

DOI: 10.13382/j.jemi.2017.04.006

# 基于 LMD 多尺度熵和极限学习机的 模拟电路故障诊断\*

刘美容<sup>1,2</sup> 曾黎<sup>1</sup> 何怡刚<sup>3</sup> 李向新<sup>4</sup>

(1. 湖南师范大学物理与信息科学学院 长沙 410081; 2. 合肥工业大学电气工程博士后流动站 合肥 230009;  
3. 合肥工业大学电气与自动化工程学院 合肥 230009; 4. 国网湖南省邵阳供电公司 邵阳 422000)

**摘要:**为了高速、高效的测试和诊断模拟电路,提出一种将局部均值分解(LMD)多尺度熵和极限学习机相结合的模拟电路故障诊断的新方法。该方法中,首先采用 LMD 将故障信号分解为若干个乘积函数(production function, PF);然后,求出各 PF 分量的多尺度熵并构造故障特征向量;最后,将特征向量输入到极限学习机中进行训练和测试。仿真实验结果显示采用该方法诊断时间只需 0.028 74 s,诊断精度达到了 98.89%。相较于其他 3 种方法有效减少诊断时间,提高故障诊断精度。

**关键词:**局部均值分解;极限学习机;多尺度熵;故障诊断;特征向量提取

**中图分类号:** TP206 **文献标识码:** A **国家标准学科分类代码:** 520.204

## Analog circuit fault diagnosis based on LMD multi-scale entropy and extreme learning machine

Liu Meirong<sup>1,2</sup> Zeng Li<sup>1</sup> He Yigang<sup>3</sup> Li Xiangxin<sup>4</sup>

(1. College of Physics and Information Science, Hunan Normal University, Changsha 410081, China;  
2. Electric Engineering Postdoctoral Center, Hefei University of Technology, Hefei 230009, China;  
3. College of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China;  
4. State Grid Shaoyang Power Supply Company, Shaoyang 422000, China)

**Abstract:** In order to efficiently test and high speed diagnose analog circuits, a new analog circuit fault diagnosis method based on LMD multi-scale entropy and extreme learning machine is proposed in this paper. First, the fault signal is decomposed into several production functions by LMD. Then, the multi-scale entropy of each PF component is worked out and fault feature vectors are constructed. Finally, the fault feature vectors are feed into the extreme learning machine to train and test. The simulation results show that the diagnosis time only needs 0.028 74 s, and the accuracy of fault diagnosis can achieve 98.89%. Compared with other three ways, the method can effectively reduce the diagnosis time and improve the accuracy of fault diagnosis.

**Keywords:** LMD; extreme learning machine; multi-scale entropy; fault diagnosis; feature vector extraction

## 1 引言

为了诊断和维修复杂的电子设备,保证系统的正常运行,往往需要耗费巨大的精力财力。在复杂的电子系统中,由于模拟电路自身的非线性因素,以及元器件中存在容差,因此给模拟电路的故障诊断造成了一定的困难。

传统的故障诊断方法有故障字典法、故障参数识别法、网络撕裂法等<sup>[1-2]</sup>。但随着模拟电路越来越复杂,诊断精度也要求越来越高,传统的故障诊断方法已经不能满足当代的需求。

近年来,人工智能快速发展,神经网络、支持向量机、决策树等广泛应用于故障诊断中<sup>[3]</sup>,特征提取和构造分类器是模拟电路故障诊断的两个重要步骤,其中特征提

收稿日期:2016-10 Received Date: 2016-10

\* 基金项目:国家自然科学基金(51577046)、国家自然科学基金重点项目(51637004)、国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、湖南省教育厅项目(17C0956)资助

取的常用的方法有小波变换<sup>[4-5]</sup>,但进行小波变换进行故障提取时,由于无法精确的选取最优小波基,所以不能保证经小波变换后能够得到最优的故障特征<sup>[6]</sup>。本文采用局部均值分解(LMD)多尺度熵来进行特征提取,LMD是由 Smith<sup>[7]</sup>提出的一种能将具有多分量的原始复杂信号分解为一系列 PF 分量的方法,该方法将复杂的多分量调频信号分解为单分量的调频信号,且其分解结果保持原信号的幅值与频率变化。国内石瑞敏等人<sup>[8]</sup>也应用了 LMD 解决了滚动轴承故障诊断。由于多尺度熵是衡量时间序列在不同尺度上的复杂性,它是在样本熵的基础上提出来的,相对于样本熵是衡量时间序列在单一尺度上的复杂性,多尺度熵能更好的反映信号的特征<sup>[9-10]</sup>。多尺度熵是时间序列在维数变化时产生新模式概率大小的量度,具有很强的抗噪声和抗干扰能力,是量化非线性时间序列复杂度的良好工具<sup>[11-12]</sup>。本文采用极限学习机(extreme learning machine, ELM)来进行故障分类,极限学习机是 2006 年提出的一种单层前馈神经网络<sup>[13-15]</sup>,它不需要建立精确的数学模型,也无需反复调整隐含层参数,和传统的神经网络相比具有学习能力快,泛化能力强等优点。

因此,本文先采用 LMD 和多尺度熵相结合的方法进行故障电路特征向量提取,再将特征向量输入 ELM 或 BP 神经网络进行故障识别。

## 2 基于 LMD 多尺度熵的特征向量提取

### 2.1 LMD 算法

LMD 分解的实质是将原始信号分解为一系列的 PF 分量  $PF_1, PF_2, \dots, PF_n$  和一个残余分量  $R$  之和,具体分解过程如下<sup>[10]</sup>:

1) 确定原始信号  $x(t)$  全部局部极值点  $n_i$  及其时候值  $tn_i$ , 计算相邻两个极值点  $n_i$  和  $n_{i+1}$  的平均值  $m_i$ :

$$m_i = \frac{n_i + n_{i+1}}{2} \quad (1)$$

将所有的平均值  $m_i$  在其对应的极值点时候  $tn_i$  和  $tn_{i+1}$  之间进行直线延伸,即可得到局部均值线段  $m_{11}(t)$ , 然后采用滑动平均法对  $m_{11}(t)$  进行滑动处理,得到局部均值函数  $m_{11}(t)$ 。

2) 计算局部幅值  $a_i$  如下:

$$a = \frac{|n_i - n_{i+1}|}{2} \quad (2)$$

将所有的局部幅值  $a_i$  在其对应的极值点时候  $tn_i$  和  $tn_{i+1}$  之间进行直线延伸,得到局部幅值线段  $a_{11}(t)$ , 然后同样采用滑动平均法对局部幅值线段  $a_{11}(t)$  进行平滑处理,得到包络估计函数  $a_{11}(t)$ 。

3) 将局部均值函数  $m_{11}(t)$  从原始信号  $x(t)$  中分离

出来:

$$h_{11}(t) = x(t) - m_{11}(t) \quad (3)$$

4) 对  $h_{11}(t)$  进行解调,如下:

$$s_{11}(t) = h_{11}(t)/a_{11}(t) \quad (4)$$

计算  $s_{11}(t)$  的包络估计函数  $a_{12}(t)$ , 如果  $a_{12}(t)$  等于 1, 则说明  $s_{11}(t)$  是一个纯调频信号, 否则需要对  $s_{11}(t)$  重复以上步骤, 直到  $-1 \leq s_{1n}(t) \leq 1$ , 且其包络估计函数满足  $a_{1(n+1)}(t) = 1$ 。所以:

$$\begin{cases} h_{11}(t) = x(t) - m_{11}(t) \\ h_{12}(t) = s_{11}(t) - m_{12}(t) \\ \vdots \\ h_{1n}(t) = s_{1(n-1)}(t) - m_{1n}(t) \end{cases} \quad (5)$$

其中,

$$\begin{cases} s_{11}(t) = h_{11}(t)/a_{11}(t) \\ s_{12}(t) = h_{12}(t)/a_{12}(t) \\ \vdots \\ s_{1n}(t) = h_{1n}(t)/a_{1n}(t) \end{cases} \quad (6)$$

5) 迭代过程中产生的全部包络估计函数的乘积即为包络信号  $a_1(t)$ :

$$a_1(t) = a_{11}(t)a_{12}(t)\dots a_{1n}(t) = \prod_q^n a_{1q}(t) \quad (7)$$

6) 将包络信号  $a_1(t)$  和纯调频信号  $s_{1n}(t)$  相乘便可以得到第一个 PF 分量:

$$PF_1(t) = a_1(t)s_{1n}(t) \quad (8)$$

7) 从  $x(t)$  中分离出第一个 PF 分量  $PF_1(t)$ , 获得新的信号  $u_1(t)$ , 将  $u_1(t)$  作为原始数据重复以上迭代过程, 循环  $k$  次, 直到  $u_k(t)$  为一个单调函数。

$$\begin{cases} u_1(t) = x(t) - PF_1(t) \\ u_2(t) = u_1(t) - PF_2(t) \\ \vdots \\ u_k(t) = u_{k-1}(t) - PF_k(t) \end{cases} \quad (9)$$

$x(t)$  被分解成  $k$  个 PF 分量和一个残余分量  $u_k(t)$  之和, 即:

$$x(t) = \sum_{p=1}^k PF_p(t) + u_k(t) \quad (10)$$

式中:  $PF_p$  表示第  $p$  个 PF 分量,  $u_k$  表示余项。

在特征提取部分, 计算 PF 的能量作为特征向量, 本文将 LMD 多尺度熵和 LMD 能量特征作比较, 则计算各 PF 的能量, 能量定义如下:

$$E_p = \sum_{j=1}^{N_j} |PF_j^p|^2, p = 1, 2, 3, \dots, k \quad (11)$$

式中:  $p$  表示分量的个数,  $PF_j^p$  表示第  $p$  个 PF 分量的第  $j$  个数据点。

### 2.2 多尺度熵(MSE)

MSE 的实质是在不同尺度因子下计算样本熵

(SampEn), 计算步骤如下<sup>[16]</sup>。

设原始数据长度为  $X = \{x_1, x_2, \dots, x_N\}$ , 预先给定相似容量  $r$  和嵌入维数  $m$ 。

1) 对  $X$  进行粗粒化处理, 从而建立新的粗粒化向量:

$$y_j(\tau) = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i \quad 1 \leq j \leq N \quad (12)$$

式中:  $\tau = 1, 2, \dots$  是正整数, 称为尺度因子,  $y_j(\tau)$  为粗粒化向量。

2) 求  $N$  个粗粒化向量的样本熵, 计算方法如下:

(1) 由在尺度  $\tau$  下的粗粒化序列组成  $m$  维数矢量

$$Y(i) = [y_i(\tau), y_{i+1}(\tau), \dots, y_{i+m-1}(\tau)] \quad (13)$$

式中:  $i = 1, 2, \dots, M - m$ 。

(2) 将向量  $Y(i)$  与  $Y(j)$  两者对应元素中最大差值的绝对值定义为距离:

$$d(i, j) = \max_{k=0, 1, \dots, m-1} \{|y_{i+k}(\tau) - y_{j+k}(\tau)|\} \quad (14)$$

(3) 给定阈值  $r$ , 统计  $d(i, j) < r$  的数目及此数目与离总数  $M - m - 1$  的比值, 记作  $B_i^m(r)$ :

$$B_i^m(r) = \frac{[d(i, j) < r]}{N - m - 1} \quad (15)$$

式中:  $1 \leq j \leq N - m, j \neq i$ , 当重构  $m$  维数据时, 求样本的平均值相似度:

$$B^m(r) = \frac{1}{N - m} \sum_{i=1}^{N-m} B_i^m(r) \quad (16)$$

(4) 当重构数据为  $m + 1$  时, 重复式(13) ~ (16) 得到  $B_i^{m+1}(r)$ , 进一步得到  $B^{m+1}(r)$ , 则定义原始序列的样本熵为:

$$SampEn(m, r) = \lim_{N \rightarrow \infty} [-\ln \frac{B_{m+1}(r)}{B_m(r)}] \quad (17)$$

当  $N$  为有限数时, 式(17)可表示为:

$$SampEn(m, r, N) = -\ln \frac{B_{m+1}(r)}{B_m(r)} \quad (18)$$

3) 将样本熵作为尺度因子的函数, 则可得  $MSE$ , 即

$$MSE(x, \tau, m, r) = SampEn(y^\tau, m, r) \quad (19)$$

### 3 极限学习机

极限学习机是一种单隐层前馈神经网络 SLFNs 学习算法, 相对于传统神经网络具有学习速度快, 泛化性能好的优点。该算法只需设置网络的隐层节点个数, 无需调整网络的输入权值以及隐含层神经元的偏置而无需调整权值, 便可以得到唯一的最优解。

给定任意  $Q$  个不同样本  $(x_i, t_i)$ , 其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$  为输入样本,  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}] \in R^m$  为输出样本, 设隐含层有  $l$  个神经元, 激励函数为  $g(x)$ , 则输出可表示为:

$$T = [t_1, t_2, \dots, t_Q]_{m \times Q}, \quad t_j = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} =$$

$$\begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(\omega_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(\omega_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(\omega_i x_j + b_i) \end{bmatrix} \quad j = 1, 2, \dots, Q \quad (20)$$

其中  $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]$  为输入层与隐含层的连接权值;  $b_i = [b_1, b_2, \dots, b_l]^T$  为隐含层神经元阈值,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]$  是隐含层和输出层的连接权值; 求解以下方程组得到最小二乘解:

$$\min \|H\beta - T'\| \quad (21)$$

其解为  $\hat{\beta} = H^+ T'$ 。其中,  $H^+$  为  $H$  的 Moore-Penrose 广义逆矩阵。其中式(21)可以表示为:

$$H\beta = T' \quad (22)$$

其中  $T'$  是矩阵  $T$  的转置,  $H$  为隐含层输出矩阵, 如下所示:

$$H(\omega_1, \omega_2, \dots, \omega_l, b_1, b_2, \dots, b_l, x_1, x_2, \dots, x_Q) = \begin{bmatrix} g(\omega_1 \cdot x_1 + b_1) g(\omega_2 \cdot x_1 + b_2) g(\omega_l \cdot x_1 + b_l) \\ g(\omega_1 \cdot x_2 + b_1) g(\omega_2 \cdot x_2 + b_2) g(\omega_l \cdot x_2 + b_l) \\ \vdots \\ g(\omega_1 \cdot x_Q + b_1) g(\omega_2 \cdot x_Q + b_2) g(\omega_l \cdot x_Q + b_l) \end{bmatrix}_{Q \times l} \quad (23)$$

当训练样本个数等于隐含层神经元个数时, 对任何的  $\omega$  和  $b$ , SLFN 都能零误差逼近训练样本, 即:

$$\sum_{j=1}^Q \|t_j - y_j\| = 0 \quad (24)$$

其中,  $y_j = [y_{1j}, y_{2j}, \dots, y_{mj}]^T, j = 1, 2, \dots, Q$ 。

当训练集样本个数  $Q$  较大时, 隐含层神经元个数通常取比  $Q$  小的数, SLFN 的训练误差可以任意逼近一个  $\varepsilon > 0$  的数, 即:

$$\sum_{j=1}^Q \|t_j - y_j\| < \varepsilon \quad (25)$$

综合以上, ELM 的学习算法如下:

1) 确定隐含层神经元的数量, 随机设置输入层神经元和隐含层神经元间的连接权值  $\omega$  和隐含层神经元的偏置  $b$ ;

2) 选取适当的函数作为隐含层神经元的激活函数, 并计算出隐含层的输出矩阵  $H$ ;

3) 计算输出层权值  $\hat{\beta} = H^+ T'$ 。

## 4 LMD 多尺度熵和 ELM 故障诊断流程

本文运用 LMD 多尺度熵对样本进行故障特征提取,将形成的特征矩阵输入到极限学习机中进行训练和测试,具体诊断流程如图 1 所示。




图 1 故障诊断流程

Fig. 1 Flow chart of fault diagnosis

故障诊断步骤如下:

- 1) 对电路进行灵敏度分析,设置灵敏度高的元件为故障元件,并设置故障模式,选择测试节点,运用 Pspice 软件对电路进行 MonteCarlo 分析;
- 2) 对样本进行 LMD 分解,获得分解后的多个  $PF$  分量;

- 3) 求各  $PF$  分量的多尺度熵,并形成故障特征矩阵;
- 4) 选择合适的激活函数和隐含层神经元个数建立极限学习机网络,将形成的故障特征矩阵输入极限学习机进行训练和测试,并得到诊断结果。

## 5 诊断实例

### 5.1 诊断电路

以图 2 所示的带通滤波器为诊断电路,选取 3 个不同幅值和频率的正弦信号源  $V1$  ( $PHASE = 0^\circ$ ),  $V2$  ( $PHASE = 90^\circ$ ),  $V3$  ( $PHASE = 90^\circ$ ),其余各元件参数如图 2 所示,电路中的电阻的容差为 5%,电容的容差为 10%,经灵敏度分析可知  $R_2, R_3, C_1, C_2$  对电路影响较大,因此选取它们为故障元件,假设电路中的元件仅可能发生单故障,设故障元件的故障值为  $X \pm 50\% X$ ,其中  $X$  为元件的标称值,被测电路一共有 8 种故障状态,加上正常状态(NF)共有 9 种状态模式。故障元件的参数如表 1 所示。

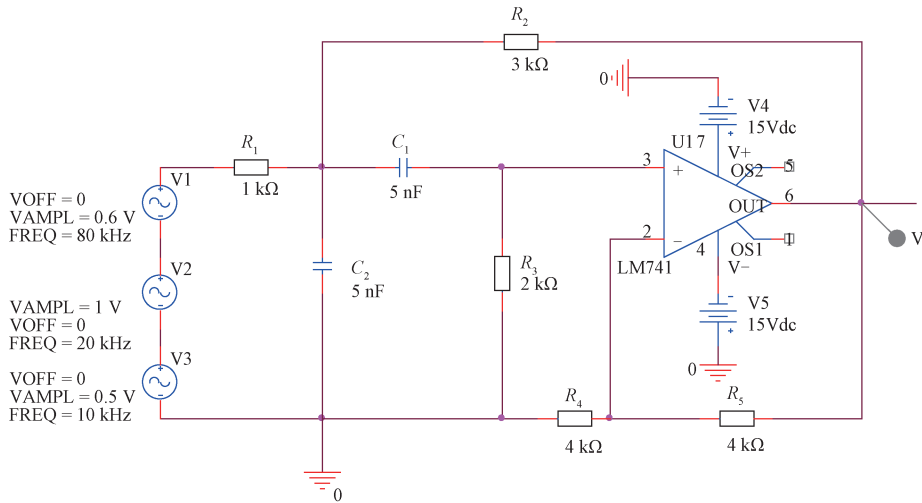


图 2 带通滤波器电路

Fig. 2 Band-pass filter circuit

表 1 故障类型及编码  
Table 1 Fault types and codes

故障类别	故障代码	故障模式	正常值	故障值
1	F1	NF	—	—
2	F2	$R_2 \uparrow$	3k	4.5k
3	F3	$R_2 \downarrow$	3k	1.5k
4	F4	$R_4 \uparrow$	4k	6k
5	F5	$R_4 \downarrow$	4k	2k
6	F6	$C_1 \uparrow$	5nF	7.5nF
7	F7	$C_1 \downarrow$	5nF	2.5nF
8	F8	$C_2 \uparrow$	5nF	7.5nF
9	F9	$C_2 \downarrow$	5nF	2.5nF

用 Pspice 仿真软件对待测电路进行瞬态分析,设采样频率为 1 MHz,对 9 种故障模式分别进行 50 次蒙特卡罗分析,形成 450 个样本,随机选取 270 个进行训练,180 个进行测试。

### 5.2 特征提取

对样本进行 LMD 分解,正常状态和  $C1-50\%$  状态下的分解结果如图 3 和 4 所示,LMD 将原始信号分解为 3 个  $PF$  分量, $PF_1, PF_2, PF_3$  和一个残余分量  $R$ ,由图 3 和 4 可以看出不同故障状态的 LMD 分解结果有一定的差异。

由于主要故障信息主要集中在前几个  $PF$  分量,为




图 3 正常信号的 LMD 分解结果

Fig. 3 LMD decomposition results of normal signal




图 4 C1-50% 状态下的 LMD 分解结果

Fig. 4 LMD decomposition results under C1-50% condition

避免多尺度特征向量的数据过于冗长,因此本文选取前 3 个  $PF$  分量分别求它们的多尺度熵。多尺度熵与尺度因子  $\tau$ , 相似容量  $r$ , 嵌入维数  $m$  有关,通常取  $r$  的值为  $0.1SD \sim 0.5SD$  ( $SD$  是原始数据的标准差),本文取  $r = 0.2SD, m = 2$ , 选取尺度因子分别 10、15、20, 因此经过 LMD 分解,并求出  $PF$  分量的多尺度熵后,形成特征向量  $[MSE_{PF1(10)}, MSE_{PF1(15)}, MSE_{PF1(20)}, MSE_{PF2(10)}, MSE_{PF2(15)}, MSE_{PF2(20)}, MSE_{PF3(10)}, MSE_{PF3(15)}, MSE_{PF3(20)}]$ 。对 9 种电路状态模式进行处理,得到多尺度熵,取任意一组数据如表 2~4 所示。

作为对比,求样本 LMD 分解后各  $PF$  分量的能量,将  $PF$  分量的能量特征作为特征向量,由于  $PF$  分量构成的特征向量维数较少且残余分量也存在一定的故障信息,因此也将残余分量作为特征向量的一部分。同样对 9 种电路状态模式进行处理,得到 LMD 能量,如表 5 所示。

表 2  $PF_1$  的多尺度熵

Table 2 The multi-scale entropy of  $PF_1$

	$MSE_{PF1(10)}$	$MSE_{PF1(15)}$	$MSE_{PF1(20)}$
F1	0.371 6	0.487 4	0.298 7
F2	0.548 9	0.466 8	0.199 5
F3	0.249 1	0.285 6	0.485 7
F4	0.547 9	0.596 7	0.445 7
F5	0.286 5	0.269 3	0.337 1
F6	0.374 2	0.361 7	0.348 9
F7	0.011 9	0.241 0	0.615 0
F8	0.935 7	0.691 5	0.544 5
F9	0.337 2	0.350 8	0.104 3

表 3  $PF_2$  的多尺度熵

Table 3 The multi-scale entropy of  $PF_2$

	$MSE_{PF2(10)}$	$MSE_{PF2(15)}$	$MSE_{PF2(20)}$
F1	-0.071 9	-0.508 9	1.379 6
F2	0.046 4	2.196 5	0.064 2
F3	0.015 0	0.020 8	0.028 3
F4	0.203 8	0.371 0	1.456 9
F5	0.074 8	-0.283 0	0.376 2
F6	0.469 3	1.365 6	0.324 0
F7	0.014 6	0.037 5	0.027 7
F8	-0.509 4	0.483 2	-0.322 3
F9	0.051 6	0.352 5	0.882 7

表 4  $PF_3$  的多尺度熵

Table 4 The multi-scale entropy of  $PF_3$

	$MSE_{PF3(10)}$	$MSE_{PF3(15)}$	$MSE_{PF3(20)}$
F1	0.254 4	0.226 0	0.179 4
F2	0.258 9	0.210 1	0.162 8
F3	0.332 6	0.126 9	0.054 2
F4	0.256 2	0.228 7	0.127 3
F5	0.285 0	0.189 0	0.107 0
F6	0.248 8	0.242 2	0.043 3
F7	0.364 5	0.208 6	0.085 8
F8	0.252 0	0.188 6	0.199 7
F9	0.289 8	0.228 0	0.179 3

表 5 9 种电路状态的能量特

Table 5 Energy characteristics of 9 circuit states

	$E(PF_1)$	$E(PF_2)$	$E(PF_3)$	$E(R)$
F1	144.990 8	963.648 9	32.932 0	1.989 1
F2	141.770 2	905.335 0	34.712 9	2.635 5
F3	143.700 0	1 190.20 0	30.700 0	3.700 0
F4	165.600 0	1 582.30 0	62.600 0	4.700 0
F5	96.9193 0	305.386 3	9.223 80	0.777 7
F6	141.000 0	1 290.700	58.800 0	6 043.8
F7	120.462 7	391.884 6	10.562 8	0.950 3
F8	86.3377 0	813.379 9	27.791 0	4.960 9
F9	363.400 0	1 160.700	37.800 0	2.700 0

### 5.3 仿真结果分析

采用极限学习机分别对 LMD 多尺度熵故障特征和 LMD 能量故障特征进行分类,随机抽取 270 个样本进行训练,180 个样本进行测试,测试结果如图 5、6 所示。当实际输出与期望输出重合时,说明分类正确。




图5 LMD 能量特征诊断结果

Fig. 5 The diagnosis result of LMD energy characteristic




图6 LMD 多尺度熵诊断结果

Fig. 6 The diagnosis result of LMD multi-scale entropy

由图 5 和 6 对比可知,LMD 能量特征(图 5)和 LMD 多尺度熵(图 6)都能表征电路的故障特征,但基于 LMD 多尺度熵的 ELM 分类效果比 LMD 能量特征的 ELM 分类效果要好,说明 LMD 多尺度熵更适合模拟电路故障特征的提取。作为对比,本文同时用 BP 神经网络进行分类,具体性能对比参数如表 6 所示。

由表 6 可知基于 LMD 多尺度熵的特征提取比基于 LMD 能量特征的诊断精度要高,而采用极限学习机进行分类比 BP 神经网络分类所需的时间要少,说明 LMD 多尺度熵和极限学习机结合是可行的且有较好的诊断性能。

表 6 带通滤波器单故障分类时 4 种方法的性能比较

Table 6 The performance comparison of four methods in single fault classification of band-pass filter

方法	诊断时间/s	诊断精度/%
LMD 能量特征(BP)	2.171072	92.22
LMD 能量特征(ELM)	0.023579	93.33
LMD 多尺度熵(BP)	1.519340	97.78
LMD 多尺度熵(ELM)	0.028874	98.89

## 6 结论

本文结合 LMD 分解、多尺度熵、极限学习机各自的优势,提出一种基于 LMD 多尺度熵和极限学习机的模拟电路故障诊断新方法,以带通滤波器为例对本文提出的方法进行了验证,并和 LMD 能量特征提取方法和 BP 神经网络的方法进行比较,结果表明本文提出的方法具有较高的诊断精度和较少的诊断时间。

## 参考文献

[ 1 ] 胡梅,樊敏. 一种模拟电路功能模块故障诊断的方法[J]. 电子测量与仪器学报,2015,29(5):676-685.  
HU M, FAN M. A method of function module fault diagnosis of analog circuit [ J ]. Journal of Electronic Measurement and Instrumentation, 2015, 29 ( 5 ): 676-685.

[ 2 ] 马翔楠,徐正国,王文海,等. 模拟电路性能退化型故障诊断方法研究[J]. 电子测量与仪器学报,2013,27(1):32-37.  
MA X N, XU ZH G, WANG W H, et al. Research on degraded fault diagnosis method for analog circuit [ J ]. Journal of Electronic Measurement and Instrumentation, 2013, 27 ( 1 ): 32-37.

[ 3 ] 余发山,康洪. 基于 GA 优化 BP 神经网络的液压钻机故障诊断[J]. 电子测量技术,2016,39(2):134-137.  
YU F SH, KANG H. Faultdiagnosis of hydraulic drilling rig based on Genetic algorithm optimized BP neural network [ J ]. Electronic Measurement Technology, 2016, 39 ( 2 ): 134-137.

[ 4 ] 孙萍萍. 基于小波包理论的激波信号去噪研究[J]. 国外电子测量技术,2016,35(7):38-42.  
SUN P P. Denoising of shock signal based on wavelet packet theory [ J ]. Foreign Electronic Measurement Technology, 2016, 35 ( 7 ): 38- 42.

[ 5 ] 徐湛. 基于稀疏小波变换的超宽带低信噪比信号检测算法[J]. 仪器仪表学报,2013,34(4):825-830.  
XU ZH. Detection algorithm for low SNR signal in UWB systembased on sparse wavelet transform [ J ]. Chinese Journal of Scientific Instrument, 2013, 34 ( 4 ): 825-830.

- [ 6 ] 何星,王宏力,陆敬辉,等. 基于优选小波包和 ELM 的模拟电路故障诊断 [ J ]. 仪器仪表学报, 2013, 34(11):2614-2618.  
HE X, WANG H L, LU J H, et al. Analog circuit fault diagnosis method based on preferred wavelet packet and ELM [ J ]. Chinese Journal of Scientific Instrument, 2013, 34(11):2614-2618.
- [ 7 ] SMITH J S. The local mean decomposition and its application to EEG perception data [ J ]. Journal of the Royal Society Interface, 2005, 2(5):443-454.
- [ 8 ] 石瑞敏,杨兆建. 基于 LMD 能量特征的滚动轴承故障诊断方法 [ J ]. 振动、测试与诊断, 2015, 35(5):832-836.  
SHI R M, YANG ZH J. Rolling bearing fault diagnosis method based on LMD energy characteristics [ J ]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(5):832-836.
- [ 9 ] 张龙,张磊,熊国良,等. 基于多尺度熵和神经网络的滚动轴承故障诊断 [ J ]. 机械设计与研究, 2014, 30(5):96-105.  
ZHANG L, ZHANG L, XIONG G L, et al. Rolling bearing diagnosis based on multiscale entropy and neural network [ J ]. Machine Design and Research, 2014, 30(5):96-105.
- [ 10 ] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy [ J ]. American Journal of Physiology-Heart Circulatory Physiology, 2000, 278(6):2039-2049.
- [ 11 ] COSTA M, GOLDBERGER A L, PENG C K. Multiscale entropy analysis of complex physiologic, time, series [ J ]. Physical Review Letters, 2002, 89(6):1-8.
- [ 12 ] 孟宗,胡猛,谷伟明,等. 基于 LMD 多尺度熵和概率神经网络的滚动轴承故障诊断方法 [ J ]. 中国机械工程, 2016, 27(4):433-437.  
MENG Z, HU M, GU W M, et al. Rolling bearing fault diagnosis method based on LMD multi-scale entropy and probabilistic neural network [ J ]. Chinese Journal of Mechanical Engineering, 2016, 27(4):433-437.
- [ 13 ] 陈绍炜,吴敏华,赵帅. 基于 PCA 和 ELM 的模拟电路故障诊断 [ J ]. 计算机工程与应用, 2015, 51(11):248-251.  
CHEN SH W, WU M H, ZHAO SH. Analog circuit fault diagnosis based on PCA and ELM. Computer Engineering and Applications, 2015, 51(11):248-251.
- [ 14 ] 高坤,何怡刚,薄祥雷,等. 基于共空间模式和超限学习机的模拟电路故障诊断 [ J ]. 仪器仪表学报, 2015, 36(1):126-133.

GAO K, HE Y G, FU X L, et al. Analog circuit fault diagnosis based on common spatial patterns and extreme learning machine [ J ]. Chinese Journal of Scientific Instrument, 2015, 36(1):126-133.

- [ 15 ] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and application [ J ]. Neurocomputing, 2006, 70:489-501.

- [ 16 ] 张龙,张磊,熊国良,等. 基于多尺度熵的滚动轴承 Elman 神经网络故障诊断方法 [ J ]. 机械科学与技术, 2014, 3(12):1854-1858.

ZHANG L, ZHANG L, XIONG G L, et al. Rolling bearing diagnosis based on multi-scale entropy and Elman neural network [ J ]. Mechanical Science and Technology for Aerospace Engineering, 2014, 3(12):1854-1858.

## 作者简介



刘美容, 1977 年出生, 博士, 湖南师范大学讲师, 研究方向为信号处理、电路故障诊断。

E-mail: liumr12@aliyun.com

**Liu Meirong** was born in 1977, Ph. D., and lecturer in Hunan Normal University. Her

primary research interests include signal processing and circuit fault diagnosis.



曾黎, 1991 年出生, 硕士研究生, 研究方向为电路故障诊断。

E-mail: 1908039655@qq.com


**Zeng Li** was born in 1991, M. Sc. candidate. Her primary research interest is circuit fault diagnosis.



何怡刚, 1966 年出生, 博导、教授, 研究方向极大规模集成电路设计测试与诊断、自动(射频)识别技术、信号处理等。

E-mail: 18655136887@163.com

**He Yigang** was born in 1966, professor and supervisor for Ph. D. His primary research interests include great scale integrated circuit design test and diagnosis, automatic (radio frequency) identification technology and signal processing.



李向新, 1982 年出生, 硕士、工程师, 研究方向为智能电网与继电保护新技术。

**Li Xiangxin** was born in 1982, M. Sc., engineer. His primary research interests include smart grid and relay protection.