

DOI: 10.13382/j.jemi.2017.12.013

基于连续小波奇异熵的模拟电路故障诊断新方法*

何 威¹ 何怡刚¹ 罗旗舞¹ 李志刚¹ 邓芳明¹ 张朝龙^{1,2}

(1. 合肥工业大学 电气与自动化工程学院 合肥 230009;

2. 安庆师范大学 物理与电气工程学院 安庆 246011)

摘要:针对模拟电路的故障诊断和定位问题,为进一步提高故障诊断准确率,提出了一种基于连续小波 Tsallis 奇异熵和超限学习机的故障诊断方法。首先应用连续小波变换计算被测电路时域响应信号的时频系数矩阵,然后将其分割为 8 个相同大小的子矩阵,分别计算每个子矩阵的 Tsallis 奇异熵,组成特征向量,最后将特征应用于超限学习机多类分类器进行区分。仿真结果表明,故障诊断方法能较好地获取故障响应信号的本质特征,并具有较其他现存方法更高的故障诊断正确率。

关键词:模拟电路;故障诊断;连续小波变换;Tsallis 奇异熵;超限学习机

中图分类号: TN407 文献标识码: A 国家标准学科分类代码: 510

Novel approach for analog circuit fault diagnosis based on continuous wavelet singularity entropy

He Wei¹ He Yigang¹ Luo Qiwu¹ Li Zhigang¹ Deng Fangming¹ Zhang Chaolong^{1,2}

(1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China;

2. School of Physics and Electrical Engineering, Anqing Normal University, Anqing 246011, China)

Abstract: Aiming at the issue of analog circuit fault diagnosis and location, a novel approach for analog circuit fault diagnosis based on continuous wavelet Tsallis singularity entropy (TSE) and extreme learning machine (ELM) is proposed to enhance the accuracy of fault diagnosis. Firstly, the fault response signals are preprocessed by the continuous wavelet transformation to obtain the time-frequency coefficient matrix, and the matrix is divided into 8 congruent time-frequency blocks. Then, the feature vector is obtained by computing TSE of each block. Finally, the feature vectors are used as the inputs of a kind of multiclass classifier, namely ELM. The simulation results demonstrate that the proposed fault diagnosis approach can not only extract the essential features of fault response signals with better performance, and also achieve higher diagnosis accuracy than other reported approaches.

Keywords: analog circuit; fault diagnosis; continuous wavelet transformation; Tsallis singularity entropy; extreme learning machine

0 引 言

随着电子技术的发展,模拟电路在电子消费品、军事装备和工业设备等领域中发挥着极其重要的作用。一旦模拟电路出现故障,将会影响电子仪器的可靠性与稳定性,并可能导致灾难性后果。因此,设计出高准确性、强实时性的模拟电路故障诊断方法正成为学界研究热点与难点之一^[1-3]。

20 世纪 90 年代以来,随着人工智能技术的发展。神经网络^[4-5]、支持向量机(SVM)^[6]、信息融合^[7]和小波分析^[8]等方法逐步应用到模拟电路故障诊断中,并取得了较好的效果。基于人工智能技术的模拟电路故障诊断一般包括两个步骤:故障特征提取与分类器的构造。小波变换由于其良好的时频特性,被广泛应用于故障诊断中。文献[9-10]提出采用小波包分析方法分解故障信号,获得子带序列,通过计算各节点的归一化能量值组成

收稿日期:2017-03 Received Date: 2017-03

* 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)、重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)资助

电路故障特征。但是,由于小波分解的子带之间存在频谱混叠现象,简单依靠上述方法不能有效提取故障特征,且计算量偏大。因此,近年来,许多学者通过将信息熵理论引入小波分解中用于故障特征提取,以期解决上述问题。文献[11]将 haar 小波和信息熵结合起来用于开关电路故障诊断;文献[12]通过采用小波包分解和样本熵提取滚动轴承故障特征;均取得了一定的效果。

人工神经网络是故障诊断领域中较为常用的分类器,但是人工神经网络存在网络训练速度慢、容易陷入局部最优优点及过拟合等问题^[13]。基于统计学习理论的 SVM 对小样本和非线性问题适应能力强,同时泛化性能较好,但是需要人为设定核函数及核参数,限制了其应用^[14]。超限学习机(extreme learning machine, ELM)作为一种新兴的神经网络,是在单隐层前馈神经网络(single-hidden layer feed forward networks, SLFNs)的基础上,通过设置合适的网络结构参数,直接利用 Moore-Penrose 广义逆求出网络输出权值。相对于传统神经网络,ELM 学习能力强、处理速度迅速,同时具有待定参数少、效率高等优点^[10,15]。

由于连续小波的尺度具有连续变化的特点,其能够较为细致的描述信号的细节特征,采用连续小波对信号进行处理,可获得能够准确表征故障特征的时频分布图^[16-17]。同时, Tsallis 信息熵作为一种非广延熵,能较好的应对小波分解中存在的能量泄露和频率混叠^[18-19]。鉴于此,本文提出一种基于连续小波时频分析, Tsallis 熵和超限学习机的模拟电路故障诊断方法。该方法首先提取模拟电路的时域响应信号,经连续小波分析后得到信号的时频特征,并通过 Tsallis 熵生成样本数据,然后应用超限学习机进行故障识别。

1 基于连续小波熵的分析方法

1.1 连续小波变换

设 $x(t)$ 是待处理信号,则连续小波变换定义为:

$$W_x(\tau, a) = \sqrt{a} \int_{-\infty}^{+\infty} x(t) \varphi(a(t - \tau)) dt = \langle x, \varphi_{\tau, a} \rangle \quad (1)$$

式中: $W_x(\tau, a)$ 为小波变换时频系数矩阵; τ 为时间参数; a 为频率参数, $a > 0$; $\varphi(t)$ 为小波函数; $\varphi_{\tau, a}(t)$ 为小波基函数。

连续小波变换通过对信号进行时间和尺度上操作,将其衍射到时间-尺度平面上,从而获得信号的连续小波系数矩阵。系数矩阵 $W_x(\tau, a)$ 刻画了信号与小波基函数之间的相似度。系数越大,表明信号该处细节部分与小波基函数越相似。

1.2 Tsallis 熵—Shannon 熵延拓

Shannon 熵于 1948 年由香农提出,用以对信息进行

度量。Shannon 熵属于 B-G 熵,具有广延性。对任意两个独立的子系统 A 和 B ,具有以下可加性:

$$\frac{S_s(A+B)}{k} = \frac{S_s(A)}{k} + \frac{S_s(B)}{k} \quad (3)$$

然而,在现实环境中,有相当一部分被测系统不具有上述可加性,即为非广延性系统。

Tsallis 熵是建立在 B-G 熵基础上的泛化非广延熵,能够较好的刻画非广延性系统的物理特性。

Tsallis 熵的离散表达式如下:

$$S_q^{(d)} = \frac{k}{q-1} \left(1 - \sum_{i=1}^n p(i)^q \right), \quad q \in \mathbb{R} \quad (4)$$

相较于 Shannon 熵,通过引入非广延参数 q , Tsallis 熵使系统熵满足如下的赝可加性:

$$\frac{S_q(A+B)}{k} = \frac{S_q(A)}{k} + \frac{S_q(B)}{k} + (1-q) \frac{S_q(A)S_q(B)}{k^2} \quad (5)$$

根据被测系统的特性,通过选择恰当的 q 值, Tsallis 熵可以更加准确的度量系统内在信息,相比于 Shannon 熵更加灵活。

1.3 连续小波奇异熵特征

设被测信号的连续小波变换后生成的系数矩阵为 $D_{m \times n}$,根据矩阵奇异值分解理论,将 $D_{m \times n}$ 分解为:

$$D_{m \times n} = U_{m \times l} A_{l \times l} V_{l \times n} \quad (6)$$

式中: 对角线矩阵 A 的主对角线元素 $\lambda_i (i = 1, 2, \dots, l)$ 是 $D_{m \times n}$ 的奇异值且 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l \geq 0$ 。当电路发生故障时,其信号的连续小波变换矩阵所含的特征成分就会随着相应改变,对应的非零奇异值的多寡及大小也会有所变换。为了量化这一变化,本文提出 Tsallis 奇异熵(tsallis singular entropy, TSE),其表达式为:

$$W_{TSE} = \frac{1}{q-1} \left(1 - \sum_{i=1}^n \Delta P_i^q \right), \quad q \in \mathbb{R} \quad (7)$$

式中: $\Delta P_i = - \left(\frac{\lambda_i}{\sum_{j=1}^l \lambda_j} \right) \log \left(\frac{\lambda_i}{\sum_{j=1}^l \lambda_j} \right)$, q 为广延参数。

本文取 $c = 1$, $q = 1.2$ 。

为了更为细致的刻画矩阵 $D_{m \times n}$ 的局部微小变化,本文在计算特征 Tsallis 熵前,先对 $D_{m \times n}$ 进行 8 等份:

$$D_{m \times n} = \begin{bmatrix} (B_1)_{\frac{m}{8} \times \frac{n}{8}} & (B_2)_{\frac{m}{8} \times \frac{n}{8}} & (B_3)_{\frac{m}{8} \times \frac{n}{8}} & (B_4)_{\frac{m}{8} \times \frac{n}{8}} \\ (B_5)_{\frac{m}{8} \times \frac{n}{8}} & (B_6)_{\frac{m}{8} \times \frac{n}{8}} & (B_7)_{\frac{m}{8} \times \frac{n}{8}} & (B_8)_{\frac{m}{8} \times \frac{n}{8}} \end{bmatrix} \quad (8)$$

按照式(8)得到 8 个子矩阵 $B_1, B_2, B_3, B_4, B_5, B_6, B_7, B_8$,然后分别对子矩阵计算 Tsallis 奇异熵,从而生成 8 维故障特征向量,作为分类器输入向量。

2 超限学习机

超限学习机是在单隐层前馈神经网络技术上发展而

来的全新神经网络。相对于传统的神经网络,单隐层前馈神经网络学习速度更快,网络结构更加简单,因而得到了广泛的应用。通过研究表明,只要激励函数 $g(x)$ 在任意实数间上可微,可通过简单的正则化计算得出网络输出权值,同时无需对网络 w_i 和 b_i 进行调整。单隐层神经网络结构如图 1 所示。

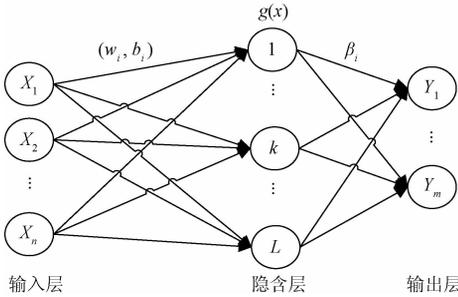


图 1 单隐层前馈神经网络结构

Fig. 1 The Structure of single-hidden layer forward neural network

对于 N 个任意的各个不同的样本 (x_i, y_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R^m$, 则一个基于前馈单隐层神经网络的超限学习机的模型可以统一表示为:

$$f_L(x) = \sum_{i=1}^L \beta_i g(x)(w_i \cdot x_i + b_i) \quad (9)$$

式中: L 为网络的隐含层节点数, $g(x)$ 为网络的激活函数。其中 $x_i \in R^n, w_i \in R^n, \beta_i \in R^m, w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 是输入层到第 i 个隐含层节点的输入权值; b_i 是第 i 个隐含层节点的偏差; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 是隐含层节点与输出层节点之间的输出权值。

若该前馈神经网络能以零误差逼近这 N 个样本, 则存在 w_i, b_i, β_i , 使式 (10) 成立:

$$f_L(x) = \sum_{i=1}^L \beta_i g(x)(w_i \cdot x_i + b_i) = y_i \quad (10)$$

式 (10) 可以简写为 $H\beta = Y$, 式中:

$$H(w_1, \dots, w_L; b_1, \dots, b_L; x_1, \dots, x_N) = \begin{bmatrix} g(a_1 \cdot x_1 + b_1) & \dots & g(a_L \cdot x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(a_1 \cdot x_N + b_1) & \dots & g(a_L \cdot x_N + b_L) \end{bmatrix}_{N \times L}$$

$$Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_L^T \end{bmatrix}_{N \times M}$$

H 表示超限学习机的隐含层输出矩阵, 从而输出权值矩阵能够由下式获取:

$$\tilde{\beta} = H^+ Y \quad (11)$$

式中: H^+ 为 H 的 Moore-Penrose 广义逆矩阵。可以采用正交投影法、正交法、迭代法和奇异值分解等方法计算矩阵的广义逆。

3 故障诊断流程

图 2 所示为本文所提出的基于连续小波变换和 Tsallis 奇异熵的超限学习机诊断流程。首先给电路施加激励信号, 然后在输出端采集故障响应信号; 将得到的故障响应信号进行连续小波变换, 得到连续小波时频系数矩阵, 求其矩阵分解后 8 个子矩阵的 Tsallis 奇异熵, 将其作为故障特征向量, 最后将这些故障特征值输入到超限学习机中, 用于建立基于 ELM 的多分类模型, 识别不同的电路故障类别。



图 2 故障诊断流程

Fig. 2 Flow chart of fault diagnosis

4 仿真实验

4.1 诊断电路故障设置

图 3 所示的四运放双二阶高通滤波器为测试电路。各元件的标称值均于图上标出。本文选用持续时间

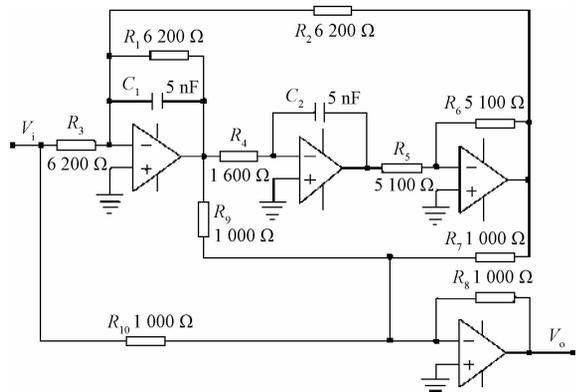


图 3 四运放双二阶高通滤波器

Fig. 3 Four opamp biquad high-pass filter

10 μs ,幅值为 10 V 的脉冲波为电路激励信号。电路元件的容差范围设置为 5 %。选择 R_1 、 R_2 、 R_3 、 R_4 、 C_1 和 C_2 作为测试对象,表 1 给出了电路中各测试元件的故障码,故障类别,标称值和故障值。

表 1 高通滤波器中各元件故障码、故障类别、标称值和早期故障值

Table 1 Fault code, fault class, nominal value and fault value of each component for high-pass filter

故障码	故障类别	标称值	故障值
F0	NF	-	-
F1	$R_1 \downarrow$	6 200 Ω	3 000 Ω
F2	$R_1 \uparrow$	6 200 Ω	15 000 Ω
F3	$R_2 \downarrow$	6 200 Ω	2 000 Ω
F4	$R_2 \uparrow$	6 200 Ω	18 000 Ω
F5	$R_3 \downarrow$	6 200 Ω	2 700 Ω
F6	$R_3 \uparrow$	6 200 Ω	12 000 Ω
F7	$R_4 \downarrow$	1 600 Ω	500 Ω
F8	$R_4 \uparrow$	1 600 Ω	2 500 Ω
F9	$C_1 \downarrow$	5 nF	2.5 nF
F10	$C_1 \uparrow$	5 nF	10 nF
F11	$C_2 \downarrow$	5 nF	1.5 nF
F12	$C_2 \uparrow$	5 nF	15 nF

4.2 基于连续小波的电路故障特征提取

对图 1 所示电路采用 Multisim 软件进行故障仿真。每类故障进行 60 次蒙特卡洛分析,即每类故障采集到 60 个时域故障样本。13 种故障模式一共采集到 780 个时域故障样本。接下来,对采集的所有时域样本进行连续小波变换,分别得到每个样本的连续小波时频系数矩阵。由于文章篇幅限制,仅显示故障 F0、F6、F10 和 F12 的连续小波时频系数矩阵等高线图,如图 4 所示。

从图 4 可以看出,4 个故障模式的时频系数等高线图区别较为明显,同时相比于其他信号处理方法可以直接从时频域上进行观察,从而说明了本文所采用的连续小波变换能很好的凸显不同故障模式之间的区别。

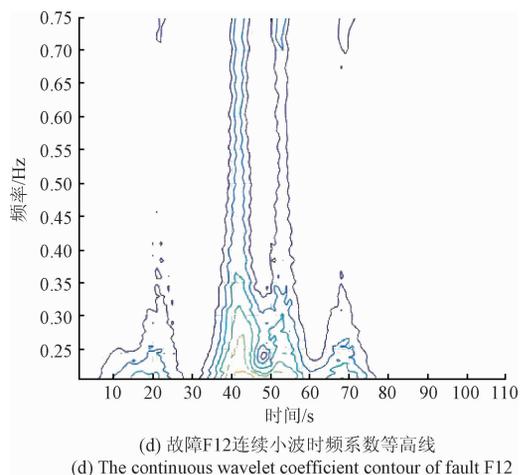
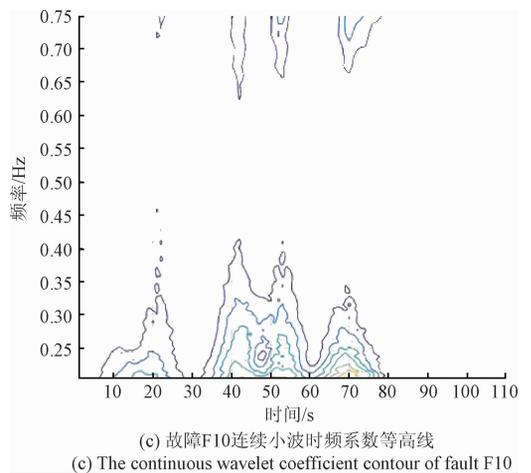
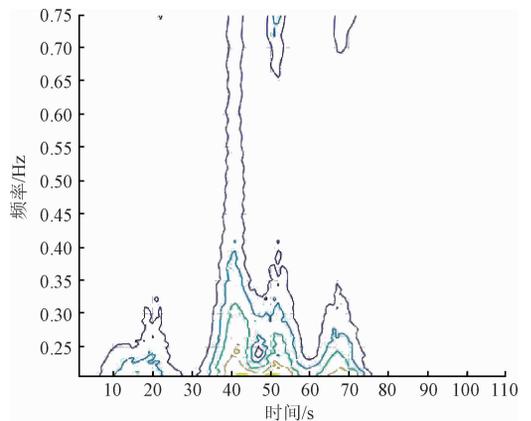
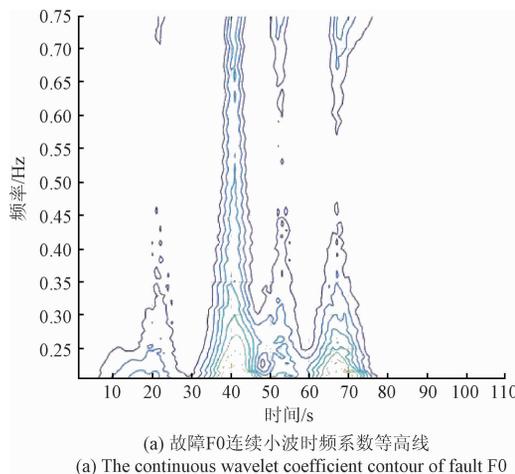


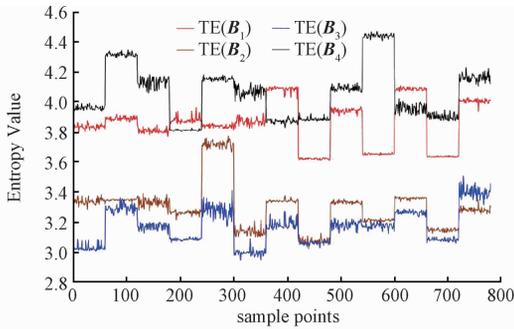
图 4 部分故障连续小波时频系数等高线

Fig. 4 Partial fault continuous wavelet coefficient contours

4.3 Tsallis 熵特征提取

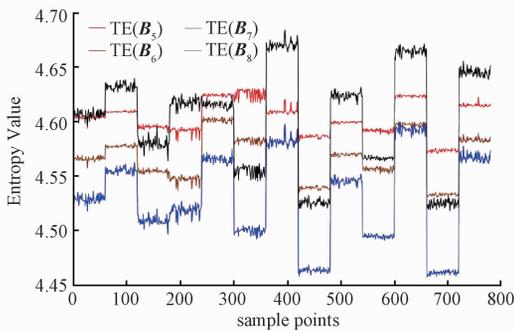
由于连续小波变换系数矩阵维数较高且包含过多的冗余信息,直接输入到分类器中进行识别,必然会导致分类器训练时间过长、准确度降低。因此,本文首先采用分割法将系数矩阵划分为 B_1 、 B_2 、 B_3 、 B_4 、 B_5 、 B_6 、 B_7 和 B_8

等 8 块子矩阵,然后分别计算每块矩阵的 Tsallis 奇异熵,生成 8 维特征向量。测试电路的全部故障信号的 Tsallis 奇异熵曲线如图 5 所示,为更好的区分不同故障类之间的特征,本文将 $TSE(B_1)$, $TSE(B_2)$, $TSE(B_3)$ 和 $TSE(B_4)$ 绘于图 5(a)中; $TSE(B_5)$, $TSE(B_6)$, $TSE(B_7)$ 和 $TSE(B_8)$ 绘于图 5(b)中。同时,为了对比本文所提出特征提取方法的效果,另外采用文献[9-10]中所提出的小波包方法对故障信号进行处理,提取 3 层小波包节点系数能量,并归一化后绘在图 6 中。从图 5 中可以看出,13 个故障模式中大多数故障样本点区别较为明显,仅有少数故障模式的某一特征值接近相等,且所有特征值均在 [2.8,4.7] 范围内,如此为后续的故障诊断提供了一个很好的条件。然而在图 6 中,节点(3,0)和(3,1)的能量值远远大于其他节点,各特征值大小相差太大,明显不适合输入到分类器中诊断。



(a) 全部样本 B_1, B_2, B_3, B_4 子矩阵 Tsallis 奇异熵图

(a) Tsallis singularity entropy chart of block B_1, B_2, B_3, B_4 , for whole samples



(b) 全部样本 B_5, B_6, B_7, B_8 子矩阵 Tsallis 奇异熵图

(b) Tsallis singularity entropy chart of block B_5, B_6, B_7, B_8 , for whole samples

图 5 全部样本的 Tsallis 奇异熵图

Fig. 5 Tsallis singularity entropy of whole sample

4.4 超限学习机故障诊断

采用超限学习机分别对 4.3 节中提取到的奇异熵和能量特征进行分类。对于每类故障,电路的训练集和测试集的大小均设为 30,因此训练集和测试集样本总数均为 390。ELM 的隐藏层节点数设为 50。测试结果如图 7 和 8 所示。

在图 7 中,除 9 个故障样本外,其余的总计 381 个故

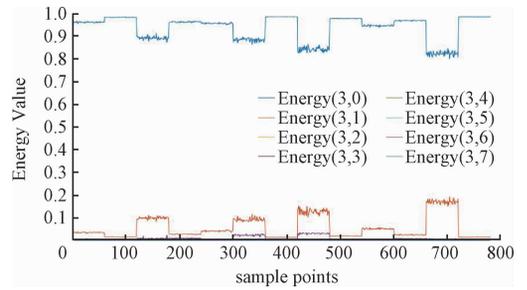


图 6 全部样本的小波包归一化能量谱图

Fig. 6 Wavelet packet normalized energy spectrum of whole sample

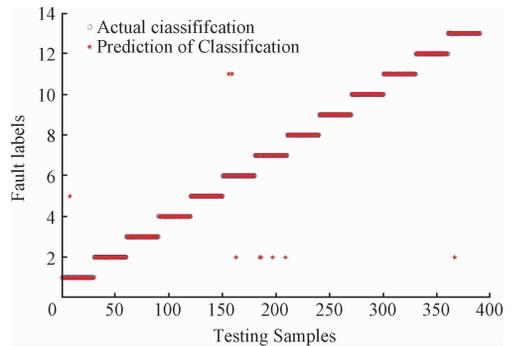


图 7 小波包能量谱诊断结果

Fig. 7 The fault diagnosis results for wavelet packet energy spectrum

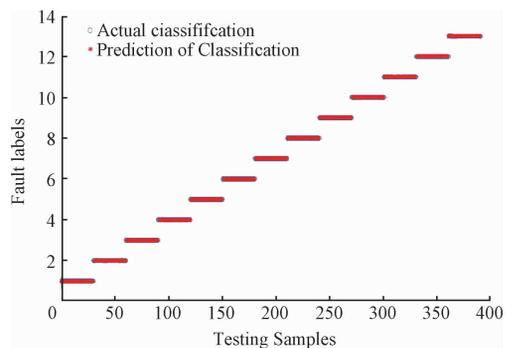


图 8 Tsallis 熵诊断结果

Fig. 8 The diagnosis results for Tsallis entropy

障样本都是可以正确区分,这 9 个故障样本是属于故障类别 F4, F10 和 F1。而造成这部分故障样本不可以正确区分的原因是这 3 类故障的小波包能量谱特征向量相似,ELM 神经网络无法正确识别。采用小波包能量谱作为特征向量的故障诊断率为 97.7%。

在图 8 中,将连续小波变化获取的故障信号的时频系数矩阵分割为 8 块大小相等的子矩阵,计算各子矩阵的 Tsallis 奇异熵得到较为分离的特征信息,从而解决了故障点错判问题。采用 Tsallis 熵作为特征向量的故障诊

断正确率为 100%。

将其他文献方法与本文方法做比较分析,比较结果如表 2 所示,同时采用 SVM 对 4.3 节获得的 Tsallis 熵特征向量进行故障诊断,其诊断结果同样列入表 2 中。采用粒子群算法 (PSO) 优化 SVM 的核参数和惩罚参数,其中核函数采用径向基核函数。设初始种群规模为 20,最大迭代数为 200,局部搜索参数 $c1 = 1.5$,全局搜索参数 $c2 = 1.7$,适应度函数为训练样本在交叉验证下的准确率,分类法采用一对一方式,训练多类 SVM 分类器。

表 2 诊断精度对比

Table 2 Comparison of diagnosis accuracy (%)

方法	正确率	方法	正确率
文献[3]	99	文献[20]	95.12
文献[8]	99.25	PSO-SVM	99.49
文献[13]	99	ELM	100

从诊断结果看,在采用连续小波 Tsallis 奇异熵作为特征向量后,PSO-SVM 和 ELM 的诊断精度均高于其他方法,从而验证了本文所提出的特征提取方法的有效性,提取的特征分离度较好。同时可以看到,利用 ELM 作为分类器的故障诊断精度是最高的,将所有的故障样本均正确识别;相对于 SVM 及其他分类器,ELM 只需设定隐含层节点数,实现较为简单且所需时间很短,更适合于在线故障诊断。综上所述,本文所提出的基于连续小波变换 Tsallis 奇异熵的 ELM 故障诊断方法,无论在故障特征提取上,还是在分类器的性能上均优于其他方法。

5 结论

本文结合连续小波变换, Tsallis 熵和超限学习机各自的优势,提出基于连续小波系数矩阵 Tsallis 奇异熵的模拟电路故障诊断方法,以四运放双二阶高通滤波器作为测试电路。

通过连续小波变换获得故障信号的时频域系数矩阵,再将系数矩阵分割为 8 块子矩阵,使得故障状态的变动能从时频图上直接观测。同时保证了局部时频系数的微小变化能够被提取到。Tsallis 作为一种非广延熵,能够很好的应对小波变换中存在的能量泄露和频谱混叠现象。通过计算各子矩阵的 Tsallis 奇异熵,组成特征向量,可以有效的提取到分离度较高的故障特征结合超限学习机的学习能力强,训练测试时间短,同时具有待参数少,实现容易等优点,获得了较为灵活的 ELM 多分类器,实现了较高的故障诊断正确率。

参考文献

[1] YANG C, TIAN S, LONG B, et al. Methods of handling

the tolerance and test-point selection problem for analog-circuit fault diagnosis [J]. IEEE Transactions on Instrumentation & Measurement, 2011, 60 (1): 176-185.

- [2] XIAO Y, HE Y. A novel approach for analog fault diagnosis based on neural networks and improved kernel PCA[J]. Neurocomputing, 2011, 74(7): 1102-1115.
- [3] 谈恩民, 何正岭. 模拟电路故障重叠诊断方法研究[J]. 国外电子测量技术, 2015, 34(6): 33-36.
- TAN EN M, HE ZH L. Study on the fault overlap diagnosis method in analog circuit [J]. Foreign Electronic Measurement Technology, 2015, 34 (6): 33-36.
- [4] 邓勇, 于晨松. 因子分析和 ELM 在模拟电路故障诊断的应用[J]. 电子测量与仪器学报, 2016, 30(10): 1512-1519.
- DENG Y, YU CH S. Application of factor analysis and ELM in analog circuit fault diagnosis [J]. Journal of Electronic Measurement & Instrumentation, 2016, 30(10): 1512-1519.
- [5] 陈绍炜, 柳光峰, 冶帅, 等. 基于蝙蝠算法优化 ELM 的模拟电路故障诊断研究[J]. 电子测量技术, 2015, 38(2): 138-141.
- CHEN SH W, LIU G F, YE SH, et al. Research for analog circuit fault diagnosis based on ELM optimized by bat algorithm [J]. Electronic Measurement Technology, 2015, 38(2): 138-141.
- [6] 张朝龙, 何怡刚, 袁莉芬, 等. 基于 GMKL-SVM 的模拟电路故障诊断方法[J]. 仪器仪表学报, 2016, 37(9): 1989-1995.
- ZHANG CH L, HE Y G, YUAN L F, et al. Analog circuit fault diagnosis based on GMKL-SVM method [J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1989-1995.
- [7] TAN Y, HE Y, SUN Y, et al. Data-fused method of fault diagnosis for analog circuits [J]. Analog Integrated Circuits and Signal Processing, 2009, 61(1): 87-92.
- [8] 张松兰. 基于自适应粒子群的模拟电路故障诊断[J]. 电子测量与仪器学报, 2015, 29(6): 901-906.
- ZHANG S L. Analog circuit fault diagnosis based on adaptive particle swarm optimization [J]. Journal of Electronic Measurement & Instrumentation, 2015, 29(6): 901-906.
- [9] 孙健, 王成华, 杜庆波. 基于小波包能量谱和 NPE 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(9): 2021-2027.
- SUN J, WANG CH H, DU Q. Analog circuit fault diagnosis based on wavelet packet energy spectrum and NPE [J]. Chinese Journal of Scientific Instrument, 2013, 34(9): 2021-2017.
- [10] 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):2614-2619.
- 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):2614-2619.
- [11] LONG Y, HE Y, YUAN L. Fault dictionary based switched current circuit fault diagnosis using entropy as a preprocessor [J]. Analog Integrated Circuits and Signal Processing, 2011, 66(1):93-102.
- [12] 苏文胜, 王奉涛, 朱泓, 等. 基于小波包样本熵的滚动轴承故障特征提取 [J]. 振动、测试与诊断, 2011, 31(2):162-166.
- SU W SH, WANG F T, ZHU H, et al. Feature extraction of rolling element bearing fault using wavelet packet sample entropy [J]. Journal of Vibration Measurement & Diagnosis, 2011, 31(2):162-380.
- [13] YUAN L, HE Y, HUANG J, et al. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor [J]. IEEE Transactions on Instrumentation & Measurement, 2010, 59(3):586-595.
- [14] LONG B, XIAN W, LI M, et al. Improved diagnostics for the incipient faults in analog circuits using LSSVM based on PSO algorithm with Mahalanobis distance [J]. Neurocomputing, 2014, 133(10):237-248.
- [15] 陈绍炜, 柳光峰, 冶帅. 基于核极限学习机的模拟电路故障诊断研究 [J]. 西北工业大学学报, 2015(2):290-294.
- CHEN SH W, LIU G F, YE SH. A method of fault diagnosis for analog circuit based on KELM [J]. Journal of Northwestern Polytechnical University, 2015, 33(2):290-294.
- [16] 冯秋实, 陈剑云, 林鹏, 等. 基于连续小波变换的输电线路故障行波测距方法的研究 [J]. 电测与仪表, 2016, 53(2):40-44.
- FENG Q SH, CHEN J Y, LIN P, et al. The research of transmission line fault location method based on the continuous wavelet transform [J]. Electrical Measurement & Instrument, 2016, 53(2):40-44.
- [17] 唐曦凌, 梁霖, 高慧中, 等. 结合连续小波变换和多约束非负矩阵分解的故障特征提取方法 [J]. 振动与冲击, 2013, 32(19):7-11.
- TANG X L, LIN L, GAO H ZH, et al. Fault feature extraction method combining continuous wavelet transformation with multi-constraint nonnegative matrix factorization [J]. Journal of Vibration & Shock, 2013, 32(19):7-11.
- [18] 陈继开, 李浩昱, 杨世彦, 等. Tasllis 小波包奇异熵与功率谱分析在电力谐波检测的应用 [J]. 电工技术学报, 2010, 25(8):193-199.
- CHEN J K, LI H Y, YANG SH Y, et al. Application of wavelet packet singularity entropy and PSD in power

harmonics detection [J]. Transactions of China Electrotechnical Society, 2010, 25(8):193-199.

- [19] WU Y Q, JI Y, SHEN Y. Marine spill oil SAR image segmentation based on Tsallis entropy and improved Chan Vese model [J]. Journal of Remote Sensing, 2012, 16(4):678-690.
- [20] SONG P, HE Y, CUI W. Statistical property feature extraction based on FRFT for fault diagnosis of analog circuits [J]. Analog Integrated Circuits and Signal Processing, 2016, 87(3):427-436.

作者简介



何威, 2013 年于合肥工业大学获得学士学位, 现为合肥工业大学博士研究生, 主要研究方向为模拟电路测试与诊断。
Email: hiway@hfut.edu.cn

He Wei received B. Sc. from Hefei University of Technology in 2013. He is currently a Ph. D. candidate in Hefei University of Technology. His research interests are testing and fault diagnosis of analog circuits.

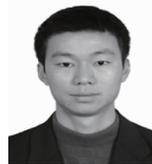


何怡刚 (通信作者), 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现为合肥工业大学教授、博士生导师, 合肥工业大学电气与自动化工程学院院长, 国家杰出青年科学基金获得者, 主要研究方向为模拟和混合集成电路设计、测试与故障诊断、智能电网技术、射频识别

技术、虚拟仪器和智能信号处理。
E-mail: 18655136887@163.com

He Yigang (Corresponding author) received M. Sc. from Hunan University in 1992 and Ph. D. from Xi'an Jiaotong University in 1996, respectively. He is currently a professor and the head of School of Electrical Engineering and Automation, Hefei University of Technology. He is one of winners of National Distinguished Young Scientists Foundation. His research interests are in the areas of circuit theory and its applications, testing and fault diagnosis of analog and mixed-signal circuits, smart grid, radio frequency identification technology, and intelligent signal processing.

罗旗舞, 2008 年于国防科技大学获得学士学位, 分别在 2011、2016 年于湖南大学获得硕士学位和博士学位。现为合肥工业大学讲师, 主要研究方向为智能信号处理及大规模电路故障测试诊断技术。



E-mail: luoqiwu@hfut.edu.cn

Luo Qiwu received B. Sc. from National University of Defense Technology in 2008, M. Sc. and Ph. D. both from Hunan University in 2011 and 2016, respectively. He is currently a lecturer in Hefei University of Technology. His current interests include the research of intelligent information processing and fault testing and diagnosis of large-scale analog circuits.