

基于 SOFM 网络和异质信息融合的模拟电路诊断

吴正苗¹, 彭敏放¹, 谭 虎¹, 沈美娥²

(1 湖南大学 电气与信息工程学院, 湖南 长沙 410082;

2 北京信息科技大学, 北京 100101)

摘 要: 大规模集成电路的发展使得传统的接触法测试在某些场合受到了限制. 针对其造成的电量测试信息不足的问题, 文中融合电量信息和非电量信息作为故障特征信息, 应用自组织特征映射(SOFM)神经网络对模拟电路进行故障诊断. 提取电路工作时的电压和温度信息作为故障特征信息, 经预处理后作为样本输入给 SOFM 神经网络进行电路故障诊断. 通过输出层各神经元的竞争, 得到获胜神经元, 从而对样本数据进行故障识别分类. 仿真结果表明, 应用所提融合诊断方法提高了诊断准确率.

关键词: 故障诊断; 特征提取; SOFM 神经网络; 数据融合; 模拟电路

中图分类号: TM131

文献标识码: A

文章编号: 1000-7180(2011)11-0160-05

Analog Circuit Diagnosis Based on SOFM Network and Heterogeneous Information Fusion

WU Zheng-miao¹, PENG Min-fang¹, TAN Hu¹, SHEN Mei-e²

(1 School of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

2 Beijing University of Information Science and Technology, Beijing 100101, China)

Abstract: With the development of VLSI, conventional contact test is constrained in some occasions. Aiming at insufficient information of analog circuit electronic test, electronic and non-electronic information is combined as fault feature signature in the paper. Self-Organizing Feature Map (SOFM) Neural network is applied to analog circuit fault diagnosis. Voltage and temperature information is extracted as fault feature information, then processed, which is sent into neural network as input sample to detect circuit fault. Using the competition of output level neurons of SOFM, the winning neuron is attained and the fault recognition for sample data is classified. Simulation results show that fusion diagnosis has more satisfactory accuracy compared with single information diagnosis.

Key words: fault diagnosis; feature extraction; SOFM neural network; data fusion; analog circuit

1 引言

模拟电路故障诊断由于受到元器件的容差、可测故障信息量不足、故障模式多样化、电路输入输出的非线性与建模难等因素的影响, 至今距实用尚有一定的距离^[1]. 随着微电子技术和大规模集成电路的发展, 模拟电路趋向于集成化和复杂化, PCB 的可测点变得越来越少, 使得传统的通过接触法测试

并提取电路电量信息作为故障特征的方法受到了限制, 尤其在某些场合对正在运行的电路设备故障搜寻时, 不允许切割很多元器件, 进行接触测试诊断. 红外诊断技术作为一种无损检测技术, 不需要接触被检目标, 具有操作安全, 灵敏度高, 检测效率高的特点^[2]. 将红外诊断技术应用到模拟电路故障诊断, 通过红外采集设备记录电路工作时的温度信息, 作为故障特征信息对电路进行诊断, 是对模拟电路故

障诊断的一种有效补充。

将神经网络应用于模拟电路故障诊断,可克服非线性、在线计算量大的缺点^[3-4]。但大多都是采用 BP 网络进行模拟电路故障诊断的,其隐含层神经元数目难以确定,必须通过经验多次试验才能确定其数目。文中采用自组织特征映射(Self-Organizing Feature Map, SOFM)神经网络对模拟电路进行故障诊断,该网络无需在训练或学习过程中预先指明训练输入矢量的所属类别,收敛速度快,且实现简单^[5]。通过将电压信息和温度信息进行融合,输入给 SOFM 网络对电路各状态分类,从而判断电路的状态,实现故障诊断^[6]。

2 应用 SOFM 网络的电路故障识别

2.1 SOFM 网络

SOFM 神经网络是一种竞争网络,由输入层(n 维的数据集)和竞争层(二维 SOM 神经网络)组成,如图 1 所示。输入层和竞争层之间实现全连接。输入样本通过竞争学习后,功能相同的输入靠得比较近,不同的分得比较开,以此将一些无规则的输入自动排开。在连接权的调整过程中,使权的分布与输入样本的概率密度分布相似^[7]。




图 1 二维 SOFM 神经网络模型

SOFM 网络的输入为 n 维数据,输出为 $m \times m$ 二维阵列结构,其训练过程如下:

① 随机选取一组输入特征矢量来初始化权值矢量 $w_i(0)$,其中 $i = 1, 2, \dots, m^2$; m^2 为输出神经元的个数。

② 从每一类中按一定的概率选取一个故障特征作为网络输入。

③ 用最小欧氏判别准则,找出最佳匹配神经元作为获胜神经元 $c(t)$,如式(1)所示。

$$c(t) = \underset{i}{\operatorname{argmin}} \|w_i(t) - x(t)\|$$

$$i = 1, 2, \dots, m^2 \quad (1)$$

④ 按式(2)和式(3)调整权值矢量,使获胜神经元及其附近神经元的权值朝输入矢量的方向移动。

$$w_j(t+1) = w_j(t) + \Delta w_j(t) \quad (2)$$

$$\Delta w_j(t) = \alpha(t) h_{c(t)j}(t) (x(t) - w_j(t)) \quad (3)$$

其中, j 为输出层的获胜神经元及其附近神经元, $\alpha(t)$ 为学习率, $h_{c(t)j}$ 为领域函数。

⑤ 更新学习率,减小邻域函数。

⑥ 检查结束条件,当特征值不再发生明显变化时退出,否则转入步骤 ③。

2.2 故障诊断过程

从本质上讲,模拟电路故障诊断是模式识别和分类的问题。电路有多少故障,就应该将输入数据分成多少类,这些输入数据就是故障特征向量,故障特征向量通过模拟电路的各种故障状态来获取。为了加快网络的收敛速度和聚类功能,故障特征向量作为输入数据输入到神经网络之前,进行必要的预处理。自组织特征映射网络采用的是无教师的学习自学习方式,无需在训练或学习过程中预先指明训练输入向量的所属类别。当输入某一类别的向量时,神经网络中的一个神经元将会在其输出端产生最大值,而其他神经元具有较小的输出值。所以,该网络能够根据最大值的位置来判断输入向量所代表的故障。

图 2 为诊断原理框图。首先对工作电路(PCB)施加激励信号,分别提取电路工作时可测点的电压信息和部分元器件的温度信息,特征提取的目的是进一步提炼信息,抽取稳定的,区别各类故障的特征参量,作为故障模式识别的依据,SOFM 网络根据各故障特征参量进行模式分类。文中以电压信息和温度信息作为故障特征,先获取电路各个状态下可测点的电压值和各元件的温度值,对其预处理后作为自组织特征映射神经网络的输入,通过竞争学习,不断的调整权值,根据输出最大神经元的位置来判断各故障类。



图 2 故障诊断原理框图

3 故障特征提取

3.1 红外诊断原理

自然界中一切温度高于绝对零度的物体,每时每刻都在辐射出具有载体信息的红外辐射,根据史蒂芬—波尔兹曼定律,物体的红外辐射能量可表示为:

$$W = \sigma \epsilon T^4 \quad (4)$$

温度值和关键点的电压值预处理后,输入给 SOFM 神经网络进行训练. 仿真默认环境温度设置为 27℃. 表 2 为电应力分析模拟的部分电路状态下元件的温度值. 表 3 为其利用式(6) 处理后的温度值. 在文中 $\text{var}x_{ij} = 0.1x_{0ij}$, 表中标 * 的为测试样本. 电压值数据在此不再赘述.

表 2 各元件的原始温度值

电路 状态	各元件的原始温度值(单位:℃)			
	T(R3)	T(R4)	T(Q3)	T(Q4)
F0	27.8764	27.8685	28.7256	28.7258
F0 *	27.8716	27.9084	28.6309	28.7254
F1	30.2058	30.2058	27.0419	27.0419
F2	27.3867	27.3867	28.5695	28.5697
F2 *	27.5145	27.5146	28.6622	28.6623
F3	27.8062	27.0000	30.7646	28.7256
F4	30.1570	27.0000	27.0132	27.0601
F5	27.9155	27.0000	27.0000	28.7417
F6	30.2060	27.0000	27.0000	27.0419
F7	29.8556	27.0607	27.8281	27.3254
F8	27.3520	29.2080	27.2540	28.5233
F9	27.3924	27.5651	28.1470	28.5790

表 3 预处理后各元件的温度值

电路 状态	预处理后各元件的温度值(无量纲)			
	T'(R3)	T'(R4)	T'(Q3)	T'(Q4)
F0	0.0000	0.0000	0.0000	0.0000
F0 *	-0.0017	0.0143	-0.0330	-0.0001
F1	0.8356	0.8357	-0.5861	-0.5862
F2	-0.1757	-0.1729	-0.0543	-0.0543
F2 *	-0.1298	-0.1270	-0.0221	-0.0221
F3	-0.0252	-0.3116	0.7098	-0.0001
F4	0.8181	-0.3116	-0.5961	-0.5799
F5	0.0140	-0.3116	-0.6007	0.0055
F6	0.8357	-0.3116	-0.6007	-0.5956
F7	0.7100	-0.2899	-0.3124	-0.4875
F8	-0.1881	0.4807	-0.5123	-0.0705
F9	-0.1736	-0.1089	-0.2014	-0.0511

用 SOFM 聚类网络对电路的各种状态进行分类,其基本思想是:如果一个电阻发生正偏,就是一个故障类,比如 R5 正向偏置 30%和 R5 正向偏置

50%属于同一个故障.
用 SOFM 网络对输入数据进行训练,整个分类过程在 MATLAB 中可以用以下语句实现:
`net=newsom(minmax(p_train),[4 4]);`
`net=train(net,p_train);`
训练步数 `net.trainParam.epochs = 1000`,取 R4 正向偏置 5%和 R5 正向偏置 30%作为测试样本,竞争层取 4×4 的二维阵列.

表 4 为诊断结果,第一行为故障状态,第二行为电压诊断时的获胜神经元,第三行为温度诊断时的获胜神经元,第四行为融合诊断时的获胜神经元. 融合诊断时 SOFM 网络对所有的故障状态实现了正确的分类. 这时,如果输入一个新的故障模式,竞争层的神经元开始竞争,激活与之最为接近的神经元. 由仿真结果可以看出融合诊断时, SOFM 网络可以对电路状态进行很好的分类, R4 正向偏置 5%时(即 R4 的变化在容差范围内),获胜神经元与 R4 标称值时相同,它们属于同一类模式即无故障状态 F0. R5 正向偏置 30%时,获胜神经元与 R5 正向偏置 50%时相同,它们属于同一类模式即软故障状态 F2. 仿真试验验证该网络对其他软硬故障也可以进行分类.

表 4 诊断结果

F0	F0 *	F1	F2	F2 *	F3	F4	F5	F6	F7	F8	F9
11	11	13	8	8	6	13	5	1	3	16	12
12	12	9	16	16	4	1	14	1	6	13	15
1	1	16	2	2	6	12	9	14	13	4	3

从表 4 也可以看出,融合诊断的分类性能比基于单一信息的分类性能要好,无论采用电压信息或者温度信息单独诊断时,故障模式都有重叠,而融合诊断时,各种故障模式相互分开. 采用信息融合的诊断方法,提高了故障定位的正确性.

5 结束语

文中采用 SOFM 网络进行模拟电路故障诊断,利用电路工作时的温度信息和电压信息并作为故障特征信息,经预处理后输入 SOFM 网络,通过其输出层神经元的竞争,得到获胜神经元,实现对故障特征向量的分类. 同时,将红外诊断技术应用于模拟电路故障诊断,通过将电压信息和温度信息融合,提高了故障定位的准确率. 结合红外诊断技术的信息融合故障诊断方法对于大规模集成电路诊断更能显示其优越性.

参考文献:

- [1] 杨士元,胡梅,王红. 模拟电路软故障诊断研究[J]. 微电子学与计算机, 2008, 25(1): 1-8.
- [2] 田裕鹏. 红外检测与诊断技术[M]. 北京: 化学工业出版社, 2006.
- [3] 彭敏放,沈美娥,贺建飏,等. 容差电路软故障检测与定位[J]. 电工技术学报, 2009, 24(3): 222-228.
- [4] 廖薇,许春冬,刘锦高. 基于神经网络的模拟电路故障诊断研究[J]. 微电子学与计算机, 2010, 27(5): 125-128.
- [5] 谢涛,何怡刚,姚建刚,等. 基于小波包和自组织网络的模拟电路故障诊断[J]. 微电子学, 2009, 39(2): 190-193.
- [6] 朱大奇,刘永安. 故障诊断的信息融合方法[J]. 控制与决策, 2007, 22(12): 1321-1328.
- [7] Erik Berglund, Joaquin Sitte. The parameterless self-

organizing map algorithm [J]. IEEE Transactions on neural networks, 2006, 17(2): 305-316.

- [8] 袁海英,陈光祜. 故障诊断中基于神经网络的特征提取方法研究[J]. 仪器仪表学报, 2007, 28(1): 90-94.

作者简介:

吴正苗 女, (1979-), 硕士研究生. 研究方向为集成电路测试与诊断、数字图像处理.

彭敏放 女, (1964-), 博士, 教授, 博士生导师. 研究方向为电路测试与诊断、电气设备状态监测、智能信息处理、电磁场理论及其应用.

谭虎 男, (1986-), 博士研究生. 研究方向为集成电路测试与诊断、复杂网络理论及应用.

沈美娥 女, (1966-), 硕士, 副教授. 研究方向为集成电路测试与诊断、计算机仿真与建模.

(上接第 159 页)

进行验证, 说明了该模型可以有效评估多媒体 Web 数据源的质量.

参考文献:

- [1] Gravano L, Chang C, Garcia-Molina H, et al. STAR-TS: stanford proposal for internet meta-searching[C] // Proceedings of the 20th ACM-SIGMOD International Conference on Management of Data. Tucson, Arizona: ACM, 1997: 207-218.
- [2] Souza D, Zobel J, Thom J. Is CORI Effective for Collection Selection an Exploration of parameters, queries, and data [C] // Proceedings of Australian Document Computing Symposium. Melbourne, Australia: IEEE, 2004: 41-46.
- [3] Abounaga A, ElGebaly k, Wong D. BE: user guided source selection and schema mediation for internet scale data integration[C] // Proceedings of the IEEE Interna-

tional Conference on Data Engineering. Istanbul, Turkey: IEEE, 2007: 1513-1514.

- [4] Xian XF, Zhao PP, Yang YF. Efficient selection and integration of hidden web database[J]. Journal of computers, 2010, 5(4): 500-507
- [5] 鲜学丰, 方巍, 赵朋朋, 等. 一种 Deep Web 数据源质量评估模型[J]. 微电子学与计算机, 2008, 25(10): 47-50.
- [6] 胡鹏昱, 苗忠义, 崔志明, 等. 扩展的 Deep Web 质量估计模型研究[J]. 微电子学与计算机, 2008, 25(9): 24-27.
- [7] 胡鹏昱, 赵朋朋, 方巍, 等. 深网数据源质量估计模型. 计算机工程, 2009, 35(9): 204-207.

作者简介:

邓松 男, (1982-), 博士研究生, 讲师. 研究方向为 Web 数据挖掘、知识工程.

王映龙 男, (1974-), 博士, 教授. 研究方向为数据挖掘.