downarrow 分别表示元件大于或小于正常容差范围, 若元件的标称值为 X , 则其软故障范围的表达为 $[0.5X, 0.95X] \cup [1.05X, 1.5X]$ 。

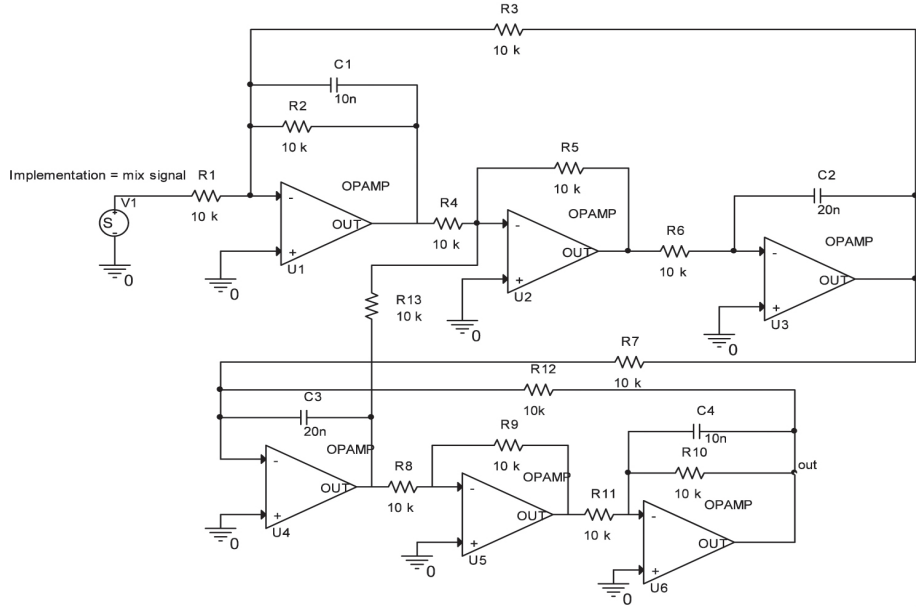


图 1 Leapfrog benchmark 电路

利用 PSpice 软件对电路进行 100 次蒙特卡洛分析, 采样时间为 $0 \sim 0.08\text{ s}$, 将数据导入到 MATLAB。Fourier 谱分割采取尺度空间方法, 解决二类聚类采用 Otsu 方法, 经过自适应无参经验小波变换。图 2 为 $R_1 \downarrow$ 状态下输出信号频谱及每个滤波器所支撑的被检测到的边界, 观察得到自适应无参经验小波变换可以分离不同的模式。




图 2 仿真信号部分频谱及支撑边界

将信号分解为 n 个 EWFs, 分别计算其能量 $E_j (j = 1, 2, \dots, n)$ 和其 Hilbert 边界谱总能量 E_{bjp} , 将 E_j 和 E_{bjp} 组合成特征向量。限于篇幅, 表 1 为部分故障下的特征向量。由此看出, 不同故障下的信号分解得到的 EWF 的能量及边界谱能量具有不同特征。模式能量主要集中在前两个 EWF 中, 且不同的故障状态其模式分量的能量有差别, 如故障 F_1, F_5 和 F_7 。而正常状态与故障 F_1 的模式能量基本相同, 但其边界谱能量区别较大。因此提取 EWF 的能量特征可以较好地区分不同状态的电路状况。

表 1 部分故障下 EWF 能量和边界谱能量

模态能量	正常 F_0	故障 F_1	故障 F_5	故障 F_7
E_1	0.344 0	0.355 3	0.384 5	0.328 6
E_2	0.320 8	0.315 9	0.282 4	0.342 1
E_3	0.065 7	0.065 9	0.073 9	0.058 3
E_4	0.178 7	0.178 3	0.163 4	0.183 1
E_{bjp}	0.217 6	0.310 8	0.219 6	0.268 0

得到组合特征向量后, 进行归一化处理, 并将其 60 次作为训练样本, 其余 40 次作为测试样本。将提取到的特征输入到 SVM 分类器中, 采取交叉验证方法寻找最优参数 c 和 g , 分类得到的结果如表 2 所示。对比改进的 HHT^[20] 方法, 可以看出文中方法的正确率较高, 对比基于手动设定分解模式的 EWT 方法正确率略有提升。由于采用自适应无参的方法改进算法使得计算时间有所增加, 但是文中方法实现了数据的自适应性分解。

表 2 不同方案不同故障的诊断率 %

故障状态	改进的 HHT	EWT	文中方法
F_0	100	100	100
F_1	99.10	100	100
F_2	100	95	97.5
F_3	98.75	100	100
F_4	95.23	95	97.5
F_5	100	100	100
F_6	100	97.5	97.5
F_7	94.34	100	100
F_8	90.23	100	100

4 结束语

针对 EWT 对模拟电路故障信号分解的自适应性不足现象,提出了自适应无参的经验小波变换,利用自适应无参经验小波变换计算出单分量个数,相应确定信号 Fourier 谱的划分边界,然后构造滤波器组,对相应区间的频谱进行滤波,从而将信号分解为若干具有紧支撑频谱的 EWF 分量,再选取与原始信号相关系数较大的 EWF,计算其能量与边际谱。该方法实现了数据的自适应性分解,并将这种新颖的方法应用到模拟电路故障诊断中。通过实验与 EEMD 对比,结果表明其不仅在提取电路的故障特征中具有较好的有效性和可靠性,而且不存在模态混叠现象,为人工智能技术在模拟电路故障在线诊断技术提供了理论支持。此外,该方法在多故障的诊断中也取得了不错的效果。

参考文献:

- [1] 罗 慧,王友仁,崔 江. 基于最优分数阶傅里叶变换的模拟电路故障特征提取新方法[J]. 仪器仪表学报, 2009, 30(5): 997-1001.
- [2] 孙 健,王成华. 基于 mRMR 原则和优化 SVM 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(1): 221-226.
- [3] GUO Yangming, MA Jiezhong, XIAO Fan, et al. SVM with optimized parameters and its application to electronic system fault diagnosis [C]//Proceedings of IEEE ICPHM. Denver, CO, USA: IEEE, 2012.
- [4] 刘海松,吴杰长,陈国钧. 克隆选择优化的 SVM 模拟电路故障诊断方法[J]. 电子测量与仪器学报, 2010, 24(12): 1132-1136.
- [5] 祝文姬,何怡刚. 一种新的模拟电路故障特征提取与诊断方法[J]. 湖南大学学报: 自然科学版, 2011, 38(4): 41-46.
- [6] 俞雪平,胡云安,郑致刚. 基于分层决策的模拟电路故障诊断技术研究[J]. 计算机测量与控制, 2009, 17(2): 304-306.
- [7] 谢 涛. 基于(多)小波(包)神经网络及优化的模拟电路故障诊断研究[D]. 长沙: 湖南大学, 2011.
- [8] 汪良伟. 基于 HHT 和 SVDD 的模拟电路故障诊断研究[D]. 南京: 南京邮电大学, 2015.
- [9] GILLES J. Empirical wavelet transform [J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [10] 王秋生,陈 璐,袁海文,等. 基于经验小波变换的电晕电流降噪方法[J]. 电网技术, 2017, 41(2): 670-676.
- [11] PAN Jun, CHEN Jinglong, ZI Yanyang, et al. Monocomponent feature extraction for mechanical fault diagnosis using modified empirical wavelet transform via data-driven adaptive Fourier spectrum segment [J]. Mechanical Systems and Signal Processing, 2016, 72-73: 160-183.
- [12] 李志农,朱 明,褚福磊,等. 基于经验小波变换的机械故障诊断方法研究[J]. 仪器仪表学报, 2014, 35(11): 2423-2432.
- [13] 向 玲,李媛媛. 经验小波变换在旋转机械故障诊断中的应用[J]. 动力工程学报, 2015, 35(12): 975-981.
- [14] DAUBECHIES I. Ten lectures on wavelets [M]. Philadelphia: Society for Industrial and Applied Mathematics, 1992.
- [15] GILLES J, HEAL K. A parameterless scale-space approach to find meaningful modes in histograms application to image and spectrum segmentation [J]. International Journal of Wavelets, Multi-resolution and Information Processing, 2014, 12(6): 1450044(1-17).
- [16] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2011, 1(1): 1-41.
- [17] LINDBERG T. Scale-space theory in computer vision [M]. Berlin: Springer, 1994.
- [18] 尚海昆,苑津莎,王 瑜,等. 基于交叉小波变换和相关系数矩阵的局部放电特征提取[J]. 电工技术学报, 2014, 29(4): 274-281.
- [19] 贾亚飞,朱永利,王刘旺,等. 基于 VMD 和多尺度熵的变压器内绝缘局部放电信号特征提取及分类[J]. 电工技术学报, 2016, 31(19): 208-216.
- [20] 单剑锋,汪良伟,宋晓涛. 基于 HHT 和 SVDD 的模拟电路故障诊断研究[J]. 计算机技术与发展, 2015, 25(7): 179-183.