

文章编号: 1001-0920(2009)09-1416-05

基于交叉熵方法和支持向量机的模拟电路故障诊断

唐静远, 师奕兵, 周龙甫, 张 伟

(电子科技大学 自动化工程学院, 成都 610054)

摘 要: 针对故障诊断系统中存在的大量无关或冗余的特征会严重影响故障诊断性能的缺陷, 提出了基于交叉熵和支持向量机方法进行特征选择和参数优化的故障诊断方法. 首先以某种概率分布产生若干随机样本, 并依据交叉熵最小原理建立分布参数的更新规则进行特征搜索和 SVM 参数优化; 然后利用优化后的特征向量和参数训练支持向量机获得故障诊断模型. 故障诊断实验结果表明, 该故障诊断方法能有效地优化故障特征和模型参数, 提高故障诊断性能.

关键词: 故障诊断; 特征选择; 模拟电路; 交叉熵方法; 支持向量机

中图分类号: TN707

文献标识码: A

Analog circuit fault diagnosis based on cross-entropy method and support vector machine

TANG Jing-yuan, SHI Yi-bing, ZHOU Long-fu, ZHANG Wei

(School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China. Correspondent: TANG Jing-yuan, E-mail: tangjingyuan0001@126.com)

Abstract: Considering that many irrelevant or redundant features in fault diagnosis system seriously spoil the fault diagnosis performance, a fault diagnosis method based on the cross-entropy method and support vector machine is proposed. Firstly, a population of random variable samples is generated by some kinds of probability distribution, and the object value of the samples is evaluated by using SVM classifiers. Parameter-updating rule of distribution parameters is established based on min-cross-entropy theory. After several iterations, the best object feature subset and optimized parameters are selected out. Then the CEM-SVM model of the circuit fault diagnosis system is built by training the SVM with optimized features and parameters. Finally, analog circuit fault diagnosis experiment on leapfrog filter shows the effectiveness of feature selection and parameters optimization of the proposed method which improve the fault classification rate and the speed fault diagnosis time.

Key words: Fault diagnosis; Feature selection; Analog circuit; Cross-entropy method; Support vector machine

1 引 言

由于模拟电路故障现象多样、元件参数具有较大的离散性、有限的可及测试节点与广泛的非线性等原因, 致使模拟电路故障诊断无论在理论上还是在方法上均距实用还有相当的距离. 模拟电路故障诊断本质上是分类问题, 而支持向量机 (SVM) 具有在小样本下即可获得满意的学习效果和保证所求解为全局最优解等优点. 因此基于 SVM 分类方法具有较好的分类应用价值, 已广泛应用于模拟电路故障诊断^[1,2], 并获得了较好的实际效果.

在实际的故障诊断中, 采集的故障数据中往往

包含很多与故障信息不相关的变量信息. 这些变量会严重影响 SVM 的分类性能, 同时过多的变量也增加了计算量, 导致实时性变差. 可行的解决方法是利用主成分分析 (PCA) 等特征提取算法进行数据处理, 达到特征提取和降维. 但有时为了获得足够的信息, 当系统本身具有很多变量时, PCA 方法所得的主元也会很多, 而过多的主元同样会将大量非故障信息带入, 从而降低故障诊断性能. 本文提出一种基于交叉熵方法的特征变量选择和 SVM 参数优化算法, 改善基于 SVM 方法的模拟电路故障诊断系统的性能.

收稿日期: 2008-10-10; 修回日期: 2009-01-08.

基金项目: 教育部新世纪优秀人才支持计划项目 (NCET-05-0804); 国家 863 计划项目 (2006AA06Z222).

作者简介: 唐静远 (1974—), 男, 四川蓬安人, 博士生, 从事模拟电路测试及可测性设计的研究; 师奕兵 (1964—), 男, 重庆人, 教授, 博士生导师, 从事 VLSI 和电子系统的计算机辅助测试、电子测量仪器等研究.

2 交叉熵方法概述

交叉熵方法 (CEM) 是一种优化方法,最先用于模拟小概率事件,后来扩展到求解最优化问题^[3].交叉熵方法近年已广泛应用到许多组合优化问题的求解中,并针对不同的应用领域设计了求解算法^[4-6].此外,该方法也应用于连续多目标优化和机器学习等领域的一些实际问题中.

交叉熵方法的基本思想是首先将优化问题同与其相关的概率估计问题关联起来,优化问题为

$$S(X^*) = \min_x S(X). \quad (1)$$

在上定义一组概率密度函数 $\{f(X, v), v \in V\}$ 和指示函数 $\{I_{I(S(X))}(x)\}$,对某个 $u \in V$,式(1)优化问题的相关估计问题为

$$l(v) = P_u(S(X) \leq u) = \int_{-\infty}^u I_{I(S(X))}(x) f(X, v) dx = E_u I_{I(S(X))}(x). \quad (2)$$

当式(2)中 $l(v)$ 取值接近最优解时,概率 l 的值会非常小, $S(X) \leq u$ 为一小概率事件.直接用 Monte Carlo 方法求解式(2),需要有足够大的样本数量.为此引入重要采样 (IS) 密度 $g(x)$,则式(2)变为参数估计式

$$l = \frac{1}{N} \sum_{i=1}^N I_{I(S(X_i))}(X_i) \frac{f(X_i; v)}{g(X_i; v)}, \quad (3)$$

其中 X_i 是根据 $g^*(x; v)$ 生成的样本.为求得最优的 IS 密度 $g^*(x; v)$,需通过优化参数 v ,从分布族 $\{f(X; v)\}$ 中选取 $g^*(x; v)$,使 $f(X; v)$ 与 $g^*(x; v)$ 之间的交叉熵(即 Kullback-Leiber 距离)最小.对于两个分布密度函数 $g(x)$ 和 $h(x)$,他们之间的交叉熵为

$$D(g, h) = E_g \ln \frac{g(x)}{h(x)} = \int g(x) \ln g(x) dx - \int g(x) \ln h(x) dx. \quad (4)$$

使 $f(X; v)$ 与 $g^*(x; v)$ 交叉熵最小的等价式为

$$\min_v D(v) = \min_v E_u I_{I(S(X))}(x) \ln f(X; v). \quad (5)$$

交叉熵方法采用了一个多级更新算法,即构造一个分布参数序列 $\{v_t, t = 0, 1, \dots\}$ 和一个级序列 $\{t_i, i = 1, 2, \dots\}$,因此式(5)可变为

$$\min_v D(v) = \min_v E_{v_{t_i}} I_{I(S(X))}(x) \ln f(X; v), \quad (6)$$

$$\min_v D(v) = \min_v \frac{1}{N} \sum_{i=1}^N I_{I(S(X_i))}(x) \ln f(X_i; v). \quad (7)$$

式(7)为(6)的参数估计形式.

3 基于 CEM-SVM 的特征选择和参数优化

SVM 基于结构风险最小化原理,将数据映射到高维空间,通过使分类间隔最大化进行分类,具有良好的泛化能力,可以避免“过拟合”,特别在处理高维

数据时具有良好的性能. SVM 虽然可以有效地处理高维数据,但是 Barzilay 等^[7]在特征选择之后使用 SVM 作为分类器,识别效果得到显著的提高.特征选择过程可以看作是机器学习领域中的求组合全局优化问题;Mao 等^[8]利用遗传算法 (GA) 同时进行特征选择和高斯核 SVM 的参数优化,并应用于基于微矩阵癌症分类问题,实验表明该方法能够选出高分类率的基因序列;Tu 等^[9]利用粒子群算法 (PSO) 和 Kernel-Adatron 算法进行特征选择和训练 SVM,取得了很好的分类效果.本文提出基于交叉熵方法进行特征选择和 SVM 参数优化的 CEM-SVM 算法,并将其应用于模拟电路故障诊断.下面重点阐述几个重要内容和算法的具体实现:

(1) 样本编码及其概率分布的选择

根据特征选择的特点,将每一个特征定义为候选解的一维离散二进制变量,变量长度就等于所有特征的数量,如果第 i 位为 1,则第 i 个特征就被选中,否则该特征就被屏蔽.假设各变量被选中的事件相互独立, x_i 服从 Bernoulli 分布,并设分布参数为 p_i , p_i 表示第 i 个变量被选中的概率.因此对于特征选择变量的样本,可以构造一个分布参数为 $p = \{p_1, p_2, \dots, p_n\}$ 的 n 维 Bernoulli 分布密度函数 $f(x; p)$,然后根据 $f(x; p)$ 生成随机的 x 序列样本,有

$$f(x; p) = \prod_{i=1}^n p_i^{x_i} (1 - p_i)^{1 - x_i}. \quad (8)$$

由式(8)可得其概率更新公式为

$$p_{it} = \frac{\sum_{k=1}^N I_{I(S(X_k))}(x_k) x_{it}}{\sum_{k=1}^N I_{I(S(X_k))}(x_k)}, \quad i = 1, 2, \dots, n. \quad (9)$$

其中: p_{it} 是第 t 次迭代中求得的第 i 个变量被选中的概率, N 是样本数.本文采用基于高斯核的 C-SVM,优化参数为误差惩罚参数 C 和高斯核宽度 γ .对于 SVM 中需要优化的参数 C 和 γ ,采用基于正态概率分布对其采样,训练中需要更新参数是样本分布概率 $N(\mu, \sigma^2)$ 中的均值 μ 和方差 σ^2 .

(2) 目标函数的选择

目标函数用来评价所选特征变量和优化参数的表现,即选中的特征变量和参数在模拟电路故障诊断中表现的性能.特征子集和参数优化选择的目的是使用少量的特征达到相同或更好的分类效果,因此目标函数应包含两部分内容:

- 1) 故障诊断的正确率.使用特征子集中确定的特征和选择的参数来训练分类器,用交叉验证结果来评价分类器的性能,并指导 CEM 的更新.
- 2) 使用的特征数量.每个特征子集包含一定数



量的特征,如果两个特征子集的准确度相同,则包含特征比较少的子集被选中.

在准确率和特征数量这两个因素中,需要重点考虑准确率,因此目标函数确定形式为

$$S(x_{id}) = M(1 - S(id)) + p \times \frac{m_c}{m_{all}} \quad (10)$$

其中: $S(x_{id})$ 为最终目标函数; $S(id)$ 为 SVM 正确分类率; m_c 为选中的变量数; m_{all} 为系统采集数据的全部变量数; M, p 为调节参数,平衡最大正确分类率与变量个数,根据具体的系统变量数和故障诊断要求设置,本文取 $M = 100, p = 5$.

算法的具体实现如下:

Step1: 初始化. 最大迭代次数为 $iter_max$; 概率分布为 p_0 ; 样本数为 N ; 分位数为 α ; 整数为 d ; 光滑因子为 λ ; 光滑参数为 q, μ_0, σ_0 ; 收敛参数为 tol . 令 $t = 0$.

Step2: 令 $t = t + 1$; 根据式(8)生成 N 个随机样本 X 的特征变量部分的样本,根据 $N(\mu_{t-1}, \sigma_{t-1}^2)$ 分布生成 N 个随机样本 X 的 SVM 优化参数 C 和 γ 部分的样本; 根据特征变量样本选择训练集和验证集的特征变量,利用选择的参数和变量训练多类支持向量机(本文采用一对一多分类支持向量机 $o-v-o$ SVM); 求出所有样本的目标函数值 S^t , 并按从小到大排列 $S^t_{(1)}, S^t_{(2)}, \dots, S^t_{(N)}$, 令 XX 表示 $N^{elite} = [* N]$ 个最好性能的样本集, $\hat{\mu}_t = S^t_{(* N)}$.

Step3: 按式(9)对特征变量的分布概率 p 进行更新.

Step4: 按下面步骤对 SVM 的参数变量进行更新:

- 1) 计算集合 X 中的平均均值和方差,即

$$\begin{aligned} \mu_{ji} &:= \frac{1}{i} \sum_{XX} X_{ij} / N^{elite}, \\ \sigma_{ji}^2 &:= \frac{1}{i} \sum_{XX} (X_{ij} - \mu_{ji})^2 / N^{elite}, \end{aligned} \quad (11)$$

其中 $j = 1, 2$ 分别表示参数 C 和 γ 样本概率分布的均值和方差.

- 2) 计算动态光滑因子,即

$$\lambda_t = \lambda - \left(1 - \frac{\lambda}{t}\right)^q \quad (12)$$

- 3) 对参数进行光滑化,即

$$\begin{aligned} \mu_t &:= \mu_t - (1 - \lambda_t) \mu_{t-1}, \\ \sigma_t^2 &:= \sigma_t^2 - (1 - \lambda_t) \sigma_{t-1}^2. \end{aligned} \quad (13)$$

Step5: 判断终止条件,若

$$\begin{aligned} \max(|\hat{\mu}_t - \hat{\mu}_{t-1}|, |\hat{\sigma}_t - \hat{\sigma}_{t-1}|, \\ \dots, |\hat{\mu}_{t-d+1} - \hat{\mu}_{t-d}|) < tol, \\ t = 1, 2, \dots, iter_max, \end{aligned}$$

则迭代结束;否则,返回 Step2.

4 基于 CEM-SVM 的模拟电路故障诊断

一个高效的故障诊断系统,应该能够及时判断出或检测出系统发生了故障并正确判断所发生的故障类型. 基于 CEM 和 SVM 故障诊断的基本思想是: 采集原始信号,对经过预处理后的信号进行故障特征提取,构成特征集;然后将特征集数据划分为训练集、验证集和测试集 3 部分,并运用训练和验证集进行基于 CEM 的特征选择和参数优化学习,输出最优特征和参数训练后的故障分类模型;最后用测试集数据检测 CEM-SVM 故障诊断系统的分类性能. 故障诊断的流程如图 1 所示.

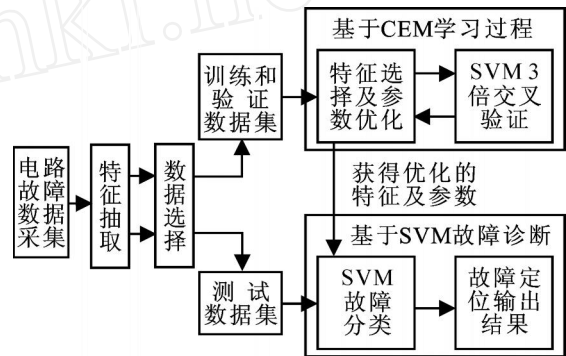


图 1 基于 CEM-SVM 特征选择参数优化框图

下面以国际标准电路(跳蛙滤波器电路^[10,11])为诊断实例,验证本文所提出故障诊断方法的可行性和有效性. 跳蛙电路结构及参数如图 2 所示. 参数故障设置采用文献[10]中的 ± 6 方式;故障设置为单参数故障 4 类: $C_1 \pm 6, C_3 - 6$ 和 $C_2 + 6$; 双参数故障 6 类: $(C_1 - 6 \ \& \ C_2 + 6), ((C_2 \ \& \ C_1) - 6), ((C_1 \ \& \ C_3) - 6), ((R_7 \ \& \ R_8) + 6), (R_8 + 6 \ \& \ R_9 - 6)$ 和 $((R_7 \ \& \ R_9) + 6)$; 三参数故障 2 类: $(C_1 + 6 \ \& \ C_2 + 6 \ \& \ C_3 - 6), (R_7 - 6 \ \& \ R_8 - 6 \ \& \ R_9 - 6)$; 四参数故障 2 类: $(R_{10} + 6 \ \& \ R_{11} + 6 \ \& \ C_1 - 6 \ \& \ C_2 - 6), (R_{12} \ \& \ R_{13} \ \& \ C_3 \ \& \ C_4) + 6$; 加上正常状态,实验中共有 15 种状态. 电路中电阻元件正常容差为标称值的 2%,电容元件正常容差为标称值的 4%. 选取测试信号 V_{in} 分段线性电压 VPWL(0, 0, 10 us, 5 v, 2 ms, 5 v). 利用 PsPice 软件对电路在各种故障状态和正常状态分别进行 50 次 Monte Carlo 仿真,在输出节点 out 采集的电压信号作为各个故障模式的原始特征. 实验中 ORCAD 版本号为 10.5; 在 Pspice 仿真(采样)时间 0.2 ms 内采集 200 个样本, Pspice 仿真类型为时域瞬态仿真; Pspice 仿真默认温度 27, 其他仿真条件均采用 Pspice 默认设置.

首先对原始数据进行 3 层 Haar 小波和 DB4 小波分解,抽取各频率段的最大系数、最小系数和平均




图 2 国际标准电路——跳蛙滤波器

系数作为故障特征,这样每个样本共获得 24 维故障特征. 然后选择一半故障数据进行训练, 其余一半数据用于测试. 在训练阶段采用 3 倍交叉验证. 实验中初始化取值如下:

$$\begin{aligned} \text{iter_max} &= 20, \quad p_0 = \frac{1}{2} \text{ones}(1, 24), \\ N &= 50, \quad \sigma = 0.1, \quad d = 5, \quad \gamma = 0.7, \quad q = 5, \\ \mu_0 &= 5 + 5 \times \text{rand}(1, 2), \\ \sigma_0^2 &= 100 \times \text{ones}(1, 2), \quad \text{tol} = 0.05. \end{aligned}$$

应用本文提出的基于 CEM-SVM 特征选择和参数优化方法进行跳蛙滤波电路故障诊断, 并与几种不同故障诊断方法结果进行比较. 实验结果如表 1 所示.

表 1 几种故障诊断方法结果比较

	训练正确率/ %	测试正确率/ %	最优特征数
σ -v-o SVM	75.0	73.0	24
PCA-SVM	78.0	75.0	16
GA-SVM	88.0	87.0	10
PSO-SVM	84.0	83.5	10
CEM-SVM	87.5	86.3	10

从表 1 可以看出, 经过优化特征选择和参数优化的方法明显取得比未经特征选择或经 PCA 特征约简的方法更好的故障诊断结果; σ -v-o SVM 和主成分支持向量机 (PCA-SVM) 的故障诊断平均准确率均小于 80%, 而进行了特征选择和参数优化的其他 3 种故障诊断方法诊断平均正确率都在 83% 以上, 充分体现了特征选择和参数优化对故障诊断性能的改善.

特征选择过程中各个特征变量被选中的概率分布随迭代次数进化的关系如图 3 所示. 第 1 行表示初始阶段 24 个特征变量都可能有 50% 概率被选取作为故障特征, 第 8 行表示本方法经过 8 次迭代后以近 100% 的概率选出的 10 个最优特征变量分别

为原特征向量的第 1, 3, 4, 5, 11, 15, 17, 19, 22, 24 个分量. 本方法同时找出优化的误差惩罚参数为 115.4, 高斯核宽度参数为 24.8, 故障诊断训练正确率达到 87.5%, 测试正确率达到 86.3%.




图 3 基于 CEM 特征变量概率分布进化图

将本文方法与基于进化算法的特征选择和参数优化方法 GA-SVM 和 PSO-SVM 进行比较, 实验结果显示, 3 种方法应用于跳蛙滤波器电路故障诊断都能正确选出分类正确率达 83% 以上的 10 个优化特征变量. 图 4 给出了 3 种算法的目标函数随迭代次数的关系图. 从图 4 可以看出, 基于 CEM-SVM 方法收敛速度最快而且获得了与 GA-SVM 方法相近的故障诊断结果; GA-SVM 方法收敛速度最慢, 但获得了最好的优化结果; 而 PSO-SVM 获得的分类效果最差. 结果显示本文方法能够以较小的代价获得好的故障诊断效果.




图 4 3 种特征选择及参数优化方法性能

5 结 论

本文研究了基于交叉熵和支持向量机的模拟电路故障诊断方法, 利用交叉熵最小原理进行故障特征选择和支持向量机的参数优化, 将获得的最优特征子集和参数训练支持向量机分类器进行模拟电路各种工作模式的分类, 完成故障决策. 通过实验可以

看出,该故障诊断方法能够有效地去掉冗余和无关特征,减少了特征数量,结合优化的参数可以提高比 PSO-SVM 方法更好的故障诊断正确率和更快的诊断速度;相比 GA-SVM 方法可以用较少的诊断时间达到相近的优化诊断结果.将特征选择方法与重采样技术、分类器集成等方法相结合用于模拟电路故障诊断是进一步的研究内容.

参考文献(References)

- [1] Wang A, Liu J, Wang H, et al. A novel fault diagnosis of analog circuit algorithm based on incomplete wavelet packet transform and improved balanced binary-tree SVMs[J]. *Bio-Inspired Computational Intelligence and Applications*, 2007: 482-493.
- [2] 孙永奎, 陈光福, 李辉. 基于可测性分析和支持向量机的模拟电路故障诊断[J]. *仪器仪表学报*, 2008, 29(6): 1182-1186.
(Sun Y K, Chen G J, Li H. Fault diagnosis method for analog circuit based on testability analysis and support vector machine[J]. *Chinese J of Scientific Instrument*, 2008, 29(6): 1182-1186.)
- [3] Rubinstein R Y, Kroese D P. The cross-entropy method: A unified approach to combinatorial optimization[M]. *Monte-Carlo simulation and machine learning*. New York: Springer, 2004.
- [4] Rubinstein R Y. The cross-entropy method and rare events for maximal cut and bipartition problems [J]. *ACM Trans on Modeling and Computer Simulation*, 2002, 12(1): 27-53.
- [5] Alon G, Kroese D P, Raviv T. Application of the cross-entropy method to the buffer allocation problem in a simulation-based environment[J]. *Annals of Operations Research*, 2005, 134(1): 137-151.
- [6] Kroese D P, Sergey P, Rubinstein R Y. The cross-entropy method for continuous multi-extremal optimization [J]. *Methodology and Computing in Applied Probability*, 2006, 8(3): 383-407.
- [7] Barzilay O, Brailovsky V L. On domain knowledge and feature selection using a support vector machines[J]. *Pattern Recognition Letters*, 1999, 20(5): 475-484.
- [8] Mao Yong, Zhou X B, Pi D Y, et al. Parameters selection in gene selection using gaussian kernel support vector machine by genetic algorithm[J]. *J of Zhejiang University Science*, 2005, 6(10): 961-973.
- [9] Tu C J, Chuang L Y, Chang J Y, et al. Feature selection using PSO-SVM [J]. *Int J of Computer Science*, 2007, 33(1): 111-116.
- [10] Kaminska B, Arabi K, Bell I, et al. Analog and mixed-signal benchmark circuits: First release [C]. *Proc of the Int Test Conf*. Washington DC, 1997:183-190.
- [11] Roh J, Abraham J A. Sub-band filtering for time and frequency analysis of mixed-signal circuit testing[J]. *IEEE Trans on Instrumentation Measurement*, 2004, 53(2): 602-611.

(上接第 1415 页)

- [3] Hong Seong Park. Bandwidth allocation scheme for cyclic-service fieldbus networks [J]. *IEEE Trans on Machatronics*, 2001, 6(2): 197-204.
- [4] Hong Seong Park, Yu Chul Kim. Implementation of a bandwidth allocation scheme in a token-passing fieldbus network [J]. *IEEE Trans on Instrumentation and Measurement*, 2002, 51(2): 246-251.
- [5] Park H S, Kim Y H, Kim D-S, et al. A scheduling method for network-based control systems [J]. *IEEE Trans on Control Systems Technology*, 2002, 10(3): 318-330.
- [6] Zhang W, Branickym S, Philips S M. Stability of networked control system [J]. *IEEE Control Systems Magazine*, 2001, 21(1): 84-99.
- [7] 彭晨, 岳东. 网络环境下基于网络 QoS 的网络控制器优化设计[J]. *自动化学报*, 2007, 2(33): 214-217.
(Peng C, Yue D. Network-based optimal controller design based on QoS[J]. *Acta Automatica Sinica*, 2007, 2(33): 214-217.)
- [8] Martin Andersson, Dan Henriksson, Anton Cervin. True-time 1. 4 reference manual [EB/OL]. <http://www.control.lth.se/dan/truetime/>, 2006-07.
- [9] Jane W S Liu. Real-time systems[M]. Beijing: Higher Education Press Arrangement with the Original Publisher, 2002: 195-218.
- [10] 唐应辉, 唐小我. 排队论基础与分析技术[M]. 北京: 科学出版社, 2006: 57-61.
(Tang Y H, Tang X W. Analysis technical of queue theory[M]. Beijing: Press of Science, 2006: 57-61.)