

· 自动化技术 ·

最小生成树SVM的模拟电路故障诊断方法

宋国明^{1,2}, 王厚军¹, 姜书艳¹, 刘红^{1,3}

(1. 电子科技大学自动化工程学院 成都 610054; 2. 成都电子机械高等专科学校计算机工程系 成都 610031;

3. 长春理工大学计算机学院 长春 130022)

【摘要】提出最小生成树的支持向量机模拟电路故障诊断方法,通过小波分解提取电路故障特征,在特征空间中以故障类的可分性测度为权值构造最小生成树,得到具有聚类属性的故障子类划分,从而优化故障决策树节点的分布。按照最小生成树的结构建立具有较大分类间隔的多分类支持向量机,能够有效地提高模拟电路故障诊断的正确率。该方法简化支持向量机的结构,在实例电路的故障诊断中获得更高的诊断精度和效率,其性能优于常用的支持向量机方法。

关键词 故障诊断; 最小生成树; 可分性测度; 支持向量机

中图分类号 TP183; TN707

文献标识码 A

doi:10.3969/j.issn.1001-0548.2012.03.018

Fault Diagnosis Approach for Analog Circuits Using Minimum Spanning Tree SVM

SONG Guo-ming^{1,2}, WANG Hou-jun¹, JIANG Shu-yan¹, and LIU Hong^{1,3}

(1. School of Automation Engineering, University of Electronic Science and Technology of China Chengdu 610054;

2. Department of Computer Engineering, Chengdu Electromechanical College Chengdu 610031;

3. School of Computer Science and Technology, Changchun University of Science and Technology Changchun 130022)

Abstract A fault diagnosis approach for analog circuits based on minimum spanning tree (MST) support vector machine (SVM) is proposed. Fault features of analog circuits are extracted by wavelet analysis method. By taking separability measure of fault classes as weights of edges in feature space, the MST is generated and the sub-class separation for fault groups with clustering property is achieved. The node distribution of fault decision tree is then optimized. Hierarchical multi-class SVMs with large margins are constituted according to the structure of MST, which can effectively improve the fault diagnosis accuracy of analog circuits. The presented approach simplifies the structure of multiclass SVMs. Case study shows that our approach achieves more precision and higher efficiency comparing with other conventional SVM methods in analog circuit fault diagnosis.

Key words fault diagnosis; minimum spanning tree; separability measure; support vector machine

模拟电路故障诊断理论和方法的研究是近30年电路测试领域研究的热点,由于模拟电路是较复杂的非线性系统,采用常规方法对其建立模型和分析比较困难。随着人工智能技术和现代信号处理技术的发展,神经网络及小波分析的模拟电路故障诊断方法得到广泛的应用^[1-2],并取得较好的效果。然而,当故障类别较多、特征数据维数较高时,由于神经网络的结构复杂使其稳定训练收敛速度比较慢,而且容易收敛到局部极小点。此外,普遍采用的梯度下降法在调节网络参数使目标函数达到最小时,会导致神经网络产生过学习而降低其推广能力,使其

应用受到局限。

支持向量机(SVM)作为一种新型的机器学习方法,以结构风险最小化为原则,具有出色的小样本学习能力和较好的推广能力,在处理样本的非线性和高维模式识别方面也具有优势。近年来,支持向量机理论在模拟电路故障诊断中的应用也得到较多研究^[3-7]。由于支持向量机是针对两分类问题提出的,而模拟电路的故障诊断属于多分类问题,需采用某种策略将多个两类分类器组合起来实现多分类,常用的方法包括“一对其余”(1-a-r)SVM、“一对一”(1-a-1)SVM^[3-6]和决策有向无环图

收稿日期: 2010-07-21; 修回日期: 2010-12-03

基金项目: 部级科研项目; 国家自然科学基金(60971036); 中央高校基本科研业务费专项资金(ZYGX2009J071)

作者简介: 宋国明(1972-),女,博士生,副教授,主要从事模拟电路的测试与故障诊断、智能信息处理、模式识别等方面的研究。

(DDAG)SVM^[7]。上述方法中,若要完成 k 分类问题,1-a-1和DDAG SVM方法需构造 $k(k-1)/2$ 个SVM,而1-a-r法需 k 个。当故障模式的数量增加时,SVM数目将急剧增加,不仅使故障诊断系统的结构复杂化,而且随着训练和决策速度变慢,使诊断效率降低。分类精度方面,1-a-r和1-a-1方法在决策时,可能存在测试样本属于多类或不属于任何一类的不可分区域,使分类精度下降;而DDAG SVM的缺点是根节点的选择直接影响分类结果,容易产生“误差积累”,分类性能并不稳定,往往达不到最优。

为了减少训练和分类阶段所需SVM数目,提高分类效率,研究人员还提出了基于二叉决策树的多分类SVM(DT-SVM)^[8-9],通过子类分割建立SVM的二叉树层次决策模型。通常有两种分割方式:一种是在每个内节点处,由一个类与剩下的类构造分割面;另一种是在内节点处,可以是多个类与多个类的分割。但是二叉树的结构并不唯一,若要获得较高的分类精度,决策树结构的选择十分关键,但通过穷举每种二叉树结构来选择分类精度最优的决策树将非常繁杂而且计算量很大,不实用。

本文提出一种基于最小生成树(MST)SVM的分级决策故障诊断方法,通过小波分析提取待测电路在各频带的能量故障特征,在故障特征空间中以样本类别的可分性测度为权值构造最小生成树,确定故障子类划分的决策树结构,并建立SVM的多分类组合策略,实现多类别模式的故障诊断。由于MST生成算法的引入,在故障决策树中先分离可分性测度较大(分类间隔较大)的故障子类,避免了不可分故障区域,有效地提高了故障分类的准确率。实验表明,该方法可优化SVM组合的决策树结构,在故障诊断精度和效率上比传统的1-a-r、1-a-1、DDAG SVM和DT-SVM故障诊断方法具有更优的性能。

1 支持向量机

支持向量机(SVM)是一种以结构风险最小为原则的机器学习算法,与传统分类器最小化经验训练误差不同,支持向量机通过寻找最优超平面,使两类样本具有最大分类间隔来最小化推广误差的上界,从而获得更好的推广能力。现对其基本原理进行简要介绍。

对于 L 个样本对构成的数据集 $\{x_i, y_i\}_{i=1}^L$, $x_i \in R^n$, $y_i \in \{+1, -1\}$,SVM的目的是设计一个超平面 $g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0$,将所有的训练样本正确分类。具有最大间隔的超平面,可以使分类的误差最小,

因此最优分类面的构造即为求解下列问题:

$$\begin{aligned} \min L(\mathbf{w}) &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t. } y_i(\mathbf{w} \cdot \Phi(x_i) + b) &\geq 1 - \xi_i, \xi_i \geq 0 \\ & i = 1, 2, \dots, L \end{aligned} \quad (1)$$

在上述目标函数中,通过非线性函数 Φ 将训练样本 x_i 从低维输入空间映射到高维特征空间, C 为自定义可调的惩罚参数,表示对分类错误的惩罚程度。通过最小化 $\frac{1}{2} \|\mathbf{w}\|^2$,可获得超平面的最大间隔。

为了减少线性不可分情况下的训练误差,定义非负的松弛向量 ξ_i ,用于构建超平面的软边界。对于给定测试向量 \mathbf{x} ,将按下式进行分类:

$$\begin{aligned} f(\mathbf{x}) &= \text{sgn}(\mathbf{w} \cdot \Phi(\mathbf{x}) + b) = \\ & \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i \Phi(x_i) \cdot \Phi(\mathbf{x}) + b \right) \end{aligned} \quad (2)$$

式(2)将测试样本 \mathbf{x} 分为两类,若 $f(\mathbf{x})=+1$,则 \mathbf{x} 属于正类;若 $f(\mathbf{x})=-1$,则 \mathbf{x} 属于负类。

根据泛函理论用满足Mercer条件的内积函数 $K(x_i, \mathbf{x})$ 来代替某一变换空间的内积 $\Phi(x_i) \cdot \Phi(\mathbf{x})$,则非线性SVM的分类决策函数为:

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, \mathbf{x}) + b \right) \quad (3)$$

式中, α_i 为用二次规划所得的Lagrange系数; $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 。

单个支持向量机只能解决二分类问题,对于多分类问题,需要采用相应的机制将多个SVM进行组合来实现。模拟电路的故障诊断属于多分类问题,针对传统SVM多分类方法的局限,根据故障特征的空间分布情况,寻求一种优化的SVM组合策略,避免不可分故障区域的出现,对提高故障诊断的正确率和效率具有重要的意义。

2 最小生成树SVM的模拟电路故障诊断方法

2.1 最小生成树

考虑具有 n 个顶点和 m 条边的无向简单图(无环无多重边的图称为简单图) $G=(V, E)$,其中 $V = \{v_1, v_2, \dots, v_n\}$ 为顶点集合, $E = \{e_1, e_2, \dots, e_m\}$ 为连接各顶点边的集合。若边 e_k 的两个端点为 i 和 j ,则边 e_k 可记为 (i, j) ,边 (i, j) 的权值记为 $w(i, j)$ 且 $w(i, j)$ 为非负的实数。在 G 的所有生成树中,所有边的权值之和最小树称为 G 的最小生成树(MST),也称为最优树。最小生成树记为 $T^* = (V, E_{T^*})$ 。

最小生成树问题是一个经典的组合优化问题,

在解决实际应用中的聚类分析、最优信息传递路径、数据存储约简等方面，是一种有效的工具^[10-12]。本文用最小生成树的Kruskal算法^[10]来解决多分类问题中子类的划分。该算法通过将图G的m条边按权值的递增顺序排列，在执行的每步总是将权值最小且不形成回路的边添加到最小生成树中，直到找到n-1条边加到树T*为止。其中，m表示边的条数，n表示节点的个数。




图1 五分类的连通图G




图2 图G的最小生成树T*




图3 五分类的最小生成树SVM

对于k分类问题，设 $S = \{S_i\}_{i=1}^k$ 是各类的特征样本数据集， S_i 为包含了n个数据样本的一个子类。在S的基础上，定义一个有权边的无向图 $G(S)=(V, E)$ ，其中 $G(S)$ 的顶点集 $V=\{S_i | S_i \in S\}$ ，边的集合 $E=\{(S_i, S_j) | S_i, S_j \in S, i \neq j\}$ 。无向图 $G(S)$ 具有k个顶点和将每对顶点相连的 $k(k-1)/2$ 条带权边，表示了k类数据间空间分布的拓扑关系， $G(S)$ 的每个顶点对应数据样本的一个类别。图1为表征五分类问题的连通图 $G(S)$ ，图2为按照Kruskal算法生成的最小生成树 T^* 。通过采用最小生成树算法，用迭代的方式对最相近的类进行分组聚类，根据各类在最小生成树中节点的分布关系，得到相应的SVM二叉树组合策略。图3为根据图2的最小生成树结构所建立的二叉树多分

类支持向量机，称为最小生成树SVM(MST-SVM)。

2.2 类的可分性测度

在无向连通图中，边的权值反映了两个顶点的距离。对于多分类问题时，边的权值描述了两个类之间的空间分布情况及可分离性(或相似性)。权值的定义方法有多种，各种距离测度如欧氏距离、马氏距离和切比雪夫距离等，是度量各类特征子集的可分离性或相似性的测度，本文采用类间重心距离和散度作为类间的距离测度。

1) 重心距离: 类 S_i 的重心 μ_i 定义为 S_i 中所有样本向量的平均值，即:

$$\mu_i = \frac{1}{n} \sum_{x_j \in S_i} x_j \quad (4)$$

类 S_p 和类 S_q 的重心距离为其重心 μ_p 与 μ_q 之间的欧氏距离:

$$d_{pq} = \|\mu_p - \mu_q\| \quad (5)$$

当以重心距离作为类间的可分性测度时，边 $e_{(p,q)}$ 的权值为 d_{pq} 。

2) 散度: 散度不仅考虑类间的距离，还考虑每类样本数据的方差。散度的计算公式为:

$$sm_{pq} = \frac{\|\mu_p - \mu_q\|}{\sigma_p + \sigma_q} \quad (6)$$

式中， σ_p 和 σ_q 分别为类 S_p 、 S_q 的方差。按照散度的定义可知，类间距离越大，方差越小，两类的可分离性会越强。

2.3 MST-SVM多分类算法

分级决策SVM多分类器的最小树生成是一个自底向上的递归过程，构建用于实现k分类的最小生成树SVM多分器的算法步骤如下:

1) 将k类数据的每一类作为图 $G(S)$ 的顶点，按照式(5)或式(6)计算每条边的权值。这样就得到一个具有k个顶点和 $k(k-1)/2$ 条赋权边的图 $G(S)=(V, E)$ 。2) 对所有的边以权重升序的方式排列。3) 将每个顶点 V_i 对应的集合 S_i 加入到树 T^* 作为树的叶节点。令 $i=1, j=1$ 。4) 若 $i=k-1$ ，则输出多分类的最小生成树 T^* ，转步骤8); 否则转步骤5)。5) 按边的权值顺序取第j条边，若该边的顶点在不相交的集合 S_p 和 S_q 中，向树 T^* 中添加一个节点。其中定义在 S_p 中的顶点为正类，在 S_q 中的顶点为负类，新节点的左分枝必须指向 S_q 包含的节点，而右分枝指向包含 S_p 的节点。6) 合并集合 S_p 和 S_q ，令 $S_p = S_p \cup S_q$ ，然后移除 S_q 。7) 更新i和j的值，使 $i=i+1, j=j+1$ ，转步骤4)。8) 根据输出的最小生成树 T^* 的层次结构，构造 $k-1$ 个支持向量机 $SVM_1, SVM_2, \dots, SVM_{k-1}$ ，其中 SVM_i 为第i个节点所

对应的SVM分类器。由每个节点所对应的正类数据集 S_p 和负类数据集 S_q 可构成 $k-1$ 个训练样本集, 并得到 $k-1$ 个决策函数 $f_1(x), f_2(x), \dots, f_{k-1}(x)$ 。分类时, 从根节点子分类器开始对测试样本进行决策, 根据输出结果送入相应节点的SVM子分类器, 直至得出测试样本所属的类别。

2.4 模拟电路故障诊断的MST-SVM方法

MST-SVM的模拟电路故障诊断方法为: 首先获取电路各类故障的特征样本; 然后按照式(5)或式(6)计算各故障类间的可分性测度作为无向图边的权重, 按2.3节的算法获得MST的故障子类分割决策树, 按树的结构建立多分类SVM, 用各个决策节点对应故障类的样本构成训练样本集, 对每个SVM进行训练, 记录每个SVM的训练参数; 最后用所得的MST-SVM对测试特征样本进行故障诊断。由于小波分析的特征提取方法在模拟电路的故障诊断中十分有效^[1-2,4-5], 因此本文通过对被测电路不同故障模式输出响应信号进行 N 层小波分解, 计算第 N 层低频系数和 $1\sim N$ 层高频系数的能量^[5], 构建 $N+1$ 维的电路特征样本 $\{E_1, E_2, \dots, E_{N+1}\}$ 。其中, E_1 为第 N 层的低频系数的能量, $E_2\sim E_{N+1}$ 分别为第 N 层至第1层小波高频系数的能量。

3 仿真实验

本文采用Sallen-Key带通滤波器电路^[1-2,5]作为模拟电路诊断对象来验证本文方法的有效性, 电路结构及元件的标称值如图4所示。电路中各元件的正常容差为标称值的 $\pm 5\%$ 。以下实验均在PC机(奔腾1.6 GHz, 1 GB内存)上的ORCAD10.5和Matlab7.0环境下完成。




图4 Sallen-Key带通滤波器电路

3.1 故障模式及故障特征提取

由于模拟电路中单故障较为常见, 故只考虑电路中的元件发生单故障的情况。设置电路中有7个故障元件: 5个电阻($R_1\sim R_5$)和两个电容($C_1、C_2$)。故障值比标称值减少或增加50%, 共有14类故障模式, 加上电路正常状态(故障代码为 F_0), 共有15种电路状态, 相应的故障类及代码如下:

F_0 为正常状态; F_1 为 $R_1-50\%$; F_2 为 $R_1+50\%$; F_3 为 $R_2-50\%$; F_4 为 $R_2+50\%$; F_5 为 $R_3-50\%$; F_6 为 $R_3+50\%$; F_7 为 $R_4-50\%$; F_8 为 $R_4+50\%$; F_9 为 $R_5-50\%$; F_{10} 为 $R_5+50\%$; F_{11} 为 $C_1-50\%$; F_{12} 为 $C_1+50\%$; F_{13} 为 $C_2-50\%$; F_{14} 为 $C_2+50\%$ 。

对电路的正常状态和故障状态分别进行仿真, 实验中电路某一时刻只设置一个元件故障, 其余元件参数在容差范围内变化, 而正常状态时所有元件参数在各自的容差范围内变化。激励信号为脉宽 $10\ \mu\text{s}$ 、幅值为 $5\ \text{V}$ 的单脉冲信号, 对脉冲响应的输出电压信号在 $0\sim 100\ \mu\text{s}$ 进行均匀采样, 获得1000个数据点。利用Haar小波对所获得的数据进行5层小波分解, 获得相应的6维小波故障特征向量 $\{E_1, E_2, E_3, E_4, E_5, E_6\}$ 。

对每种故障模式进行150次Monte-Carlo分析, 可得150个故障特征样本, 其中50个样本作为训练样本, 另外100个作为测试样本, 则用750个样本构成训练集, 1500个样本构成测试集。

3.2 MST-SVM分类器的构造

针对15种故障类型, 可得到具有15个顶点和105条边的无向图。用每类故障的训练样本, 按照式(5)和式(6)定义的距离测度计算图中各边的权重, 按照第2节所述的MST-SVM生成算法, 可得到故障诊断的SVM决策树。图5为按照式(6)定义的散度为边的权重测度生成的MST-SVM的拓扑结构图。




图5 以散度为距离测度生成的MST-SVM拓扑结构图

图5中, 节点 T_i 代表1个SVM分类器, 总共构造14个SVM子分类器。节点的序号代表了分类器生成的先后顺序, 处于较低层次的节点较早生成, 包含的故障子类也较少; 根节点最后生成, 包含了所有的故障类。以式(5)定义的重心距离作为无向图各边的权重时, 得到的MST-SVM结构与图5略有不同, 但是对故障子类划分大致相似, 只是在分割的层次

顺序稍有差别。

3.3 故障诊断

按照所建立的MST-SVM多分类器模型,选择高斯函数 $K(\mathbf{x}, x_i)=\exp(-\gamma|\mathbf{x}-x_i|^2)$ 作为各SVM子分类器的核函数,根据各节点对应的故障类型,选取该子类的故障特征构成训练样本集进行训练。训练时,对故障特征样本进行标准化预处理,使其具有零均值和标准方差;按照交叉验证的方法选择每个SVM子分类器的参数,选择使验证集的精度最高的支持向量机参数。为了使多分类支持向量机具有更优的分类性能,每个SVM子分类器可以选择不同的参数。对训练完毕的各个SVM分类器按MST的层次关系组合,对测试集的故障特征样本进行诊断。

为了比较不同SVM故障诊断方法的性能,本节用传统SVM方法(1-a-r、1-a-1和DDAG)与在内节点处每次只分割出一类的二叉决策树SVM方法(DT-SVM)对15类故障进行诊断。为了便于比较,4种方法的基本SVM均采用高斯核函数,参数选择为: $\gamma=5$,惩罚参数 $C=1\ 000$ 。

表1 各种SVM方法的故障诊断结果

	1-a-r	1-a-1	DT-SVM	MST-1	MST-2
F_0	82	92	93	96	96
F_1	93	94	98	99	100
F_2	94	95	98	96	96
F_3	100	100	100	100	100
F_4	78	80	84	89	89
F_5	100	100	100	100	100
F_6	100	100	100	100	100
F_7	100	100	100	100	100
F_8	98	98	98	98	98
F_9	100	100	100	100	100
F_{10}	98	100	100	100	100
F_{11}	99	99	100	100	100
F_{12}	100	100	100	100	100
F_{13}	97	100	100	100	100
F_{14}	90	86	85	88	88
正确率/(%)	95.27	96.27	97.07	97.73	97.8

表1列出了用5种方法对1 500个测试样本进行诊断的结果,表中所示为每类故障正确诊断的样本数及总体诊断正确率。表中,MST-1和MST-2分别表示按以重心距离和散度为测度生成的两种MST-SVM。实验中1-a-1和DDAG的故障诊断结果相同,因此只列出1-a-1的诊断结果。

从表1看到,本文算法虽然采用不同的可分性测度生成最小生成树,每个故障类的分割顺序不一样,但构成的MST-SVM对15种故障诊断的结果却非常

接近,分别为97.73%和97.8%,在5种故障诊断方法中故障诊断正确率最高,效果最好。基于决策树的SVM故障诊断方法优于1-a-r和1-a-1,但因未考虑各故障类特征样本的空间分布特点,未对子类的分割顺序优化,因此其诊断精度低于MST-SVM方法。1-a-r和1-a-1的故障诊断正确率较低,其中1-a-r的故障诊断正确率最低,在5种方法中误诊断的样本数最多,这是因为当故障的模式较多时,构造的分类面较其他方法复杂,更容易出现不可分故障区域。

3.4 效率分析

下面从训练和分类的复杂度来比较本文方法与4种SVM方法的故障诊断效率。表2列出了实验中每种方法需训练的SVM个数($\#SVM_{\text{train}}$)故障分类时需遍历SVM的平均个数 $\#SVM_{\text{test}}$ 、故障分类所需的支持向量数($\#SVs$, u-SVs)、训练时间 T_{train} 和测试时间 T_{test} 。其中 $\#SVs$ 为每种SVM分类器的支持向量个数总和, u-SVs (unique SVs)为不相同的支持向量个数,由于一个训练样本可能会是多个SVM中的支持向量,在分类测试阶段,对于相同的支持向量 x_i 与测试样本 \mathbf{x} 的核函数值 $K(x_i, \mathbf{x})$ 只需计算一次,从而可以减少测试时间。训练时间和测试时间以程序运行的CPU时间为准,采用Matlab自带的计时工具记录。

表2 各种SVM故障诊断方法的训练及诊断效率比较

	1-a-r	1-a-1	DDAG
$\#SVM_{\text{train}}$	15	105	105
$\#SVM_{\text{test}}$	15	105	14
$\#SVs$	562	455	455
u-SV	348	219	219
T_{train} /s	12.09	2.42	2.42
T_{test} /s	0.22	0.42	0.15
	DT-SVM	MST-SVM1	MST-SVM2
$\#SVM_{\text{train}}$	14	14	14
$\#SVM_{\text{test}}$	7.5	4.8	5
$\#SVs$	976	621	701
u-SV	308	305	309
T_{train} /s	3.45	1.99	2.05
T_{test} /s	0.16	0.12	0.12

由表2可见, MST-SVM在训练和故障分类时所需的SVM个数最少,而在训练时样本数也随着树的高度逐级减少,因而具有较快的训练速度;在测试时并不需要计算所有的二值分类器,而是按照最小生成树的结构对各类故障分级诊断,分类时所需遍历SVM的平均个数也最少,因此测试时间比其他4种算法少,分类的效率最高。

综上所述, 最小生成树SVM方法不仅具有较高的故障诊断精度, 还提高了故障诊断的效率, 在类型较多的故障诊断中具有明显的优势, 是模拟电路故障诊断的有效方法。

4 结 论

在模拟电路的多故障诊断中, 支持向量机的多分类扩展策略对故障诊断的准确率和效率十分重要。本文在分析传统支持向量机多分类方法优劣的基础上, 引入最小生成树算法用于构建故障分级决策的SVM, 将决策树节点的故障子类分割问题转化为求取最小生成树, 并得到具有聚类属性的故障子类划分, 从而优化故障决策树的节点排布及SVM的组合策略, 以提高分类的性能。仿真实验中, 用小波分析方法提取被测电路的故障特征, 按照两种可分性测度构建了最小生成树SVM, 用14个SVM分类器实现对Sallen-Key滤波器电路15种单软故障的诊断。与其他几种常用的SVM多分类方法比较, 本文方法所构造的SVM结构简单, 具有更高的故障诊断精度和效率, 总体性能优于传统的支持向量机方法。

参 考 文 献

- [1] AMINIAN F, AMINIAN M. Fault diagnosis of analog circuits using Bayesian neural networks with wavelet transform as preprocessor[J]. Journal of Electronic Testing, 2001, 17(1): 29-36.
- [2] AMINIAN F, AMINIAN M, COLLINS H W, et al. Analog fault diagnosis of actual circuits using neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(3): 544-550.
- [3] SIWEK K, OSOWSKI S, MARKIEWICZ T. Support vector machine for fault diagnosis in electrical circuits[C]// Proceedings of the 7th Nordic Signal Processing Symposium. Reykjavik, Iceland: IEEE, 2006, 7: 342-345.
- [4] LONG Bing, HUANG Jian-guo, TIAN Shu-lin. Least squares support vector machine based analog circuit fault diagnosis using wavelet transform as preprocessor[C]// International Conference on Communications, Circuits and Systems. Fujian: IEEE, 2008, 5: 1026-1029.
- [5] 孙永奎, 陈光福, 李辉. 基于自适应小波分解和SVM的模拟电路故障诊断[J]. 仪器仪表学报, 2008, 29(10): 2105-2109.
SUN Yong-Kui, CHENG Guang-ju, LI Hui. Analog circuit diagnosis method using adaptive wavelet analysis and SVM [J]. Chinese Journal of Scientific Instrument, 2008, 29(10): 2105-2109.
- [6] LI Hua, ZHANG Yong-xin. An algorithm of soft fault diagnosis for analog circuit based on the optimized SVM by GA[C]//The Ninth International Conference on Electronic Measurement & Instruments. Beijing: IEEE, 2009, 4:1023-1027.
- [7] WANG An-na, LIU Jun-fang, WU Jie. Research on soft fault diagnosis algorithm of analogy circuits based on DDAGSVMs[C]//Proceeding of the 2007 IEEE International Conference on Integration Technology. [S.l.]: IEEE, 2007, 3:499-503.
- [8] FEI B, LIU J. Binary tree of SVM: a new fast multiclass training and classification algorithm[J]. IEEE Transactions on Neural Networks, 2006, 17(3): 696-704.
- [9] VURAL V, DY J G. A Hierarchical method for multi-Class support vector machines[C]//Twenty-First International Conference on Machine Learning. [S.l.]: [s.n.], 2004: 831-838.
- [10] AHUJA R K, MAGNANTI T L, ORLIN J B. Network flows :theory, algorithm, and applications (English Version) [M]. Beijing: Mechanical Industry Press, 2005: 510-536.
- [11] 肖俊, 庄挺越, 吴飞. 基于层次细节与最小生成树的三维地形识别与检索[J]. 软件学报, 2003, 14(11): 1955-1963.
XIAO Jun, ZHUANG Ting-yue, WU Fei. Recognition and retrieval of 3D terrain based on level of detail and minimum spanning tree[J]. Journal of Software, 2003, 14(11): 1955-1963
- [12] 李朝健, 李朝鹏, 李肯立. 基于最小生成树的并行分层聚类算法[J]. 微电子学与计算机, 2008, 25(9): 196-198.
LI Zhao-jian, LI Zhao-peng, LI Ken-li. An adaptive parallel hierarchical clustering algorithm without memory conflicts[J]. Journal of Microelectronics & Computer, 2008, 25(9): 196-198.

编辑 漆 蓉