

DOI: 10.13382/j.jemi.2017.03.015

基于倒谱和决策树的模拟电路故障诊断*

邓勇 于晨松 文浩

(西南石油大学 机电工程学院 成都 610500)

摘要:针对非线性模拟电路故障诊断中参数型故障元件定位的难题,提出一种结合倒谱和决策树的模拟电路故障诊断的方法。首先对采集到的模拟电路离散电压信号进行倒谱变换;然后对变换后的数据进行小波分解并提取相应子频带的能量谱,将提取的能量谱作为对应模式的故障特征;最后利用决策树的分类功能对电路的模式进行判断。仿真结果表明,有效地提取了模拟电路不同模式的故障特征,提高了模拟电路故障诊断的效果。

关键词: 模拟电路;故障诊断;倒谱;小波分析;决策树

中图分类号: TN707 **文献标识码:** A **国家标准学科分类代码:** 510.10

Analog circuit fault diagnosis based on cepstrum and decision tree

Deng Yong Yu Chensong Wen Hao

(School of Mechatronic Engineering, Southwest Petroleum University, Chengdu 610500, China)

Abstract: Aiming at the problem of parametric fault diagnosis in nonlinear circuits, an approach utilizing cepstrum and decision tree is proposed. Firstly, the acquired fault response signals are converted by cepstrum. Then, the wavelet analysis is used to decompose the converted data and the energy is taken from different frequency bands. Finally, the obtained fault features are inputted into decision tree to identify different faults. The simulation results show that the proposed method can extract the fault signature effectively and can get a good diagnosis result.

Keywords: analog circuit; fault diagnosis; cepstrum; wavelet analysis; decision tree

1 引言

随着电子产业的迅猛发展,数模混合电路的应用日益广泛。由于模拟电路具有容差、非线性和难以模型化等特点,使得其在数模电路故障诊断中占用了大量的时间和成本。为了解决模拟电路故障诊断的难题,众多的专家学者进行了多种方法的尝试。文献[1]提出了一种模块化功能故障检测方法,构造了第一级、第二级故障字典,但其在构造字典时工作量较大。文献[2]利用小波神经网络能正确无误地诊断出所有硬故障,但其对软故障的诊断率只有80%。文献[3]将Volterra核置于子带进行分析,虽然复杂度有所减少,但仍需要计算Volterra

核。文献[4]第一次在SI电路测试和诊断中引入故障特征预处理概念,减少了计算和故障诊断时间,但该方法仅适用于中小规模开关电流电路的故障诊断。文献[5]介绍了基于优选小波包的故障特征提取方法,并得出DB3小波基具有更好诊断效果的结论,但极限学习机在故障诊断时存在随机性的问题。文献[6]在模拟电路故障诊断中引入了ELMAN神经网络,取得了不错的诊断效果,但是计算量较大,效率不高。文献[7-8]利用小波网络和脊波网络对模拟电路进行故障诊断,虽大幅提高了故障诊断结果,但是存在网络结构没简化的问题。文献[9]将短时傅里叶变换应用于模拟电路故障诊断,但短时傅立叶的窗函数是固定的,对信号的分析时不如小波变换灵活。文献[10]介绍了基于核方法的模拟电路

故障诊断方法,该方法不需要大量的训练样本,避免了计算量大的问题,但是仍存在核函数的合理构造的问题。

文献[11-12]主要研究倒谱和小波分析在声频信号特征提取的应用。在此基础上,本文将倒谱和小波变换引入到模拟电路故障特征提取中,希望通过二者的结合提取出区分度更加显著的故障特征。

在模拟电路的故障诊断中,由于存在电感和互感等现象,会导致在采集到的响应信号中混有噪声,使得电路的故障区分度降低。对采集到的响应信号进行倒谱处理,可以使变换后的信号能量更加集中,扩大信号动态分析的频谱范围,能有效地从噪声中分离出故障特征,提高模拟电路故障诊断效果。

小波变换是一种信号时间尺度分析方法,它在低频段用高的频率分辨率和低的时间分辨率,而在高频段用低的频率分辨率和高的时间分辨率,因此可以提高信号的时频分辨率。在非线性模拟电路参数型故障定位中,当电路中某一元件值发生变化,其非参数型频谱同样会发生微小变化。利用小波的时频局部化分析特性对响应信号进行分解,可以将故障特征置于子带中进行分析,更利于提取出具有区分度的故障信息。

文献[13-15]对决策树及其用法进行了介绍。决策树由节点和有向边组成,在其自顶向下的递归过程中,决策树在每一步选择中都采取当前状态下最优的选择,以得出最好的节点分类属性。相比于其他算法,决策树易于理解和实现,可在相对短的时间内对大型数据源得出可行且效果良好的结果。

2 故障特征提取

2.1 倒谱

已知时域信号 $x(t)$ 经过傅里叶变换变为频域函数 $X(f)$ 或功率谱密度函数 $G_x(f)$, 再进行一次对数的功率谱密度函数傅里叶变换并取平方, 则可得到倒频谱函数 $C_p(q)$, 其数学表达式为:

$$C_p(q) = |F\{\log G_x(f)\}|^2 \quad (1)$$

$$C_a(q) = \sqrt{C_p(q)} = |F\{\log G_x(f)\}| \quad (2)$$

式中: $C_a(q)$ 为幅值倒频谱, 是工程上常采用的开方形式。

倒谱可分为实倒谱和复倒谱, 相比于复倒谱, 实倒谱与信号的相位无关。本文采用是实倒谱, 将采集到的模拟电路电压信号 V 进行实倒谱变换, 设 X_z 是电压信号 V 的 Z 变换, 则实倒谱 S_d 的计算公式为:

$$S_d = Z^{-1}\{\log |X_z|^2\} \quad (3)$$

2.2 小波分析

小波的定义如下, 如果函数 $\psi(t)$ 的傅里叶变换为

$\Psi(\omega)$, 如果它能够满足:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (4)$$

其中函数 $\psi(t)$ 为小波函数。

对于经过倒谱变换的电压信号 $f(k)$, $\psi(t)$ 为母小波, 设:

$$\psi_{m,n}(k) = 2^{m/2} \psi(2^m k - n) \quad (5)$$

则电压信号 $f(k)$ 的离散小波变换为:

$$DWT_{m,n} = 2^{m/2} \sum_k f(k) \psi(2^m k - n) \quad (6)$$

其重构式即逆变换为:

$$f(k) = C \sum_{-\infty}^{+\infty} \sum_{-\infty}^{+\infty} DWT_{m,n} \psi_{m,n}(k) \quad (7)$$

小波分解图如图1所示。




图1 小波分解图

Fig. 1 Wavelet decomposition

2.3 小波能量谱

使用小波对倒谱变换后的信号进行分解, 会得到不同频段的分解系数, 以各频段能量来构造故障特征向量。提取出来的能量值包含丰富的故障信息, 当模拟电路发生故障时, 某种或某几种频段的能量值会发生变化。使用该方法无需系统的模型结构, 直接利用频率成份能量变化即可诊断电路故障。

设 $d_i^j(k)$ 是经小波分解后的第 i 层第 j 个节点的小波分解系数, 各个频带对应的能量 E_{ij} 为:

$$E_{ij} = \sum_{k=1}^N |d_i^j(k)|^2 \quad (8)$$

式中: $j=0, 1, \dots, 2^i - 1, N$ 表示信号的长度, 全部 E_{ij} 构成小波包能量谱。

$$\mathbf{E} = [E_{i,0}, E_{i,1}, \dots, E_{i,j}, E_{i,2^i-1}] \quad (9)$$

得出的 \mathbf{E} 即为对应故障模式的特征向量, 可用于进行故障模式的判断。

3 决策树

决策树是一种归纳分类算法, 它通过对训练集的学习, 挖掘出有用的规则, 用于对新集进行预测。目前决策树主要采用 C4.5 算法, C4.5 算法以信息熵为标准进行属性选择, 熵函数计算公式如下。

1) 计算训练样本 T 的信息熵:

$$I(T) = - \sum_{i=1}^N \left\{ \left[\frac{F(M_i, T)}{|T|} \right] \log_2 \left[\frac{F(M_i, T)}{|T|} \right] \right\} \quad (10)$$

式中: $|T|$ 为训练样本的个数, M_i 为相应的分类, N 为样本总类别数, $F(M_i, T)$ 为相应分类中样本的个数。

2) 计算由属性 B 对样本集 T 划分的期望信息值 $I_B(T)$:

$$I_B(T) = - \sum_{i=1}^P \left[\left(\frac{|T_i|}{|T|} \right) I(T_i) \right] \quad (11)$$

式中: P 为测试属性 B 的不同值的个数; T_i 为根据 B 划分样本的第 i 种取值的子样本; $|T_i|$ 为对应的样本个数。

3) 由属性 B 得出的信息增益为:

$$H(B) = I(T) - I_B(T) \quad (12)$$

4) 计算按属性 B 划分时, 样本集合 T 的潜在信息:

$$T(B) = \sum_{i=1}^P \left[\frac{T_i}{|T|} \log_2 \frac{T_i}{|T|} + \pi \left(1 - \frac{T_i}{|T|} \right) \log_2 \left(1 - \frac{T_i}{|T|} \right) \right] \quad (13)$$

样本集合 T 的信息增益比率为:

$$H_r(B) = \frac{H(B)}{T(B)} \quad (14)$$

4 仿真实验

本文首先对采集到的电压信号进行倒谱变换, 然后利用小波对变换后的数据进行分解, 并提取各频段的能量值作为故障特征, 将提取的故障特征分成训练样本集和测试样本集, 输入决策树进行网络训练和模式判别, 流程如图 2 所示。




图 2 诊断流程
Fig. 2 Flow chart of fault diagnosis

为了证明本文基于倒谱和决策树的模拟电路故障诊断方法的有效性, 以状态滤波器电路进行仿真实验, 电路如图 3 所示。

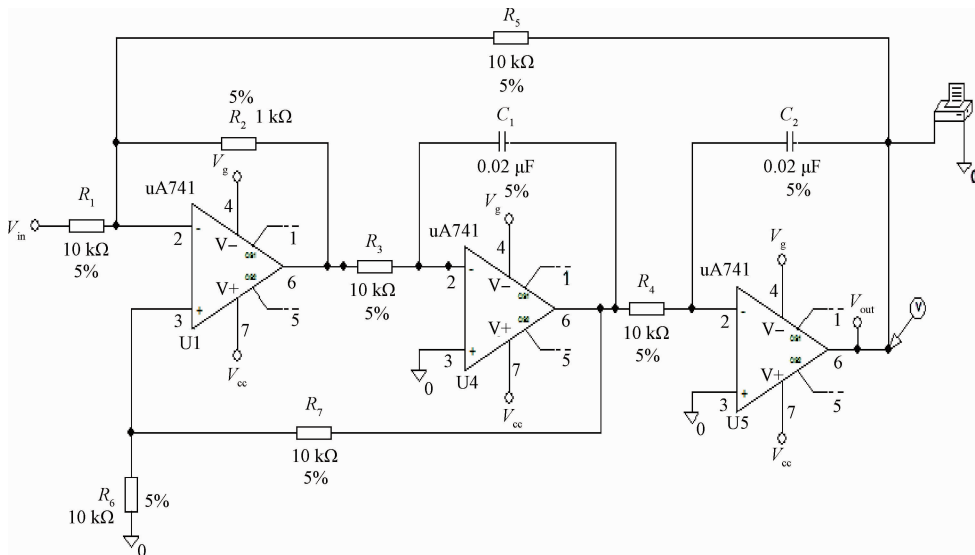


图 3 状态滤波器电路
Fig. 3 The circuit of state filter

电路输入端是幅值 1 V, 频率 1 kHz 的正弦信号, 电路中元件的容差设置为 5%, 电路设置包括正常状态在内的共计 7 种故障模式, 故障值设定见表 1。

使用 PSPICE 软件对状态滤波电路的正常和故障模式进行 50 次 Monte Carlo 仿真, 在 V_{in} 处施加激励信号, 在 V_{out} 处采集 1 000 点电压信号作为原始特征, 最终会得到 7 组具有 50 个样本信号的特征数据。对采集到的电压信号进行实倒谱变换, 结果如图 4 所示。

表 1 状态滤波器故障模式表

Table 1 The state filter's fault modes

故障编号	元件名称	正常值	故障值
1	NF	-	-
2	C_1^-	0.02 μ F	0.016 μ F
3	C_1^+	0.02 μ F	0.024 μ F
4	R_1^-	10 k Ω	8 k Ω
5	R_1^+	10 k Ω	12 k Ω
6	R_2^-	10 k Ω	8 k Ω
7	R_7^+	10 k Ω	12 k Ω




图4 电压信号波形

Fig.4 The waveform of voltage signal

由图4可知,经倒谱变换后的电压信号的能量会在某几个位置相对集中,不同故障模式下能量集中的位置会有所不同。使用小波对经倒谱变换后的电压信号进行分解,可将故障特征置于子带中,这更有利于分离出故障特征的不同点。

相比于 Haar 和 Db2 小波基,Db3 小波基消失矩阶数更大,频带划分效果越好,对故障特征进行小波分解可获得更高的故障诊断精度。所以本文使用 Db3 小波对倒谱变换后的电压信号进行5层分解,并根据式(8)提取子带的能量值作为故障特征,提取出的故障特征如图5所示。

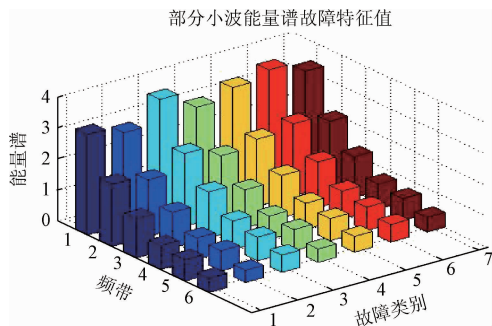


图5 部分小波能量谱故障特征值

Fig.5 Partial wavelet energy spectrum fault features

为证明倒谱变换在去除故障特征冗余信息的作用,本文将未经倒谱变换的电压信号进行小波分解,提取故障特征后输入决策树作为对比。

将50组故障特征分成30组的训练样本和20组测试样本。将训练样本输入决策树对其进行网络的训练,然后用测试样本对训练好的决策树的故障诊断能力进行检验,诊断结果如图6所示。

由表2可看出,未经倒谱处理后的诊断率为82.1%,经倒谱处理后的诊断率为91.4%。这说明倒谱变换可以有效去除电压信号中的冗余信息,提高模拟电路故障诊断的精度。

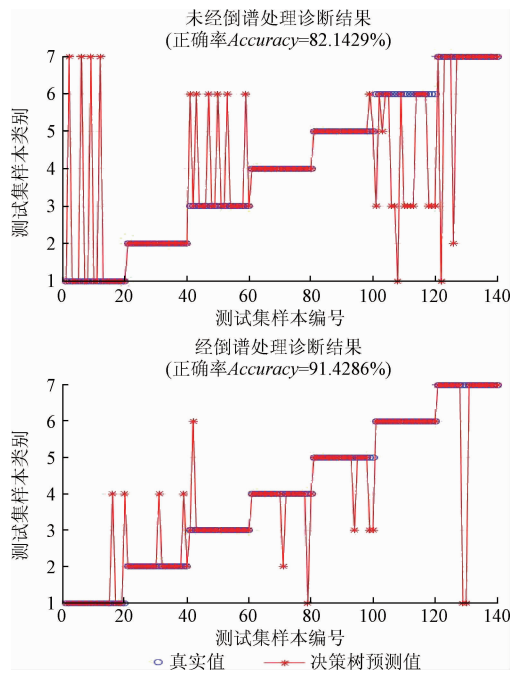


图6 故障诊断结果

Fig.6 The fault diagnosis results

表2 故障诊断结果表

Table 2 The fault diagnosis results

编号	样本数	未经倒谱变换的		经倒谱变换的	
		正确样本数	诊断率/%	正确样本数	诊断率/%
1	20	16	80	18	90
2	20	20	100	18	90
3	20	14	70	19	95
4	20	20	100	18	90
5	20	19	95	17	85
6	20	8	40	20	100
7	20	18	90	18	90

为与决策树进行比较,本文使用BP神经网络重复上述实验步骤。神经网络的隐层数设为一层,隐层节点数由凑凑法得出,当节点数为12时获得最佳诊断效果,具体的诊断结果如表3。

表3 诊断对比表

Table 3 The diagnostic comparison

方法	诊断率	训练时间/s	诊断时间/s
BP神经网络	89.3%	3.726 1	0.064 1
决策树	91.4%	0.497 4	0.005 3

由表3可知,决策树的故障诊断率要稍高于BP神经网络,但在网络训练和诊断的时间消耗上要大大低于BP神经网络。对于一些大规模的模拟电路,使用决策树进行故障诊断,可以在保证诊断精度的同时降低诊断消耗。

5 结论

针对模拟电路的故障识别定位的难题,本文提出了基于倒谱和决策树的诊断方法。首先对经倒谱变换后的电压信号进行小波分解,然后提取子频段的能量值,最后使用决策树进行故障诊断。从分析与实验验证的过程可知,本文提出的诊断方法可以有效提取故障特征,提高模拟电路故障诊断率的同时降低了诊断消耗,为解决模拟电路故障识别与定位的难题提供了一种新选择。

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):676-684.
HU M, FAN M. A method of function module fault diagnosis of analog circuit [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29 (5): 676-684.
- [2] GUO J, HE Y, LIU M. Wavelet neural network approach for testing of switched-current circuits [J]. Journal of Electronic Testing, 2011, 27(5):611-625.
- [3] BURTON T G, GOUBRAN R A, BEAUCOUP F. Nonlinear system identification using a subband adaptive volterra filter[J]. IEEE Transactions on Instrumentation & Measurement, 2009, 58(5):1389-1397.
- [4] 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.
- [5] 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.
- [6] 丁硕,常晓恒,巫庆辉,等.基于Elman神经网络的传感器故障诊断研究[J].国外电子测量技术,2014,33(4):78-81
DING S, C XIAO H, WU Q H, et al. Sensor fault diagnosis research based on the Elman neural network[J]. Journal of Foreign Electronic Measurement Technology, 2014,33(4): 78-81.
- [7] 肖迎群,何怡刚.基于脊波网络的模拟电路故障诊断[J].电工技术学报,2010,25(6):155-162.
XIAO Y Q, HE Y G. A fault diagnosis method of analog circuit based on ridgelet network [J]. Transactions of

- China Electrotechnical Society, 2010.25(6):155-162.
- [8] XIAO Y Q, HE Y G, et al. A linear ridgelet network approach for fault diagnosis of analog circuit[J]. Science China Information Sciences, 2010, 53(11):2251-2264.
- [9] AVARGEL Y, COHEN I. Modeling and identification of nonlinear systems in the short-time fourier transform domain [J]. IEEE Transactions on Signal Processing, 2010, 58(1):291-304.
- [10] 伞冶,石慧姝,郭珂.核方法及其在模拟电路故障诊断中的研究进展[J].电子测量技术,2013,36(1):91-96.
SAN ZH, SHI H SH, GUO K. The research of nuclear method in analog circuit fault diagnosis [J]. Journal of Electronic Measurement and Technology, 2013,36(1): 91-96.
- [11] 黄博,高勇.基于倒谱特征和小波包特征熵的直升机声目标识别[J].探测与控制学报,2007,29(6):15-18.
HUANG B, GAO Y. The recognition of helicopter acoustic target based on cepstrum characteristic and wavelet packet characteristic entropy [J]. Journal of Detection & Control 2007,29(6): 15-18.
- [12] 董丽娜,何怡,叶卫平.基于小波分析的梅尔频率倒谱参数[J].北京师范大学学报:自然科学版,2015(5):469-474.
DONG L N, HE Y, YE W P. Wavelet analysis based Mel frequency cepstrum parameters [J]. Journal of Beijing Normal University: Nature Science, 2015 (5): 469-474.
- [13] GARG P, NEIDER D, MADHUSUDAN P, et al. Learning invariants using decision trees and implication counterexamples [J]. Acm Sigplan Notices, 2015, 51(1):499-512.
- [14] RUTOWSKI L, JAWORSKI M, PIETRUCZUK L, et al. The CART decision tree for mining data streams [J]. Information Sciences, 2014,266(5):1-15.
- [15] JINDAL A, DUA A, KAUR K, et al. Decision tree and SVM based data analytics for theft detection in smart grid [J]. IEEE Transactions on Industrial Informatics, 2016, 12(3):1-1.

作者简介



邓勇,1972年出生,1994年毕业于西安交通大学获得学士学位,1997年毕业于电子科技大学获得硕士学位,2012年毕业于电子科技大学获得博士学位,高级工程师,现在西南石油大学任教,主要从事复杂电子系统故障诊断与预测的研究。

E-mail: y_den117@126.com

Deng Yong was born in 1972, received B. Sc. from Xi'an Jiaotong University in 1994, M. Sc. from University of Electronic Science and Technology of China in 1997 and Ph. D. from University of Electronic Science and Technology of China in 2012, respectively. He is a senior engineer and working in Southwest Petroleum University now. His research direction is diagnosis and prediction of complicated electronic systems.



于晨松, 1991 年出生, 2015 年于西南石油大学获得学士学位, 硕士生, 主要研究方向为模拟电路的故障诊断和人工智能算法。
E-mail: 1309163786@qq.com

Yu Chensong was born in 1991, received B. Sc. from Southwest Petroleum University in

2015. Now he is M. Sc. candidate in Southwest Petroleum University. His research interest includes analog circuit fault diagnosis and artificial intelligence algorithms.



文浩, 1991 年出生, 2015 年于西南石油大学获得学士学位, 硕士生, 主要研究方向为无损检测和人工智能算法。

E-mail: 503542589@qq.com

Wen Hao was born in 1991, received B. Sc. from Southwest Petroleum University in 2015. Now he is M. Sc. candidate in Southwest Petroleum University. His research interest includes nondestructive testing and artificial intelligence algorithms.