

文章编号: 1000-8152(2008)03-0556-04

一种云样本的控制产生及在电路故障诊断中的应用

崔 江, 王友仁

(南京航空航天大学 自动化学院, 南京 江苏 210016)

摘要: 为了选择电路故障诊断中的特征样本, 提出了产生云样本的方法, 并用于神经网络的训练和识别. 首先采用逆向云理论对初始特征样本进行统计以获取数字特征, 其次采用正向云理论产生扩展训练样本, 并用新产生的样本训练两种神经网络. 仿真结果表明, 采用云样本训练的神经网络要比采用常规样本训练的性能稳健, 具有较好的抗噪声性能, 在模拟电路故障诊断中达到了较好的诊断效果.

关键词: 云模型; 特征样本; 神经网络; 故障诊断

中图分类号: O235; TM930

文献标识码: A

A method of cloud-sample control and generation with application to circuit fault diagnosis

CUI Jiang, WANG You-ren

(Nanjing University of Aeronautics and Astronautics, College of Automation and Engineering, Nanjing Jiangsu 210016, China)

Abstract: To select feature samples in circuit fault diagnosis, we propose a method of cloud-sample generation, and apply it to artificial-neural-network training and recognition. First, the inverse cloud model theory is employed to obtain the statistical digital feature of the samples, and then the extended training data set is produced by positive cloud theory. Second, two kinds of networks are trained with the newly produced data set. Simulation results reveal that the performance of the neural network trained by the cloud samples is better than that trained by the conventional methods. The results also proved that the network is robust to random noise, and the proposed method is valid in the faults diagnosis of analog circuit.

Key words: cloud model; feature samples; neural network; fault diagnosis

1 引言(Introduction)

模拟电路的故障诊断是一项较为复杂和困难的研究课题^[1]. 其主要方法可分为两大类: 基于模型的方法和基于机器学习的方法. 前者主要应用于线性电路的故障诊断; 后者采用基于机器学习方法直接建立电路特征样本和故障模式之间的映射关系, 不依赖电路内部结构和先验知识.

人工神经网络(ANN)是一种基于机器学习的方法, 此类技术已在国内外得到了广泛的研究和应用^[2]. 神经网络的诊断性能取决于不同的训练样本, 故研究特征样本的选择或产生技术具有重要的理论和实际价值, 但目前相关的研究成果很少^[3~6].

本文提出了一种训练样本的云模型产生方法. 通过基于云模型的统计方法产生新的样本(称为“云样本”), 并设计训练集进行神经网络的训练和

分析. 实际研究表明, 采用云样本训练的神经网络获得了较稳健的网络性能, 对随机噪声具有良好的抵抗力, 在模拟电路测试中取得了较好的诊断效果.

2 基于云模型的样本产生方法和训练(Samples generation method based on cloud model and training)

研究表明, 组成电路的模拟分立元件参数值都近似服从正态分布^[7]. 当元件产生故障时, 得到的电路响应曲线也具有一定的正态分布特性. 通过对待测电路响应进行特征提取, 可以得到各故障模式的特征空间分布. 各样本集在特征空间内形成一个中间“厚”、边缘“薄”的“云团”: 中央是所谓的“好样本”^[3]; 和其他“云团”交界的样本是“边界样本”; 和其他“云团”混合的样本是“差样本”.

收稿日期: 2006-05-24; 收修改稿日期: 2007-03-30.

基金项目: 国家自然科学基金资助项目(60374008, 60501022); 航空科学基金资助项目(2006ZD52044); 南京航空航天大学青年基金资助项目(Y0521033).

样本集的“云团”分布特点, 客观上较为符合云模型特别是正态云模型的相关理论^[8]: 特征样本对应云模型概念中的“云滴”; “好样本”、“边界样本”和“差样本”可分别对应云模型概念中的“基本元素”、“外围元素”和“弱外围元素”等概念. 因此, 采用云模型的相关统计理论产生新样本可突出“好样本”的作用, 且新样本的分布和原始训练样本基本一致^[5], 这有利于提高分类器的泛化能力和诊断性能; 且云样本的产生融合了随机产生理论, 对随机噪声具有一定的抵抗作用.

2.1 云样本的产生方法(Cloud samples generation method)

云样本的控制和产生同时需要逆向云和正向云模型算法, 如图1所示.




图1 云样本产生方法框图

Fig. 1 Flow of cloud samples generation method

记第*i*类故障模式样本集为 $\mathbf{x}_i = [\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in}]$, 其中, $\mathbf{x}_{ij} (j=1, 2, \dots, n)$ 为该集合中的第*j*个样本向量, μ_i 表示 $\mathbf{x}_i$ 的确定度. 由于模拟电路故障样本往往具有较高的数据维, μ_i 的值难以获取, 一般情况下仅需估计3个数字特征, 即: 期望 $\mathbf{Ex}$ 、熵 $\mathbf{En}$ 和超熵 $\mathbf{He}$. 该方法称为无需确定度的逆向云算法^[8], 步骤如下:

1) 估算训练集 $\mathbf{x}_i$ 的均值 $\bar{\mathbf{X}}$ 、一阶中心矩 $\mathbf{K}$ 和方差公式 $\mathbf{S}$:

$$\bar{\mathbf{X}} = \frac{1}{n} \sum_{j=1}^n \mathbf{x}_{ij}, \quad (1)$$

$$\mathbf{K} = \frac{1}{n} \sum_{j=1}^n |\mathbf{x}_{ij} - \bar{\mathbf{X}}|, \quad (2)$$

$$\mathbf{S} = \sqrt{\frac{1}{n-1} \sum_{j=1}^n |\mathbf{x}_{ij} - \bar{\mathbf{X}}|^2}. \quad (3)$$

2) 估算3个数字特征 $\mathbf{Ex}$ 、 $\mathbf{En}$ 和 $\mathbf{He}$:

$$\mathbf{Ex} = \bar{\mathbf{X}}, \quad (4)$$

$$\mathbf{En} = \sqrt{\frac{\pi}{2}} \cdot \mathbf{K}, \quad (5)$$

$$\mathbf{He} = \sqrt{(\mathbf{S} - \mathbf{En}) \cdot (\mathbf{S} + \mathbf{En})}. \quad (6)$$

设定云滴个数 Num , 利用正向云模型产生云样本的基本步骤如下:

1) 产生期望值为 $\mathbf{En}$ 、方差为 $\mathbf{He}^2$ 的正态随机数:

$$\mathbf{En}' \sim N(\mathbf{En}, \mathbf{He}^2); \quad (7)$$

2) 利用上述1)产生的正态随机数, 进一步产生期望值为 $\mathbf{En}$ 、方差为 $\mathbf{En}'^2$ 的正态随机数并计算其确定度;

3) 根据设定的云滴个数, 重复步骤1)和2)即可获取第*i*类故障模式的云样本集: $\text{drops}'(\mathbf{x}_i, \mu_i)$, 其中 μ_i 是一种“副产品”.

重复上述所有算法, 即可得到全部故障模式的云样本集.

2.2 网络训练集和测试集(Training and test set)

为测试云样本的有效性, 建立BP神经网络和RBF神经网络并进行训练. 设计的3类训练样本集合分别为: $\text{Tr1} = \{\text{原始训练样本叠加1\%均值白噪声}\}$ 、 $\text{Tr2} = \{50\% \text{原始训练样本}, 50\% \text{云样本}\}$ 、 $\text{Tr3} = \{\text{原始训练样本}\}$. 其中, 原始训练样本从初始特征样本集中加以选取(这里选取一半), 再利用原始训练样本产生云样本集. 为提高训练效率, 对所有样本集运用了主元分析(PCA)技术.

此处设计的测试集包括12个, 依次记为Test1, Test2, $\dots$, Test12. 其中Test1= $\{\text{初始特征样本}\}$, Test2~Test6为Test1依次叠加1%, 5%, 10%, 15%, 20%白噪声形成; Test7= $\{\text{云样本}\}$, Test8~Test12为Test7依次叠加1%, 5%, 10%, 15%, 20%白噪声形成.

由于实际采集的数据往往受各种不确定因素的影响, 由此得到的测试样本也与计算机仿真得到的样本有所差别, 这些不确定性因素的影响可归结至随机噪声的干扰. 因此, 采用云样本参与网络训练和测试具有重要的实际意义.

3 电路故障诊断实例和数据分析(Sample circuit diagnosis and analysis)

3.1 实例电路和云样本产生(Sample circuit and cloud samples generation)

如图2所示为一带通滤波器, 其中的 R_2, R_4, C_1 和 C_2 为可能产生单软故障的元件, 加上无故障情况, 整个电路一共有9种故障模式.




图2 模拟带通滤波器

Fig. 2 Analog band-pass filter

在Pspice环境下进行电路建模和Monte Carlo分析;故障模式的设置采用ITC'97基准^[7]. V_{out} 为电压信息的可测节点,特征提取方法采用多层小波包分解算法.取初始特征样本集的一半(4500个)作为神经网络的原始训练样本,其余作为测试样本.

依据云样本产生算法,并设定云滴数量为500,产生所有故障模式的云样本共4500个.图3为元件 R_4 阻值减小的软故障多维云样本在二维空间内的图像显示.




图3 元件 R_4 减小软故障所产生的云样本

Fig. 3 Cloud samples image produced by reducing R_4 value

对产生的云样本集合和初始特征样本集合同时进行归一化和PCA分析(分析误差为0.01)等预处理,特征维数由16降为9.

3.2 神经网络训练(ANN training)

首先建立3层感知器网络,网络参数如下:输入层神经元个数为9;隐层神经元个数选为8,采用Tansig激活函数;输出层节点个数为9(即故障模式数),激活函数采用Sigmoid.采用基于附加动量法的BP算法进行训练,训练精度设为0.01.对3种样本集训练完毕,得到3种BP ANN(采用Tr1, Tr2和Tr3训练的依次记为BP1, BP2和BP3).

其次,建立3层RBF网络进行训练.其输入和输出节点都为9;训练精度设定为0.01;隐层激活函数采用高斯径向基函数,输出则采用线性激活函数.最后得到3种RBF ANN(采用Tr1, Tr2和Tr3训练的依次记为RBF1, RBF2和RBF3).

在MATLAB7.0仿真环境下,编程实现特征样本的提取、归一化、PCA分析和云样本产生算法.对两组神经网络进行训练,得到的各种参数对比如表1所示.

表1 两组神经网络的训练时间和步长对比

Table 1 Comparison for two groups of ANN

名称	训练精度	训练时间/s	所需步长
BP1	0.01	133	19107
BP2	0.01	126	17321
BP3	0.01	150	21922
RBF1	0.01	24	200
RBF2	0.01	21	173
RBF3	0.01	26	202

3.3 诊断和数据分析(Diagnosis and analysis)

将待诊断的疑似故障特征样本 x 输入至神经网络,通过激活函数计算得到输出诊断向量:

$$F = [F_1, F_2, \dots, F_q, \dots, F_9], \quad (8)$$

其中 F_q 为第 q 类故障和样本 x 之间的相似程度,且 $F_q \in [0, 1]$.一般地,输出向量中的最大值所对应的故障模式应为待诊断的故障类型 F ,即

$$F = \max_{1 \leq q \leq 9} \{F_1, F_2, \dots, F_q, \dots, F_9\}. \quad (9)$$

对某个测试样本集进行诊断时,对应的故障诊断率 F_r 按下式计算:

$$F_r = \frac{\sum_{q=1}^9 c_q}{T} \times 100\%, \quad (10)$$

其中: c_q 为正确诊断第 q 类故障模式的样本个数, T 为该测试样本集的全部样本数目.

利用BP ANN分别对Test1~Test12进行测试,其故障诊断率如表2所示.设计的测试集既包含训练样本也包含其他测试样本,故对应诊断率是网络性能的一种综合反映.

表2 BP神经网络的故障诊断率对比

Table 2 Diagnosis rate comparison for BP ANN

	Test1	Test2	Test3	Test4
BP1/%	90.22	89.33	85.56	75.56
BP2/%	89.33	88.44	85.33	75.67
BP3/%	94.89	94.22	87.33	77.11
	Test5	Test6	Test7	Test8
BP1/%	66.22	60.44	73.11	72.89
BP2/%	68.22	66.00	89.11	88.89
BP3/%	66.00	59.33	61.78	61.56
	Test9	Test10	Test11	Test12
BP1/%	70.00	66.00	63.56	59.56
BP2/%	83.56	77.78	70.00	68.22
BP3/%	60.89	59.28	57.11	54.00

采用RBF ANN对测试集进行测试,得到的诊断

率如表3所示。

表3 RBF神经网络的故障诊断率对比
Table 3 Diagnosis rate comparison for RBF ANN

	Test1	Test2	Test3	Test4
RBF1/%	79.56	79.11	72.00	66.44
RBF2/%	78.78	79.00	72.78	67.00
RBF3/%	86.44	80.67	61.56	53.78
	Test5	Test6	Test7	Test8
RBF1/%	59.56	55.11	52.89	53.56
RBF2/%	62.89	57.56	71.33	71.33
RBF3/%	48.22	47.56	41.11	40.89
	Test9	Test10	Test11	Test12
RBF1/%	53.78	53.00	52.67	52.56
RBF2/%	68.89	68.00	59.56	59.11
RBF3/%	39.78	38.00	37.56	36.44

由表2可看出, BP3的记忆力较好, 但整体的泛化性能要逊于BP1和BP2。BP1在诊断Test1~Test6时性能稍逊BP3, 但在识别云样本方面远好于BP3。BP2在测试云样本性能方面优于另外两种, 随着噪声污染的加重, 3个BP网络的诊断性能有接近的趋势, 但BP2的故障诊断率变化趋势最为平缓, 对随机噪声的鲁棒性优于另外两个网络。从表1和表3可看出, RBF的训练速度很快, 但采用RBF网络进行故障诊断的整体正确率要低于BP网络; 另外, 就诊断Test1~Test6而言, RBF1和RBF2的性能较为接近, 但RBF2的整体性能要优于另外两个RBF网络, 决策性能较为稳健, 这和表2的变化趋势相一致; 在诊断Test7~Test12方面, RBF2的优势更为明显。

综上, 基于云样本训练的BP2或RBF2对噪声样本具有较好的鲁棒性, 性能较为稳健, 且在故障决策方面宜采用BP网络。

4 结论(Conclusions)

针对神经网络训练中的特征样本选择问题, 本文

提出了一种基于云模型统计理论的样本控制和产生方法, 并进行了仿真研究。结果表明, 云样本产生简单有效, 应用于基于神经网络的模拟电路测试中取得了较好的诊断效果。

参考文献(References):

- [1] FENTON W G, MCGINNITY T M, MAGUIRE L P. Fault diagnosis of electronic systems using intelligent techniques: a review[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 2001, 31(3): 269 – 281.
- [2] AMINIAN F, AMINIAN M, COLLINS H W. Analog fault diagnosis of actual circuits using neural networks[J]. *IEEE Transactions on Instrumentation and Measurement*, 2002, 51(3): 544 – 550.
- [3] 刘刚, 张洪刚, 郭军. 不同训练样本对识别系统的影响[J]. 计算机学报, 2005, 28(11): 1923 – 1928.
(LIU Gang, ZHANG Honggang, GUO Jun. The influence of different training samples to recognition system[J]. *Chinese Journal of Computers*, 2005, 28(11): 1923 – 1928.)
- [4] 杨慧中, 卢鹏飞, 张素贞, 等. 网络泛化能力与随机扩展训练集[J]. 控制理论与应用, 2002, 19(6): 963 – 966.
(YANG Huizhong, LU Pengfei, ZHANG Suzhen, et al. Generalization of networks and random expanded training sets[J]. *Control Theory & Applications*, 2002, 19(6): 963 – 966.)
- [5] GEORGE N K. On over fitting, generalization, and randomly expanded training sets[J]. *IEEE Transactions on Neural Networks*, 2000, 11(5): 1050 – 1057.
- [6] 解培中, 张志涌. 一种新的用于故障诊断分类器的特征样本生成方法[J]. 系统工程与电子技术, 2001, 23(11): 35 – 37.
(XIE Peizhong, ZHANG Zhiyong. New approach to conform feature samples for fault diagnosis classifiers[J]. *Systems Engineering and Electronics*, 2001, 23(11): 35 – 37.)
- [7] KAMINSKA B. Analog and mixed-signal benchmark circuits-first release[C] // *Proceedings of International Test Conference*. Washington, DC: IEEE Press, 1997: 183 – 190.
- [8] 李德毅, 杜鹄. 不确定性人工智能[M]. 北京: 国防工业出版社, 2005.
(LI Deyi, DU Yu. *Artificial Intelligence with Uncertainty*[M]. Beijing: National Defense Industry Press, 2005.)

作者简介:

崔江 (1977—), 男, 讲师, 博士研究生, 主要研究方向为电路测试, E-mail: cuijiang@nuaa.edu.cn;

王友仁 (1963—), 男, 教授, 博士生导师, 主要研究方向为仿生硬件理论和测试等技术研究, E-mail: wangyrc@nuaa.edu.cn.