

基于粒子群算法优化支持向量机的模拟电路诊断*

胡云艳¹, 彭敏放¹, 田成来¹, 谭虎¹, 宋丽伟¹, 沈美娥²

(1. 湖南大学 电气与信息工程学院, 长沙 410082; 2. 北京信息科技大学, 北京 100101)

摘要: 为了提高支持向量机网络(SVM)进行模拟电路诊断的准确率,提出了一种基于粒子群(PSO)算法和支持向量机的诊断方法。该方法首先对被测电路的响应信号进行多小波变换,通过归一化处理得到分类能力强的最优故障特征;然后用粒子群算法优化支持向量机的结构参数,实现对不同故障模式分类识别。仿真结果表明,此方法能有效提高模拟电路故障诊断准确率。

关键词: 故障诊断; 模拟电路; 粒子群优化; 多小波变换; 支持向量机

中图分类号: TP391 **文献标志码:** A **文章编号:** 1001-3695(2012)11-4053-03

doi:10.3969/j.issn.1001-3695.2012.11.013

Analog circuit fault diagnosis based on particle swarm optimization SVM

HU Yun-yan¹, PENG Min-fang¹, TIAN Cheng-lai¹, TAN Hu¹, SONG Li-wei¹, SHEN Mei-e²

(1. College of Electrical & Information Engineering, Hunan University, Changsha 410082, China; 2. Beijing University of Information Science & Technology, Beijing 100101, China)

Abstract: In order to improve the accuracy of analog circuit fault diagnosis using support vector machine (SVM) network, this paper proposed the method based on particle swarm optimization(PSO) and SVM. It preprocessed the response signals of the analog circuit using multiwavelet transform and obtained the optimal fault feature with better classification capacity using energy normalization. Then, after training the SVM by PSO, inputted the features into the ensemble SVM to identify different fault cases. Simulation results indicate that this method can effectively enhance the analog fault diagnosis accuracy.

Key words: fault diagnosis; analog circuit; particle swarm optimization(PSO); multiwavelet transform; support vector machine(SVM)

近年来,随着智能信息处理技术在模拟电路故障诊断领域的应用,模拟电路智能诊断的研究也不断深入,研究者们提出了许多智能故障诊断方法^[1-6],取得了优于传统诊断方法的诊断效果。但由于模拟电路自身的特点,如响应的连续性、器件的容差和电路的非线性等原因,使得这些方法离广泛应用尚有一定差距。

模拟电路智能诊断大多包含故障特征的提取和故障模式的分类及识别两个步骤。在故障特征提取方法中,多小波变换能够克服小波变换的维数灾等缺陷,有效地降低特征空间维数,从而减小分类和识别算法的计算量,提高其分类识别能力。在故障模式分类和识别方面目前主要采用神经网络、支持向量机等,相对而言,神经网络的研究比较深入。神经网络虽然因很多优点而备受关注,但仍然存在如训练时间比较长、局部最优等问题,且由于神经元所选择的激励函数的支撑集是无穷大的,其非正交性使得网络收敛速度迅速减慢^[1-7]。支持向量机能有效地解决小样本、高维数、非线性等学习问题,并能克服人工神经网络学习合理结构难以确定和存在局部最优等缺点,大大地提高了学习方法的泛化能力。但模型参数和结构难以设置,严重影响了故障诊断的速度与准确率。粒子群优化(PSO)算法是近年来发展的一种新的基于群体智能的优化算法,该算法通过个体之间的协作搜索空间中的最优解,其概念更简单、

参数更少、更容易实现。本文提出了采用粒子群算法优化支持向量机的模拟电路诊断方法。

1 应用多小波变换的特征提取

多小波变换的思想是在单小波的基础上通过伸缩和平移变换得到的。它克服了单小波的缺陷,能够同时兼具正交性、正则性、高消失矩、紧支性等优良特征。并且多小波和多尺度函数都具有对称性,可使滤波器具有线性相位或广义线性相位,避免了重构产生的误差^[8]。与单小波相比,多小波在构造上更为灵活,当 $r \geq 2$ 时,多小波的尺度函数矢量和多小波函数矢量分别为

$$\varphi(t) = [\varphi_1(t), \varphi_2(t), \dots, \varphi_r(t)]^T \quad (1)$$

$$\phi(t) = [\phi_1(t), \phi_2(t), \dots, \phi_r(t)]^T \quad (2)$$

其中: $\varphi(t)$ 经过平移生成空间 V_i, V_i 同时满足 $\bigcup_{j=-\infty}^{+\infty} V_j = L^2(R)$,
 $\bigcap_{j=-\infty}^{+\infty} V_j = \{0\}, \dots, V_{-1} \subset V_0 \subset V_1 \dots V_{j-1} \subset V_j \subset \dots; \phi(t)$ 通过平移生成空间 W_i, W_i 是 V_i 的正交补空间。

多小波的两尺度函数方程可以表示为

$$\varphi(t) = \sum_{k \in \mathbb{Z}} H_k \varphi(2t - k) \quad (3)$$

$$\phi(t) = \sum_{k \in \mathbb{Z}} G_k \varphi(2t - k) \quad (4)$$

收稿日期: 2012-04-24; **修回日期:** 2012-05-30 **基金项目:** 国家自然科学基金资助项目(60673084, 60973032, 61173108); 湖南省自然科学基金资助项目(10JJ2045); 湖南省学位与研究生教育教改项目(JG2011C004)

作者简介: 胡云艳(1986-),女,湖北天门人,硕士研究生,主要研究方向为电路与系统测试、电气设备状态监测等(huyunyan12345678@163.com); 彭敏放(1964-),女,教授,博导,博士,主要研究方向为电路测试与诊断、电气设备状态监测、智能信息处理、电磁场理论及其应用等。

其中： G_k 和 H_k 都是 r 阶矩阵，分别为高通和低通滤波器序列；将单小波的 Mallat 算法加以推广，得到多小波的分解式为

$$C_{j-1,k} = \sqrt{2} \sum_{k \in Z} H_{n-2k} C_{j,n} \quad (5)$$

$$D_{j-1,k} = \sqrt{2} \sum_{k \in Z} G_{n-2k} C_{j,n} \quad (6)$$

其中： $C_{j-1,k}$ 是低通部分，称为尺度系数， $D_{j-1,k}$ 是高通部分，称为小波系数。

多小波重构的表达式^[9,10]为

$$C_{j,k} = \sum_{n \in Z} H_{n-2k}^T C_{j-1,k} + \sum_{n \in Z} G_{n-2k}^T C_{j-1,k} \quad (7)$$

本文采用 AMX2 多小波，利用它对响应信号进行三层多小波分解，提取各频段的能量

$$T = [E_3^0 \ E_3^1 \ E_3^2 \ E_3^3] \quad (8)$$

$$\text{总能量为} \quad E = \left(\sum_{j=0}^3 |E_3^j|^2 \right)^{\frac{1}{2}} \quad (9)$$

$$\text{归一化} \quad T' = \left[\frac{E_3^0}{E} \ \frac{E_3^1}{E} \ \frac{E_3^2}{E} \ \frac{E_3^3}{E} \right] \quad (10)$$

选择适当的多小波分解层数对故障特征提取至关重要。若分解层数过少，则得到的能量不能有效反映故障特征；若分解层数过多，则会导致冗余特征的增加，从而影响诊断精度和诊断效率。因此，为简单起见，多小波分解的层数设置为 3。

2 基于粒子群优化支持向量机的模拟电路故障诊断

模拟电路故障诊断的实质是对故障模式的分类识别，先对电路施加外部激励，用多小波变换提取电路故障特征，并归一化处理。处理后的故障特征分为测试和训练两部分。用粒子群算法优化支持向量机，得到最优结构参数。在训练的过程中用改进支持向量机对故障进行分类。训练完成后，输入测试样本，得到诊断结果。其诊断的结构如图 1 所示。

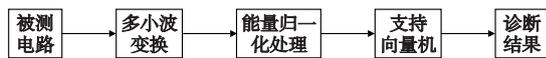


图 1 故障诊断算法结构

2.1 基于 SVM 的分类识别

支持向量机在解决小样本、非线性及高维模式识别中表现出许多特有的优势。其最初是用于二分类问题，但在实际应用中需要处理多类问题，因而需要把多类问题分解为多个两类问题，训练各个两类分类器来解决多分类问题。对于多分类问题，SVM 有三种分类方法，即一对一法、一对多法和决策导向无环图。通过比较这三类支持向量机的性能，其中一对一多分类组合 SVM 具有明显的优势。本文采用一对一法，每个分类器只能将一类与另一类分离，而不考虑其他类，SVM 求解 K 类问题共需要 $K(K-1)/2$ 个分类器。设样本集为 (x_i, y_i) ， $i=1, \dots, n, x \in R^d, y \in \{+1, -1\}$ ， d 为输入空间维数，SVM 在特征空间构造的最优分类超平面为

$$w \cdot k(x, x_i) + b = 0 \quad (11)$$

其中： $w = \sum_{i=1}^n a_i y_i k(x, x_i)$ ， w 为权向量， b 为偏置。SVM 的分类问题最终转换为如下二分类优化问题^[11-13]：

$$\min_{w, b, \xi} J_{LS}(w, \xi) = \|w\|^2/2 + (r/2) \sum_{i=1}^n \xi_i \quad (12)$$

$$\text{s. t.} \begin{cases} (w^j)^T k(x, x_i) + b^j \geq 1 - \xi_j & y_j = i \\ (w^j)^T k(x, x_i) + b^j \leq -1 + \xi_j & y_j = j \\ \xi_j \geq 0 & j = 1, \dots, n; j \neq i \end{cases} \quad (13)$$

其中： $\xi_i \geq 0$ 为松弛因子； C 为惩罚参数； w^j 是第 i 和 j 类的权重向量； b^j 是第 i 和 j 类的偏值； $k(x, x_i)$ 为数据空间映射到特征空间的核函数。最后得到决策函数为

$$f(x) = \text{sgn}(w^j k(x, x_i) + b^j) \quad (14)$$

在进行分类时，将测试样本分别输入到不同的支持向量机类型中，最后采用投票策略对结果进行投票，经过所有的决策函数判别后，哪一类得票数最多就认为属于那一类^[14]。

2.2 基于粒子群算法优化支持向量机方法的实现

粒子群算法^[15,16]的实质是模拟鸟群在飞行过程中整个鸟群都能保持完整的飞行队形，对应于要求解的最优问题，将待优化的参数当做整个空间的一个粒子。初始化一群随机粒子，然后粒子们根据自身经历的最好解及种群最好解来调整自身飞行速度及位置。PSO 是基于群体智能理论的优化算法，每个粒子代表解空间的一个候选解，解的优劣程度由适应度函数决定。假设在某个空间中，总共有 n 个粒子以一定的速度飞行，第 i 个粒子在 N 维空间的位置向量表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$ ，飞行速度表示为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iN})$ ，各个粒子记忆、追随当前的最优粒子，在解空间中搜索。粒子通过跟踪粒子本身所找到的最优个体极值 pbest 表示其位置，并在整个群体之中记录所有粒子经历过的最好全局极值点，用 gbest 表示其位置。在每次算法迭代中，粒子根据式 (15) 和 (16) 来更新自己的位置和速度。

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 \text{rand}_1(pbest_{id}^k - x_{id}^k) + c_2 \text{rand}_2(gbest_{id}^k - x_{id}^k) \quad (15)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (16)$$

其中： c_1 和 c_2 为加速系数，分别调节向全局最好粒子和个体最好粒子方向飞行的最大步长； rand_1 和 rand_2 为均匀分布在 $[0, 1]$ 内的随机数； ω 为惯性权重，维护全局和局部搜索能力的平衡。

具体算法如下：

a) 对待测电路进行 Monte Carlo 分析，使用多小波变换提取最优特征，进行归一化处理，将得到的特征向量分为测试和训练 SVM 两部分。

b) 初始化粒子群的种群和最大迭代次数。根据粒子位置确定训练样本和支持向量机参数，并对参数进行初始化，训练支持向量机。

c) 对每个粒子进行适应度评价，如果好于该粒子当前的最好位置的适应度，则更新 pbest；如果所有的粒子的最好位置的适应度好于当前全局最好位置的适应度，则更新 gbest，判断粒子群最大迭代次数和故障诊断率是否达到要求，如果是则转步骤 e)；否则转步骤 d)。

d) 调整粒子的速度和位置。

e) 在算法结束后，当前迭代次数达到预先设定的最大次数，则依据式 (11) 输出最终值。

f) 将测试样本输入已经训练好的 SVM 中，得到诊断结果。

g) 停止运算。

3 诊断实例与结果分析

仿真电路如图 2 所示。该电路为 25 kHz 带通滤波器，其中各元件的标称值均在图中标出，电阻电容的容差范围为标称值的 5%，带通滤波器的核心频率为 25 Hz，考虑电路中 R2、

R3、C1、C2 四个元件的故障。本文主要研究电路中无源元件发生故障时的情况。

分别对正常状态和故障状态(R2 ↓、R2 ↑、R3 ↓、R3 ↑、C1 ↓、C1 ↑、C2 ↓、C2 ↑)共八种状态进行诊断。所设置的故障类型如表 1 所示。其中,符号 ↓ 和 ↑ 表示比标称值小和比标称值大。↑ 表示相应故障模式对应的容差区间设置为[正常容差,50%], ↓ 表示相应故障模式对应的容差区间设置为[-50%,正常容差]。

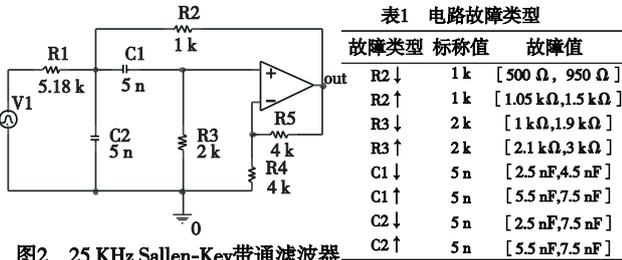


图2 25 KHz Sallen-Key带通滤波器

实验采用激励幅值为 5 V、脉宽为 10 μs 的单脉冲信号作为激励源。该电路只有输出点 V。为可测点,对该点电压的瞬态值作记录,对可测点电压进行多小波变换,应用 AMX2 多小波对采样信号进行三层分解,构造具有四个频带能量的特征向量,并对其归一化。使用 Pspice 对电路的不同故障情况进行 Monte Carlo 分析,得到 300 次数据作为样本,其中 100 次用于训练 SVM,200 次用于测试 SVM。数据样本如表 2 所示。

表2 三层多小波分解后响应信号各频段的能量归一化表

电路状态	E_0^0	E_1^1	E_2^2	E_3^3
无故障	0.30626923886	0.00000059892	0.91710006310	0.00000069912
C ₁ 正偏	0.35891323014	0.00000063051	0.96870124506	0.00000073021
C ₁ 负偏	0.29857607153	0.00000029899	0.50232491016	0.00000060874
C ₂ 正偏	0.20461520714	0.00000023216	0.79180267435	0.00000052360
C ₂ 负偏	0.36476148109	0.00000067794	0.94364871034	0.00000052499
R ₂ 正偏	0.40128371315	0.00000069182	0.94928193702	0.00000055432
R ₂ 负偏	0.39461508274	0.00000069038	0.92069918326	0.00000060331
R ₃ 正偏	0.49111328360	0.00000071250	0.99126431080	0.00000062495
R ₃ 负偏	0.41053084613	0.00000065201	0.95851536642	0.00000060261

为了验证该方法故障诊断的准确性和有效性,同时检验基于 PSO 优化的支持向量机的快速分类能力,分别用 SVM 网络与 PSO 优化后的 SVM 网络进行故障诊断,方法 1 是采用 SVM 在一定范围内按照一定的间隔取值来选取最优参数;方法 2 是采用 PSO-SVM,设定初始粒子个数为 30 个,学习因子 $C_1 = C_2 = 2$,惯性权值 $\omega = 0.8$,最大迭代数为 1 000。操作方法如下:首先用训练样本分别对网络进行训练,然后把测试样本输入网络进行分类识别。诊断结果如表 3 所示。

表3 PSO-SVM 与 SVM 方法诊断结果

诊断模型	故障诊断率/%	诊断时间/s
PSO-SVM	97.13	30.56
SVM	93.24	28.71

通过仿真可以看出,PSO-SVM 网络的故障诊断率为 97.13%,SVM 网络的故障诊断率为 93.24%,前者在故障准确率和效率上明显优于后者。传统的支持向量机网络在选择结构参数时都具有盲目性,均根据人工经验确定,所以得到的效果不是很理想;采用粒子群算法优化支持向量机后,SVM 网络

参数得到优化,大大提高了网络的分类能力。文献[16]中采用了同样的粒子群优化支持向量机方法,用小波变换提取故障特征,其故障诊断率达到 95% 左右。可见,本文诊断率高于传统方法的诊断结果。

4 结束语

本文基于粒子群优化算法和 SVM 网络并结合多小波变换,提出了一种基于 PSO-SVM 网络与多小波变换的模拟电路故障诊断方法。利用多小波变换提取有效的故障特征向量,减少了训练网络的规模;针对 SVM 网络模型结构和参数难以设置的缺点,结合 PSO 算法寻优能力和收敛能力较强的优点,采用 PSO 算法优化 SVM 网络,优化网络参数,提高了网络的泛化能力和学习能力。仿真结果表明,本文所提出的采用粒子群算法优化 SVM 网络的模拟电路故障诊断方法是有效的,该方法加快了网络的收敛速度和分类速度,提高了故障诊断的精度。

参考文献:

- [1] CATELANI M, FORT A. Soft fault detection and isolation in analog circuits: some results and a comparison between a fuzzy approach and radial basis function network[J]. IEEE Trans on Instrumentation and Measurement, 2002, 51(2): 196-202.
- [2] JALAT-EVAKILKANDI M, MIRZAEI B. A new hierarchical-clustering combination scheme based on scatter matrices and nearest neighbor criterions[C]//Proc of the 5th International Symposium on Telecommunications. 2010:904-908.
- [3] TASDEMIR K, MILENOV D, TAPSALL B. Topology-based hierarchical clustering of self-organizing maps[J]. IEEE Trans on Neural Networks, 2011, 22(3): 474-485.
- [4] 袁海英,陈光. 模拟电路的可测性及故障诊断方法研究[J]. 电子测量与仪器学报, 2006, 20(5): 17-20.
- [5] 彭敏放,沈美娥,何怡刚,等. 应用 RBF 网络和 D-S 证据推理的模拟电路诊断[J]. 电工技术学报, 2009, 24(8): 6-12.
- [6] 唐静远,师奕兵. 采用模糊支持向量机的模拟电路故障诊断新方法[J]. 电子测量与仪器学报, 2009, 23(6): 7-12.
- [7] 王淑娟,陈博,赵国良. 基于小波包变换预处理的模拟电路故障诊断方法[J]. 电工技术学报, 2003, 18(4): 118-122.
- [8] 宋国明,王厚军,姜书艳,等. 一种聚类分类决策的 SVM 模拟电路故障诊断方法[J]. 仪器仪表学报, 2010, 31(5): 998-1004.
- [9] 王海晖,彭嘉雄. 基于多小波变换的图像融合研究[J]. 中国图象图形学报, 2004, 9(8): 1002-1007.
- [10] 马超,陈西宏,徐宇亮,等. 基于支持向量机属性约简集成的模拟电路故障诊断[J]. 仪器仪表学报, 2011, 32(3): 660-666.
- [11] 王军峰,张维强,宋国乡. 模拟故障诊断的多小波神经网络算法[J]. 电工技术学报, 2006, 21(1): 33-36.
- [12] 孙永奎,陈光,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.
- [13] 唐静远,师奕兵,张伟. 基于支持向量机集成的模拟电路故障诊断[J]. 仪器仪表学报, 2008, 29(6): 1216-1220.
- [14] 孙永奎,陈光,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.
- [15] 王佩丽,彭敏放,杨易旻,等. 应用模糊最优小波包和 LS-SVM 的模拟电路诊断[J]. 仪器仪表学报, 2010, 31(6): 1282-1288.
- [16] 左磊,侯立刚,张旺,等. 基于粒子群-支持向量机的模拟电路故障诊断[J]. 系统工程与电子技术, 2010, 32(7): 1553-1556.