

遗传算法优化的SVM模拟电路故障诊断方法

陈世杰, 连 可, 王厚军

(电子科技大学自动化工程学院 成都 610054)

【摘要】提出了一种利用遗传算法优化的SVM多分类决策树(GADT-SVM)实现模拟电路故障诊断的新方法。介绍了GADT-SVM的设计思想和算法原理;利用传递函数对模拟电路进行建模,并用小波分解提取电路冲激响应的能量分布作为故障特征;使用GADT-SVM对故障特征样本进行分类实现故障诊断。仿真结果表明,与未经优化的DAG-SVM和DT-SVM故障诊断方法相比,该方法可以减小诊断“误差积累”的影响,具有更好的误差控制能力。

关键词 模拟电路; 故障诊断; 遗传算法; 支持向量机

中图分类号 TP18

文献标识码 A

doi:10.3969/j.issn.1001-0548.2009.04.019

Method for Analog Circuit Fault Diagnosis Based on GA Optimized SVM

CHEN Shi-jie, LIAN Ke, and WANG Hou-jun

(School of Automation Engineering, University of Electronic Science and Technology of China Chengdu 610054)

Abstract A new method for analog circuit fault diagnosis is presented based on genetic algorithm optimized support vector machine multi-class decision tree (GADT-SVM). The design idea and algorithm principle of GADT-SVM is introduced firstly; then model of analog circuit is built by transfer function, and fault characteristic is picked-up by wavelet energy distribution of impulse response. Finally, fault samples are recognized by GADT-SVM. Experiment results show that our method can depress error accumulation phenomena of diagnosis and have stronger error control ability compared with the traditional DAG-SVM and DT-SVM.

Key words analog circuit; fault diagnosis; genetic algorithm; support vector machine

故障诊断问题可以归纳为多类别分类的模式识别问题^[1]。训练多个两分类SVM并将其按照某种规则组合起来实现多类别分类识别是目前利用支持向量机进行故障诊断的常用方法^[2]。

故障诊断与一般模式识别问题不同的是在工程实际中往往不仅追求故障诊断的正确率,而且对诊断误差的控制要求也很严格。但常用的基于有向无环图(directed acyclic graph, DAG)的SVM多分类方法(DAG-SVM)^[3]和基于决策树的SVM多分类方法(DT-SVM)^[4]都没有考虑误差控制问题。如DAG-SVM在处理具有 K 种故障模式的诊断问题时需要构造 $k(k-1)/2$ 个SVM两类别分类器,然后采用有向无环图将所有SVM两类别分类器组合起来实现多分类功能。当类别数 K 确定,该DAG的结构就是固定的,同时单个SVM在图中的位置可以随意安排,因此分类性能不稳定。而对于DT-SVM,从理论上说, K 类

故障模式识别问题所有可能构造的严格二叉树的数目为 $\prod_{i=1}^{K-1} (2i-1)$, $K \geq 3$ ^[5]。因此,不同的决策树结

构其故障诊断的性能也是不同的。传统的方法没有过多考虑决策树结构的优化问题,在每个树节点均采用将一类样本与其余样本分开的策略,这样的树结构是固定的,而且生成的树高最高,容易产生“误差积累”。本文提出了一种基于遗传算法优化的SVM多分类决策树(GADT-SVM)模拟电路故障诊断新方法。

1 基于遗传算法的SVM多分类决策树优化

文献[6]提出了一种利用遗传算法优化SVM决策树结构的多类别分类方法——GADT-SVM。该方

法以两分类SVM最优决策面分类间隔(margin)最大为准则,在每个决策节点将多类训练样本划分为两类进行训练,使两个子类间的可分性尽可能强,以构造合理的树结构,最终生成最优(或近优)SVM决策树。

1.1 遗传算法的设计

遗传算法设计的关键是针对需要解决的具体问题设计:(1)参数编码策略。(2)初始种群产生方法。(3)适应度函数。(4)遗传操作。

1.1.1 实值编码策略

为了提高搜索效率,采用实值编码的策略实现原始训练样本集类别的编码,编码形式为: {类别编号|标识码}。整个染色体分为两个基因段,其中“类别编号”基因段编码为当前节点类别号的一个随机排列,其长度为当前节点的类别数 L ;“标识码”基因段编码为1到 L 之间的一个随机整数,用以标注当前节点的分类策略。如,决策树根节点的某一染色体编码为{1,2,L ,K|N},其中, $K \geq 3$ 为原始训练样本集类别总数,随机整数 $N \in [1, K]$ 表示在染色体第 N 位将训练样本分开。对于根节点以下的子节点,根据其父节点的划分结果,将父节点染色体“类别编号”基因段中本节点不包含的类别对应的基因剔除后重新随机排列,并随机产生新的“标识码”形成新的染色体。

1.1.2 初始种群的产生

采用实值编码,解空间与染色体空间重合。考虑到种群数目过大不仅增加GA运算时间,而且会使种群形态过于分散,从而使算法收敛困难,所以本文选择种群规模的大小为训练样本的30%,在解空间中随机产生初始种群,并使其均匀分布于解空间。

1.1.3 适应度函数的确定

对决策树而言,越上层节点的分类性能对整个分类模型的推广性能影响越大。因此,在生成决策树的过程中,应该让最容易分割的类最早分割出来。即在决策树的上层节点处分割,以减小“误差积累”的影响,采用SVM的分类间隔作为两类间的可分离测度设计GA适应度函数,以使每个决策节点类间可分离度尽可能大。

根据SVM理论^[7],GA的适应度函数设计为:

$$\text{margin} = 2/\|\mathbf{w}^*\| \quad (2)$$

其中:

$$\mathbf{w}^* = \sum_{i=1}^n \alpha_i^* y_i \mathbf{x}_i \quad (3)$$

式中 α^* 为支持向量对应的Lagrange乘子。

1.1.4 遗传操作算子

遗传操作是实现寻优的关键,通常包括选择、交叉和变异操作算子。操作算子设计如下:

(1) 选择。选择算子的作用是从上一代遗传结果中以一定概率繁殖适应度较大的个体进入下一代的遗传操作。若个体 a_i 的适应度函数为 $\text{fit}(a_i)$,种群规模为 pop_size ,则选中 a_i 为下一代个体的概率为:

$$P(a_i) = \text{fit}(a_i) / \sum_{j=1}^{\text{pop_size}} \text{fit}(a_j) \quad (4)$$

显然适应度高的个体,繁殖的下一代数目较多;而适应度较小的个体,繁殖的数目较小,甚至被淘汰。

(2) 交叉。本文先采用随机的方式将种群中的个体两两配对,然后在每对个体中随机设置一个交叉点,进行单点交叉运算。特别地,为防止划分出现基因交叠,在交叉操作后必须对“类别编号”基因段进行完备性检测:若交叉操作后“类别编号”基因段仍保持当前决策节点完备的基因,则接受本次交叉操作;否则放弃本次交叉操作,返回原染色体。

(3) 变异。为了在遗传操作初期取得较大的变异算子以维持种群的多样性,防止出现早熟现象。在算法已接近最优解邻域时,减小变异算子,确保其局部搜索能力,本文采用如下自适应变异概率:

$$P_m = \exp(-1.5 \times 0.5t) / \text{pop_size} \cdot \sqrt{L+1} \quad (5)$$

式中 t 是进化代数; $L+1$ 是染色体长度。

同样,为了防止“类别编号”基因段上基因出现重复,当“类别编号”基因段上某一基因座上的基因发生变异时,变异后的基因编码对应的基因座上的基因应相应地变换为变异基因座上的原基因编码。如8分类问题的某一原始染色体“类别编号”基因段编码如图1a所示。若第二基因座上的基因发生变异,变异后的基因编码为7,则最终变异操作得到的新染色体“类别编号”基因段如图1b所示。

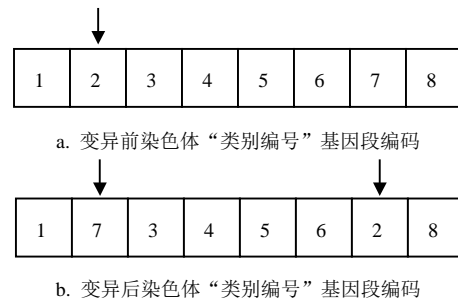


图1 变异操作示意图

1.2 基于遗传算法的SVM决策树生成算法

基于遗传算法优化的SVM决策树生成算法可描

述如下:

(1) 将全部训练样本集所属类别按实值编码策略进行编码,并在根节点调用GA得到最优或近优的染色体,根据染色体的“标识码”值将“类别编号”基因对应的原始训练样本类划分为两类训练基本SVM。(2) 判断各子节点是否只包含一类样本,若是转步骤(4),反之转步骤(3)。(3) 对包含两类以上样本的子节点,按照编码策略形成新的染色体,并调用GA得到子节点最优或近优的染色体,根据染色体的“标识码”值将“类别编号”基因对应的样本类划分为两类训练基本SVM,转步骤(2)。(4) 结束循环,生成最优(或近优)决策树。

与DAG-SVM和DT-SVM不同,由于在每一决策节点引入了GA进行决策优化,对不同的分类问题将生成不同的决策树结构,因此GADT-SVM决策树的生成具有自适应性。

2 系统建模及故障特征提取

2.1 基于传递函数的系统故障建模

系统传递函数是系统内在固有特征的一种精确描述,本文将作为系统故障建模依据。设 $H(t, P)$ 为某系统传递函数,其中 P 为系统的参数集,与系统元件有关。输入冲激信号 $x(t) = \delta(t)$, 输出 $y(t) = \delta(t) * H(t, P)$ 就指示了系统当前的工作状态。很显然,当任何一个(或多个)系统元件参数发生故障时, $y(t)$ 都自然地体现了系统的故障行为。

2.2 基于小波变换的故障特征提取

直接将系统的冲激响应采样值作为故障特征向量进行处理会陷入“维数灾难”,使得即使对小规模

的电路也会产生巨大的计算量,因而必须对故障信号进行特征提取^[8]。小波变换可以作为信号特征提取的一种很好的数学工具。关于小波变换的基本理论详见文献[9],本文直接提取各级小波变换的能量分布作为故障特征信号。

设 $y(t)$ 在不同尺度层次的高频系数分别为 cd_1, cd_2, \dots, cd_J , 低频系数为 ca_j , 其中 J 为信号小波分解的级数。以上系数可以根据Mallat塔式算法得到^[9]。显然, $y(t)$ 在不同层次的能量为:

$$E_j = \sum_k (|ca_{j,k}|^2 + |cd_{j,k}|^2) \quad (6)$$

式中 $k = 1, 2, \dots, N/2^j$; $j = 1, 2, \dots, J$; N 是 $y(t)$ 采样点数。根据式(6)可以得到系统冲激响应在不同尺度下的能量分布矢量 E_1, E_2, \dots, E_J , 其具有不受瞬态信号时移的影响,抗干扰能力强等优点,经归一化后可以作为故障特征矢量。

3 诊断实例

采用文献[10]中的电路对DAG-SVM、DT-SVM和本文提出的GADT-SVM3种算法的故障诊断性能进行比较。实验电路如图2所示。




图2 实验电路图


表1 系统状态参数设置

状态编号	系统状态	系统参数						
		$R_1/k\Omega$	$R_2/k\Omega$	$R_3/k\Omega$	$R_4/k\Omega$	$R_5/k\Omega$	C_1/nF	C_2/nF
1	正常状态	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	[4.75,5.25]	[4.75,5.25]
2	C_2 偏大	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	[4.75,5.25]	[5.25,7.875]
3	R_2 偏小	[4.921,5.439]	[4.475,0.95]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	[4.75,5.25]	[4.75,5.25]
4	R_4 偏大	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[2.1,3.15]	[3.8,4.2]	[4.75,5.25]	[4.75,5.25]
5	R_5 短路	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	0	[4.75,5.25]	[4.75,5.25]
6	C_1 击穿	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	$+\infty$	[4.75,5.25]
7	C_2 偏小	[4.921,5.439]	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	[4.75,5.25]	[2.375,4.75]
8	R_1 断路	$+\infty$	[0.95,1.05]	[3.8,4.2]	[1.9,2.1]	[3.8,4.2]	[4.75,5.25]	[4.75,5.25]


系统在 s 域内的传递函数为:

$$H(s) = \frac{R_2 R_4 C_1 (R_3 + R_5)}{R_1 R_2 R_4 R_5 C_1 C_2 + (R_2 R_4 R_5 C_1 + R_1 R_2 R_5 C_2 + R_1 R_2 R_5 C_1 - R_1 R_4 R_3 C_1)s + (R_1 + R_2)R_5 s^2}$$


其参数集 $P = \{R_1, R_2, R_3, R_4, R_5, C_1, C_2\}$ 。与文献[11]的故障设置不同，本文同时考虑了硬故障和软故障状态。规定参数容差范围为5%；超过正常值的100%以上为硬故障状态，此类故障往往导致系统拓扑结构发生改变；低(高)于参数容差下(上)限50%为软故障状态，此类故障不会改变系统拓扑结构，但会引起系统性能改变。




a. 正常状态




b. C₂偏大




c. R₂偏小




d. R₄偏大




e. R₃短路



f. C₁击穿



g. C₂偏小




h. R₁断路


图3 系统在不同状态下的冲激响应

为了简便，本文仅设置了包括正常状态在内的8种运行状态进行实验，如表1所示。在表1设定的区间范围内，系统各参数服从均匀分布。输入 $U_i(t) = \delta(t)$ ，用Pspice对表1设置的每种系统状态分别进行了100次蒙特卡洛仿真实验，取其均值得到系统在8种不同状态下的冲激响应分别如图3a~图3h所


示。由图可见,当系统发生硬故障时,其冲激响应比较容易区分(如图3e、图3f、图3g、图3h所示);当系统发生软故障时,其冲激响应有可能非常近似而难于识别(如图3a、图3b、图3c和图3d所示)。



a. DAG-SVM结构



b. DT-SVM结构



c. GADT-SVM结构

图4 DGA-SVM、DT-SVM、GADT-SVM决策树结构图

在每类状态中,任取50组数据作为训练样本,另50组数据作为测试样本。采用db3小波对样本数据

进行10级小波分解,并按前面介绍的方法提取小波系数的能量分布作为故障特征。这样,可以将样本的原始空间压缩到10维的特征空间,大大降低了SVM训练和分类的复杂度。

以表1中的状态编号代表各故障状态,分别用DAG-SVM方法、DT-SVM方法和本文介绍的GADT-SVM方法对不同的故障状态进行学习。其中,DAG-SVM和DT-SVM中的决策节点可以任意选择。本文采用的DAG-SVM、DT-SVM结构如图4a、图4b所示;图4c是经GADT-SVM优化后生成的决策树结构。由图可见,GADT-SVM很好地将8类状态样本按其可区分的难易程度进行了划分。为了便于比较,以上3种分类方法每个节点的二值SVM分类器均采用径向基核函数: $K(x_i, x_j) = \exp(-|x_i - x_j|^2 / \sigma^2)$, 其参数 $\sigma = 5$ 。

训练结束后,用3种SVM多分类器分别对各类测试样本进行诊断识别,诊断结果如图5~图7所示。

	1	2	3	4	5	6	7	8
1	42	5		3				
2	2	39					5	4
3			35		8		7	
4	2		5	41				2
5					49	1		
6						50		
7				4			46	
8								50

图5 DAG-SVM诊断结果(分类正确率88%)

	1	2	3	4	5	6	7	8
1	37	7		3			6	
2	8	35					7	
3	2		38	1	3		2	4
4	2	5		40		1	2	
5	1	1			48			
6					1	49		
7							50	
8						1		49

图6 DT-SVM诊断结果(分类正确率86.5%)

图中每一行对应一类样本,每一列显示样本被诊断为某一系统状态的次数,如图5第1行显示第1类样本被正确诊断为状态1的次数42次,被误诊为状态2的次数5次,被误诊为状态4的次数3次。图中错

分样本数用黑体显示, 阴影区代表难于识别的状态所属模糊组, 其中状态1、2组成模糊组 $\Phi_{1,2}$, 状态3、4组成模糊组 $\Phi_{3,4}$ 。以阴影区覆盖诊断结论的次数与总的诊断次数的比值作为模糊组误差控制能力的指标, 表2显示了3种方法中对诊断误差的控制能力。

	1	2	3	4	5	6	7	8
1	45	5						
2	7	43						
3			42	8				
4	2		11	39				
5			1		49			
6						50		
7				2			48	
8								50

图7 GADT-SVM诊断结果(分类正确率91.5%)

由图5~图7可见, 对于5、6、7、8类容易分辨的故障状态, 3种SVM多分类方法均给出了正确率较高的诊断结论; 但对于难于分辨的状态1和状态2以及状态3和状态4, DAG-SVM和DT-SVM由于结构没有进行优化, 其误诊结论往往偏离真实情况很远(表现为错分样本脱离阴影区, 且散布很广), 误差积累现象严重; 本文采用的方法由于对决策树结构进行了优化, 大大降低了误差积累的影响, 其误诊结论很好地控制在了可容许的范围内(表现为误诊结论集中在阴影区范围内)。表2定量地比较了3种诊断方法的误差控制能力。

表2 3种SVM诊断方法对误差的控制能力比较

模糊组	DAG-SVM	DT-SVM	GADT-SVM
$\Phi_{1,2}(\%)$	88	87	100
$\Phi_{3,4}(\%)$	83	88	100

4 结 论

本文采用GADT-SVM方法实现了模拟电路的故障诊断, 用传递函数对模拟电路进行建模; 利用小波分解提取电路冲激响应的能量分布作为故障特征样本; 用GADT-SVM对故障特征样本进行模式识别, 给出了诊断结论。仿真结果证明, 对决策树结构进行优化后, GADT-SVM的诊断结果比传统的DAG-SVM和DT-SVM具有更好的误差控制能力, 对软故障可以提供更精确的诊断结论。

参 考 文 献

- [1] 王 承, 陈光, 谢永乐. 基于主元分析与神经网络的模拟电路故障诊断[J]. 电子测量与仪器学报, 2005, 19(5): 14-18.
WANG Cheng, CHEN Guang-ju, XIE Yong-le. Fault diagnosis in analog circuits based on principal component analysis and neural networks[J]. Journal of Electronic Measurement and Instrument. 2005, 19(5): 14-18.
- [2] HSU C W, LIN C J. A comparison of methods for multi-class support vector machine[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [3] PLATT J C, CRISTIANINI N, SHAWE T J. Large margin DAGs for multiclass classification[J]. Advances in Neural Information Processing Systems, 2000, 12(3): 547-553.
- [4] FUMITAKE T, SHIGEO A. Decision tree-based multiclass support vector machines[C]//Proceedings of the 9th International Conference on Neural Information Processing. [S.l.]: [s.n.], 2002: 1418-1422.
- [5] 孟媛媛, 刘希玉. 一种新的基于二叉树的 SVM 多类分类方法[J]. 计算机应用, 2005, 25(11): 2653-2657.
MENG Yuan-yuan, LIU Xi-yu. A new SVM multiclass classification based on binary tree[J]. Journal of Computer Applications, 2005, 25 (11): 2653-2657.
- [6] 连 可, 黄建国, 王厚军, 等. 一种基于遗传算法的 SVM 决策树多分类策略研究[J]. 电子学报, 2008, 36(8): 1502-1507.
LIAN Ke, HUANG Jian-guo, WANG Hou-jun, et al. Study on a GA-based SVM decision-tree multi-classification strategy[J]. Acta Electronica Sinica, 2008, 36(8): 1502-1507.
- [7] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2000.
BIAN Zhao-qi, ZHANG Xue-gong. Pattern recognition [M]. Beijing: Tsinghua University Press, 2002.
- [8] SPINA R, UPADHYAYS S. Linear circuit diagnosis using neuromorphic analyzer[J]. IEEE Trans Circuits Syst II, 1997, 44: 188-196.
- [9] MALLAT S. A wavelet tour of signal processing[M]. San Diego, CA: Academic, 1999.
- [10] AMINIAN M, AMINIAN F. Neural-network based analog-circuit fault diagnosis using wavelet transform as preprocessor[J]. IEEE Transaction on Circuits and Systems, 2000, 47(2): 151-156.
- [11] 连 可, 王厚军, 龙 兵. 基于 SVM 的模拟电子系统多故障诊断研究[J]. 仪器仪表学报, 2007, 28(6): 1029-1034.
LIAN Ke, WANG Houjun, LONG Bing. Study on SVM-based analog electronic system multiple fault diagnosis[J]. Chinese Journal of Scientific Instrument, 2007, 28(6): 1029-1034.

编 辑 漆 蓉