

应用Elman网络优化非线性模拟电路测试激励

殷时蓉^{1,2}, 陈光禹², 谢永乐²

(1. 重庆交通大学机电学院 重庆 南岸区 400074; 2. 电子科技大学自动化工程学院 成都 610054)

【摘要】非线性模拟电路瞬态测试激励信号的参数对电路故障识别率影响很大,在搜索最佳激励信号的过程中,需建立非线性模拟电路的系统模型。Elman网络是一种递归神经网络,能逼近任意动态非线性系统。该文用一种改进的Elman网络建立故障电路和非故障电路的系统模型,用遗传算法搜索最佳瞬态测试激励信号参数,仿真实验结果表明经过该方法优化后的激励信号能大大提高非线性模拟电路的故障识别率。

关键词 Elman网络; 非线性电路; 优化; 测试激励
中图分类号 TP391.9 **文献标识码** A

Optimization of Testing Stimulus for Nonlinear Circuits by Applying Elman Neural Network

YIN Shi-rong^{1,2}, CHEN Guang-ju², and XIE Yong-le²

(1. College of Electromechanical and Automobile Engineer, Chongqing Jiaotong University Nan'an Chongqing 400074;
2. School of Automation Engineering, University of Electronic Science and Technology of China Chengdu 610054)

Abstract The parameters of transient testing stimulus for nonlinear analog circuits greatly influence the fault diagnosis efficiency. In the course of finding the optimum stimulus, we have to develop the nonlinear analog circuits' models. Elman network which is a dynamic recurrent neural network can approximate any dynamic nonlinear system. In this paper, Elman network is used to develop the models of the fault circuits and fault free circuit, the optimum stimulus is searched with genetic algorithm. Experiment results demonstrate that the optimum stimulus achieved has high fault identification.

Key words Elman network; nonlinear circuits; optimization; testing stimulus

模拟电路的瞬态响应故障诊断是用特定的波形信号如脉冲波、锯齿波或分段线性信号(piece wise line, PWL)等激励被诊断电路,然后监测其瞬态响应,并和无故障电路响应比较,以识别电路是否有故障^[1-4]。瞬态测试程序生成很简单,故障诊断的执行时间可以被大大缩短^[3]。激励信号的参数(脉冲的宽度、频率,锯齿波的斜率、PWL信号各转折点处的电压等)对诊断效率(故障识别率)影响很大。因为电路故障,特别是软故障,对某些激励信号的响应和无故障电路响应难以区别。各国学者提出了很多优化激励的方法以提高故障识别率,文献[1-2]用计算电路元件灵敏度分析方法,文献[5]用控制理论方法,但都要先写出电路的节点方程。在搜索最佳激励信号的过程中,需要多次重复地对被测电路进行仿真,因此需要建立故障电路和非故障电路的系统模型。非线性模拟电路系统模型的建立是一个难题,

很难写出非线性模拟电路的系统方程,特别是有储能元件和反馈回路的电路,电路的输出不仅与本时刻的输入有关,还与前一时刻电路的状态有关。

神经网络能以任意精度逼近任何非线性函数,在非线性和模式识别上广泛应用。本文提出用一种改进的Elman神经网络建立电路模型,用遗传算法优化瞬态测试激励信号的各项参数,用瞬态响应的总体类间离散度作衡量所选激励信号进行故障诊断的效率的适度函数。

1 Elman神经网络

带储能元件和反馈回路的非线性模拟电路输入输出关系复杂,很难写出其系统方程。如果已知电路在输入激励下的响应,可以用神经网络逼近该系统。已经证明,对三层BP神经网络,隐层传输函数用S函数,输出层用线性函数,只要隐层有足够多的

神经元, 可以任意精度逼近非线性函数和有效的进行模式识别^[6-7]。但是, BP网络是静态网络, 网络的输出仅仅是当前输入的非线性映射, 不能直接应用于动力学系统建模。

如果要用神经网络逼近一个带反馈和储能元件的非线性模拟电路, 可以有两种方法。一种方法是在BP网络中加入延时单元来处理(又称外时延网络), 将动态时间建模问题变为一个静态空间建模问题。但必须先知道动态系统的输入输出延时步长, 即首先需要对结构模型进行定阶, 随着系统阶次的增加或阶次未知时, 迅速膨胀的网络结构, 将使学习收敛速度更加缓慢。此外较多的输入节点也使相应的模型对外界噪声特别敏感。另一种就是采用局部递归神经网络(又称内时延网络)。如果在网络中引入反馈单元, 则组成一个具有记忆功能的动态递归神经网络。Elman网络是一种典型的具有内反馈结构的动态递归网络, 它把隐层输出反馈回输入, BP网络的所有权值修正训练方法都可以用于Elman网络^[6,8-9]。对单输入单输出(SISO)系统, 用Elman网络逼近时只需要一个输入节点, 一个输出单元, 网络结构比用BP网络逼近时要简单得多。

1.1 Elman网络结构




图1 Elman神经网络的网络结构图

本文用一种改进的Elman网络, 其网络结构如图1所示。和BP网络相比它除了有输入层、隐层、输出层之外, 还有一个特殊的连接单元(context nodes)。连接单元是用来记忆隐层单元以前时刻的输出值, 可认为是一个延时算子。递归部分是固定的, 即不能进行学习, 前馈连接部分可以进行连接权值修正, BP网络的所有权值修正训练方法都可以用于Elman网络。改进的Elman网络是在标准Elman网络的结构单元上增加一个固定增益为 α 的自反馈连接。

$u(k)$ 为网络的外部输入, $y(k)$ 为网络输出, $x(k)$ 为隐层输出, $xc(k)$ 为结构单元输出。设网络的输入层有 q 个节点, 隐层和连接单元有 n 个节点, 输出层有 m 个节点, 则网络输入 $u(k)$ 为 q 维向量, 隐层输出

$x(k)$ 及连接单元输出 $xc(k)$ 为 n 维向量, 网络输出 $y(k)$ 为 m 维向量, 连接权 W^1 为 $n \times n$ 维矩阵, W^2 为 $n \times q$ 维矩阵, W^3 为 $m \times n$ 维矩阵, 则图1网络的数学模型为:

$$xc(k) = \alpha xc(k-1) + x(k-1) \tag{1}$$

$$x(k) = f(W^1 xc(k) + W^2 u(k)) \tag{2}$$

$$y(k) = g(n_y) = g(W^3 x(k)) \tag{3}$$

式中 $f(\cdot)$ 为隐藏层传输函数, 多取为sigmoid函数, 即 $a = \frac{1}{1+e^a}$; $g(\cdot)$ 为输出层传输函数, 多采用线性函数; $0 \leq \alpha < 1$ 为自连接反馈增益因子, 当 α 固定为0时, 该网络为标准的Elman网络。标准的Elman网络只能逼近一阶延时函数, 当 α 不为0时, 为改进的Elman网络。由式(2)知, $xc(k)$ 依赖于过去不同时刻的隐层输出, 所以 $y(k)$ 是一个动态递归过程, 采用BP学习算法, 改进后的Elman网络能逼近任意阶次的非线性动态函数。

1.2 Elman网络的学习规则

设第 k 步时网络的实际输出为 $y(k)$, 目标输出为 $y_d(k)$, 定义误差函数为:

$$E(k) = \frac{1}{2} (y_d(k) - y(k))^T (y_d(k) - y(k)) \tag{4}$$

将 E 对连接权 W^1 、 W^2 、 W^3 分别求偏导, 由梯度下降法可得Elman网络的学习算法:

$$\Delta w_{ij}^3(k) = -\eta_3 \frac{\partial E}{\partial w_{ij}^3(k)} = -\eta_3 \frac{\partial E}{\partial y_i(k)} \frac{\partial y_i(k)}{\partial n_{iy}(k)} \frac{\partial n_{iy}(k)}{\partial w_{ij}^3(k)} = \eta_3 [y_{id}(k) - y_i(k)] g'_i(\cdot) x_j(k) \tag{5}$$

$$\Delta w_{jt}^2(k) = -\eta_2 \frac{\partial E}{\partial w_{jt}^2(k)} = -\eta_2 \frac{\partial E}{\partial y(k)} \frac{\partial y(k)}{\partial n_y(k)} \frac{\partial n_y(k)}{\partial x_j(k)} \frac{\partial x_j(k)}{\partial w_{jt}^2(k)} = \eta_2 [y_d(k) - y(k)] g'(\cdot) w_j^3 f'_j(\cdot) u_t(k) \tag{6}$$

$$\Delta w_{jl}^1(k) = -\eta_1 \frac{\partial E}{\partial w_{jl}^1(k)} = -\eta_1 \frac{\partial E}{\partial y(k)} \frac{\partial y(k)}{\partial n_y(k)} \frac{\partial n_y(k)}{\partial x_j(k)} \frac{\partial x_j(k)}{\partial w_{jl}^1(k)} = \eta_1 [y_d(k) - y(k)] g'(\cdot) w_j^3 f'_j(\cdot) x_l(k) \tag{7}$$

式中 η_1 、 η_2 、 η_3 分别是 W^1 、 W^2 、 W^3 的学习速率。

2 瞬态测试激励信号的优化

2.1 瞬态测试激励信号的优化流程

搜索适合被测电路的最佳激励信号的最佳激励信号各参数过程是一个优化过程。优化算法可以采用贪婪法、遗传算法、模拟退火算法等。遗传算法不受问题本身

的性质、优化准则形式、模型结构形式、被优化参数数目和有无约束等的限制, 仅用目标函数在概率准则引导下进行全局自适应自动搜索, 通过它能够处理传统优化方法难以解决的复杂问题。因此本文选用遗传算法, 把每个激励信号编码成一个染色体, 根据每个染色体(个体)的适应度函数值, 利用遗传算法的复制、交叉、变异算子产生下一代个体(新的瞬态测试激励信号)。瞬态测试激励信号的优化流程为:

(1) 测量故障电路和非故障电路在某几个信号激励下的响应, 形成神经网络的训练样本。选择几个激励信号是为了提供更多的训练样本, 使训练后的神经网络更逼近系统。

(2) 训练Elman神经网络, 建立故障电路和非故障电路系统模型。

(3) 初始化搜索参数, 包括瞬态激励信号参数的取值范围和初始值。生成遗传算法的初始化种群。设置遗传算法的交换率 pc 和变异率 pm 。

(4) 计算故障电路和非故障电路在当前所选激励下的响应和总体类间离散度。

(5) 判断是否满足搜索停止条件, 满足条件, 转(7), 否则, 转(6)。

(6) 使用遗传算法的复制、交叉、变异算子产生下一代个体(新的瞬态激励信号)。转(4)。

(7) 输出最佳激励信号参数, 结束搜索。

2.2 遗传算法适应度函数构造

如果要把 n 个样本分成 c 类, 属于第 i 类的有 n_i 个样本, $n = \sum_{i=1}^c n_i$, P_i 是第 i 类的先验概率。则各类样

本可以分开是因为它们位于特征空间的不同区域, 显然这些区域之间距离越大, 类别可分性就越大^[10]。如果每一类样本表示与非线性模拟电路的一个故障相对应的故障特征, 则类间离散度越大, 故障越容易被识别。因此可以用样本总体类间离散度衡量所选瞬态激励用于非线性模拟电路故障诊断的效率, 即用作遗传算法的适应度函数。

令 $\mathbf{x}_k^{(i)}$ 、 $\mathbf{x}_l^{(j)}$ 分别为 i 类及 j 类中的 D 维特征向量, $\delta(\mathbf{x}_k^{(i)}, \mathbf{x}_l^{(j)})$ 为这两个向量之间的距离, 则所有特征向量的总体类间离散度定义为:

$$J_d(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^c P_i \sum_{j=1}^c P_j \frac{1}{n_i n_j} \sum_{k=1}^{n_i} \sum_{l=1}^{n_j} \delta(\mathbf{x}_k^{(i)}, \mathbf{x}_l^{(j)}) \quad (9)$$

多维空间中两个向量之间有很多种距离度量, 在欧氏距离情况下有:

$$\delta(\mathbf{x}_k^{(i)}, \mathbf{x}_l^{(j)}) = (\mathbf{x}_k^{(i)} - \mathbf{x}_l^{(j)})^T (\mathbf{x}_k^{(i)} - \mathbf{x}_l^{(j)}) \quad (10)$$

用 \mathbf{m}_i 表示第 i 类样本的集总平均向量:

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{x}_k^{(i)} \quad (11)$$

用 \mathbf{m} 表示所有各类的样本集总平均向量:

$$\mathbf{m} = \sum_{i=1}^c P_i \mathbf{m}_i \quad (12)$$

将式(10)~(12)带入式(9)得:

$$J_d(\mathbf{x}) = \sum_{i=1}^c P_i \left[\frac{1}{n_i} \sum_{k=1}^{n_i} (\mathbf{x}_k^{(i)} - \mathbf{m}_i)^T (\mathbf{x}_k^{(i)} - \mathbf{m}_i) + (\mathbf{m}_i - \mathbf{m})^T (\mathbf{m}_i - \mathbf{m}) \right] \quad (13)$$

如果各类的先验概率相等, 即 $P_i = \frac{1}{c}$, 且各类的样本特征向量只有一个, 则总体类间离散度可以表示为:

$$J_d(\mathbf{x}) = \sum_{i=1}^c (\mathbf{x}^{(i)} - \mathbf{m})^T (\mathbf{x}^{(i)} - \mathbf{m}) \quad (14)$$

因此遗传算法的适应度函数为:

$$\text{fitness}(\mathbf{x}) = \sum_{i=1}^n (\mathbf{x}_i - \sum_{k=1}^n \mathbf{x}_k)^T (\mathbf{x}_i - \sum_{k=1}^n \mathbf{x}_k) \quad (15)$$

式中 n 为类别总数(即无故障电路和故障电路的总数); \mathbf{x}_i 为第 i 个故障电路的响应。

3 仿真实验

本文用图2所示电路验证本文方法的效率。 R_6 的电流和电压关系为: $i=0.003u+0.02u^2$ 。故障集为: $R_1=0.9 \text{ k}\Omega$, $R_1=1.1 \text{ k}\Omega$, $R_5=9 \text{ k}\Omega$, $R_5=11 \text{ k}\Omega$, $R_6: i=0.003u+0.018u^2$, 共5个软故障。




图2 被诊断电路原理图




图3 PWL电压信号示意图

瞬态激励信号选用PWL信号。图3所示为典型的PWL电压信号, 模拟电路的PWL激励的最大测试时间 t_{\max} 可以根据电路频率响应分析得到, 最大电压值 U_{\max} 和最少电压值 U_{\min} 可以由电路的适用场合、内部

元件特性值得到。各时间转折点 t_i 处的电压值 u_i 可以在电压允许范围之内任意选择取值。

用pspice仿真电路, 4个PWL电压信号激励被诊断电路, 测量电阻 R_5 两端的电压值。建立故障电路和非故障电路流的Elman网络模型。用遗传算法进行搜索, 得到最佳激励信号的各转折点处电压值为(1,3.3,5.4,8,2,2,5.2,4.4,6.6,8)。

分别用起始点电压为1 V, 终端 $U_{\max}=8$ V的斜坡函数信号和搜索出的优化信号激励故障电路和无故障电路, 得到两种激励下的电路响应。再分别用两种激励下电路的响应BP训练神经网络, 并对故障电路和无故障电路进行10组Monte-Carlo分析, 仿真神经网络, 得到两种激励信号下的故障识别率如表1所示。可以看出, 经过优化的激励信号能大大提高电路的故障诊断能力。

表1 故障识别率

故障	斜坡信号		优化信号	
	正确识别数	故障识别率/(%)	正确识别数	故障识别率/(%)
无故障电路	6	60	7	70
$R_1=0.9$ k Ω	7	70	8	80
$R_1=1.1$ k Ω	6	60	8	80
$R_5=9$ k Ω	7	70	8	80
$R_5=11$ k Ω	6	60	7	70
$R_6: i=0.003u+0.018u^2$	5	50	8	80

4 结 论

在搜索最佳瞬态激励的过程中, 需重复多次的对非线性模拟电路进行仿真, 因此需建立其系统模型。Elman网络把隐层输出反馈回输入, 是一种递归神经网络, 改进的Elman网络能逼近任意动态非线性系统。本文用改进的Elman网络建立故障电路和非故障电路的系统模型, 用遗传算法搜索最佳瞬态测试激励信号参数, 实验结果表明经过本文方法优化后的激励信号能大大提高非线性模拟电路的故障诊断率。本文方法也适用于带储能元件和反馈回路的非线性模拟电路。

参 考 文 献

- [1] BURDIEK B. The qualitative form of optimum transient test signals for analog circuits derived from control theory methods[J]. ISCAS, 2002, 1: 157-160.
- [2] VARIYAM PN, CHATTERJEE A. Specification-driven test generation for analog circuits[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2000, 19(1): 1189-1201.
- [3] TAYLOR D, PLATTS A. Transient response testing of nonlinear analogue circuits using optimized fault sets[J]. IEE Proceeding on Circuits Device System, 2003, 15(2): 104-112.
- [4] YIN Shi-rong, CHEN Guang-ju, XIE Yong-le. Wavelet neural network based fault diagnosis in nonlinear analog circuits[J]. Journal of Systems Engineering and Electronics, 2006, 17(3): 521-526.
- [5] BERNHARD B. Generation of optimum test stimuli for nonlinear analog circuits using nonlinear programming and time-domain sensitivities[C]//Design, Automation and Test in Europe, 2001, Conference and Exhibition 2001, Proceedings. Munich, Germany: IEEE, 2001: 603-608.
- [6] 葛宏伟, 梁艳春. 进化Elman神经网络模型与非线性系统辨识[J]. 吉林大学学报(工学版), 2005, 35(5): 511-520.
GE Hong-wei, LIAN Yan-chun. Evolutionary Elman neural network model and identification for Non-linear systems[J]. Journal of Jinlin University(Engineering and Technology Edition), 2005, 35(5): 511-520.
- [7] HAGAN M T, DEMUTH H B, BEALE M H. Neural network design[M]. Beijing: China Machine Press, 2002.
- [8] MERAL M, SENGOR N S. System identification with hybrid Elman network[C]//Signal Processing and Communications Applications Conference, Proceedings of the IEEE 12th. [S.l.]: IEEE, 2004: 80-83.
- [9] MBEDE J B, HUANG Xin-han, WANG Min. Robust neuro-fuzzy sensor-based motion control among dynamic obstacles for robot manipulators[J]. IEEE Transactions on Fuzzy Systems, 2003, 11(2): 249-261.
- [10] 边肇祺, 张学工. 模式识别[M]. 第2版. 北京: 清华大学出版社, 2000.
BIAN Zhao-qi, ZHANG Xue-gong. Pattern Recognition[M]. 2nd ed. Beijing: Tsinghua University Press, 2000.

编辑 漆 蓉