

基于 PSO-LSSVM 的模拟电路故障诊断

陈志凡¹, 单剑锋¹, 宋晓涛², 王文清¹

(1. 南京邮电大学 电子科学与工程学院, 江苏 南京 210003;

2. 太原理工大学 计算机科学与技术学院, 山西 太原 030024)

摘要:针对传统神经网络技术在模拟电路故障诊断应用中存在的问题,提出了一种基于粒子群(Particle Swarm Optimization, PSO)和最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)的模拟电路故障诊断方法。该方法先从一个滤波器系统的频率响应数据中提取由小波系数的均值、标准差和熵构成的频率小波特征向量来训练最小二乘支持向量机,之后再采用粒子群算法来优化支持向量机的结构参数,避免了参数选择的盲目性,进而提高了模型的诊断精度。在对 Elliptical Filter 电路进行的故障检测中,验证了该方法的可行性。

关键词:粒子群算法;最小二乘支持向量机;模拟电路;故障诊断

中图分类号:TP206.3

文献标识码:A

文章编号:1673-629X(2015)05-0209-05

doi:10.3969/j.issn.1673-629X.2015.05.049

Analog Circuit Fault Diagnosis Based on PSO-LSSVM

CHEN Zhi-fan¹, SHAN Jian-feng¹, SONG Xiao-tao², WANG Wen-qing¹

(1. School of Electronic Science and Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;

2. School of Computer Science and Technology, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: In order to solve the problem of fault diagnosis method for analog IC diagnosis based on neural network, the method based on Particle Swarm Optimization (PSO) and Least Squares Support Vector Machine (LSSVM) is proposed. Use wavelet feature vectors from frequency response data of a filter system which are composed of the mean, standard deviation and entropy of wavelet coefficients to train LSSVM. The parameters of LSSVM are optimized with PSO algorithm to improve the accuracy of fault diagnosis, avoiding the blindness of parameters selection. The Elliptical Filter is used for the faults simulation experiment, the results demonstrated feasibility of the proposed method.

Key words: particle swarm optimization; least square support vector machine; analog circuit; fault diagnosis

0 引言

半导体技术的飞速发展促进了模拟集成电路的广泛应用,同时对模拟电路测试和故障诊断提出了更高的要求,但由于模拟电路的非线性,电路中的元件的容差和电路响应的连续性,使得传统的电路故障诊断很难应用于实践中^[1]。随着神经网络、小波分析和支持向量机等不断发展与研究,这些人工智能技术也逐渐地运用在模拟电路故障诊断中^[2]。文献[3]提出了将 BP 神经网络和 Wiener 核相结合的模拟电路故障诊断方法,但是需要算出故障状态下的 Wiener 核,并用这 Wiener 核作为神经网络的特征参数,该方法计算难

度大,不易实行。在文献[4]中,作者将被测电路的故障响应信号不加任何预处理作为神经网络的输入,导致了一个很小的被测电路就需要一个很大的神经网络,并且获得的故障诊断率并不高。

支持向量机(Support Vector Machines, SVM)是由 Vapnik 等提出的一种基于统计理论学习上的机器学习算法。在故障诊断时能够有效地解决小样本、高维数和非线性等问题^[5]。最小二乘支持向量机(LSSVM)方法是在传统支持向量机的基础上通过转化得来的^[6],在训练过程遵循结构化风险最小化原则,且采用了二次损失函数,因此大大降低了计算复杂度,提

收稿日期:2014-06-24

修回日期:2014-09-26

网络出版时间:2015-04-22

基金项目:国家自然科学基金资助项目(GZ212015)

作者简介:陈志凡(1989-),男,硕士研究生,研究方向为智能信息处理;单剑锋,博士,副教授,研究方向为智能信息处理。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20150422.0950.002.html>

高了求解问题的速度。粒子群优化(PSO)算法属于进化算法(Evolutionary Algorithm, EA)的一个分支,最早由 Kennedy 和 Eberhart 于 1995 年提出^[7]。该算法是通过个体之间的协作搜索空间中最优解的一种新的群体智能的优化算法,易于实现。

文中结合粒子群和最小二乘支持向量机来对模拟电路进行故障诊断,先从频率响应曲线中得到小波系数的均值、标准差和熵作为频率小波特征向量,再利用粒子群算法的泛化学习能力优化支持向量机的参数,最后将训练好了的 LSSVM 模型用来模拟电路故障的诊断。

1 频率响应的小波特征

由于传统的频率特征,如中心频率和最大频率响应,只是频率响应曲线的局部点。文中提出了一组代表频率曲线全局参数的小波特征作为特征向量。在离散小波分析中,分别运用近似系数和细节系数将一个信号分解成低频分量和高频分量,这是通过原始小波(母小波)的移位和缩放来实现的。

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (1)$$

其中, $\psi(x)$ 是母小波; a, b 分别定义为缩放和移位的程度,系数展开 $C(a, b)$ 可以表示如下:

$$C(a, b) = \langle \psi_{a,b}(x), I(x) \rangle = \frac{1}{\sqrt{a}} \int I(x) \psi\left(\frac{x-b}{a}\right) dx \quad (2)$$

其中, $I(x)$ 表示信号,对所有可能的 x 进行积分; $C(a, b)$ 是判断式(1)中变换后的母小波和输入信号 $I(x)$ 的相关性。

在文献[8]中已经研究过小波变换系数能量指数作为特征来训练 LSSVM 分类。对于近似系数,特征向量可以定义如下:

$$FW_1 = [El_1, \dots, El_j, \dots, El_k] \quad j = 1, 2, \dots, k \quad (3)$$

$$El_j = \sum_i^n |ca_j(i)|^2 \quad (4)$$

其中, $ca_j(i)$ 表示第 j 阶分解的第 i 个近似系数; k 表示一个预定义分解层次。

对于细节系数,特征向量可以定义为:

$$FW_2 = [Eh_1, \dots, Eh_j, \dots, Eh_k] \quad j = 1, 2, \dots, k \quad (5)$$

$$Eh_j = \sum_i^n |cd_j(i)|^2 \quad (6)$$

其中, $cd_j(i)$ 表示第 j 阶分解的第 i 个细节系数; k 表示一个预定义分解层次。

由于能量指标方法不能提供较高的分类精度,因此文中采用新的方法来处理小波分解系数:即用每一阶分解层的平均值、标准差和熵来构造特征向量,以提

高分类的准确度。对于近似系数,特征向量可以定义如下:

$$FW_3 = [\mu_1, \mu_2, \dots, \mu_k, \sigma_1, \sigma_2, \dots, \sigma_k, e_1, e_2, \dots, e_k] \quad (7)$$

$$\mu_j = \frac{1}{n} \sum_i^n ca_j(i) \quad (8)$$

$$\sigma_j = \sqrt{E(ca_j(i) - \mu_j)^2} \quad (9)$$

$$e_j = - \sum_i^n P(ca_j(i) = a_i) \log P(ca_j(i) = a_i) \quad (10)$$

对于细节系数,特征向量可以定义如下:

$$FW_4 = [u_1, u_2, \dots, u_k, \gamma_1, \gamma_2, \dots, \gamma_k, \theta_1, \theta_2, \dots, \theta_k] \quad (11)$$

$$u_j = \frac{1}{n} \sum_i^n cd_j(i) \quad (12)$$

$$\gamma_j = \sqrt{E(cd_j(i) - u_j)^2} \quad (13)$$

$$\theta_j = - \sum_i^n P(cd_j(i) = a_i) \log P(cd_j(i) = a_i) \quad (14)$$

其中, $ca_j(i)$, $cd_j(i)$ 分别表示为近似和细节的第 j 阶分解第 i 个系数。

因为归一化后能够提高 LSSVM 分类精度,所以在模拟滤波电路中,频率特征向量在被用来训练 LSSVM 分类诊断之前先进行归一化,假设非归一化的特征向量是:

$$FV_0(i) = [f_1(i), f_2(i), \dots, f_j(i), \dots, f_m(i)] \quad (15)$$

其中, $i = 1, 2, \dots, n; j = 1, 2, \dots, m; n$ 是样本数; m 是样本特征数。

归一化方法是用相应的最大值归一化特征里所有的特征向量,定义如下:

$$FV_A(i) = \left[\begin{array}{cc} \frac{f_1(i)}{\max_i(f_1(i))}, & \frac{f_2(i)}{\max_i(f_2(i))}, \dots, \\ \frac{f_j(i)}{\max_i(f_j(i))}, & \frac{f_m(i)}{\max_i(f_m(i))} \end{array} \right]$$

2 基于 PSO-LSSVM 的电路故障诊断模型

2.1 构建 LSSVM 故障分类器

LSSVM 是一种新的 SVM 模式, LSSVM 的回归构造为:给定一个训练集 $\{x_i, y_i\}_{i=1}^l$, 其中 $x_k \in R^n$ 是第 k 个输入模式, $y_k \in R$ 是第 k 个输出模式, 定义用来分类的 LSSVM 方法的函数为:

$$f(x) = \text{sgn}(w \cdot \varphi(x) + b) \quad (16)$$

优化问题可以写为:

$$\min J(w, \xi) = \frac{1}{2} \|w^2\| + \frac{\gamma}{2} \sum_{i=1}^l \xi_i^2$$

$$\text{s. t. : } y_i = w^T \cdot \varphi(x_i) + b + \xi_i, \quad i = 1, 2, \dots, l \quad (17)$$

式中, $\varphi(x_i)$ 为输入空间到高维空间的非线性映射; γ 为正则化参数; ξ_i 为误差函数。

为了解决以上的优化问题,构造 Lagrange 函数:

$$L(w, b, \xi, \alpha) = J(w, \xi) - \sum_{i=1}^l \alpha_i \{w^T \varphi(x_i) + b + \xi_i - y_i\} \quad (18)$$

式中, $\alpha_i (\alpha_i \in R)$ 为 Lagrange 乘子。

对 $L(w, b, \xi, \alpha)$ 进行求导并消去 w, ξ_i , 得到线性方程组如下:

$$\begin{bmatrix} K + C^{-1}I & I \\ I^T & 0 \end{bmatrix} \begin{bmatrix} \alpha \\ b \end{bmatrix} = \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (19)$$

式中, $I = (1, 1, \dots, 1)^T$; $y = (y_1, y_2, \dots, y_l)^T$; $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_l)^T$; $K = \{K_{ij} = K(x_i, x_j)\}_{i,j=1}^l$ 是核矩阵, 其中 $K_{ij}(x, y)$ 是核函数, 函数描述如下:

$$K_{ij}(x, y) = \varphi(x_i)^T \cdot \varphi(y_j) \quad (20)$$

通过线性方程组(19)可求得 α_i 和 b , 可得到 LSSVM 的分类函数如下:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l \alpha_i K(x, x_i) + b \right\} \quad (21)$$

常用的核函数有三种,分别是径向基核函数、多项式核函数和 Sigmoid 核函数。文中采用径向基核函数作为 LSSVM 的核函数,其表达式为: $K(x, x_i) = \exp(-\frac{\|x - x_i\|^2}{2\sigma^2})$, 需要优化的参数有正规化参数 γ 和核函数 σ^2 。

式(21)用来故障分类的 LSSVM 函数可表示为 $f(x) = \text{sgn}\{h(x)\}$, 该函数的输出值只有 +1 和 -1, 可以用来实现两类分类问题。LSSVM 方法是通过将其对偶问题转化为求解线性方程组的问题,大大地降低了计算的难度,节省了时间,因此与传统支持向量机相比提高了训练速度。

实际应用中故障一般是多类,而传统的支持向量机只能解决两类分类问题,所以有必要重构 LSSVM 模型,用来解决多分类问题的 LSSVM 模型方法有一对一、一对多、二叉树等算法^[9]。

一对一算法的思想是对 k 种故障类别,需要构造 $k(k-1)/2$ 个两类 LSSVM 模型,每两类之间训练一个 LSSVM 来将彼此分开,预测新样本时,采取投票决策法,在每两个 LSSVM 间产生一个优胜者,然后在优胜者间一次进行比较,直至产生得票最多的优胜者。该方法的缺点是可能出现过学习。

一对多算法的思想是对 k 种类别,构造 k 个两类 LSSVM 模型,判别时,将测试的样本输入到这 k 个模型之中,若判别得出的结果为 1,则表明该类别就是预先设定的类别模式,如果不是,则 LSSVM 函数中 $h(x)$ 最大值代表其对应的类别。缺点是每次训练都要训练全

部样本。

基于二叉数的多类分类 LSSVM 是将所有类别划分直至只含有单独的类别为止。二叉树方法只需构造 $k-1$ 个 LSSVM 分类器,测试时不需要计算所有的分类器判别函数,从而提高了测试速度,且避免了传统方法的不可分问题,所以文中用来构造模拟电路故障诊断模型的方法为二叉树法。

2.2 模拟电路 PSO-LSSVM 方法故障诊断的实现

式(17)中的正规化参数 γ 影响着系统的计算精度;径向基核函数中的 σ^2 影响着系统的泛化学习能力,传统的优化参数法有交叉试验法、试凑法^[10],但这两种方法存在运算复杂,用时长,未必能找到全局最优解等问题,因此文中采用粒子群算法计算最优参数值。

粒子群算法的实质是模拟整个鸟群保持完整飞行队形的整个飞行过程,对应于求解最优问题,可以将待优化的参数看作整个空间中的一个粒子^[11-13],粒子具有位置和速度这两个属性^[14]。假设有以一定速度飞行的 n 个粒子在某一个空间中,第 i 个粒子在 N 维空间的飞行速度表示为 $v = (v_{i1}, v_{i2}, \dots, v_{iN})$,位置向量表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$ ^[15],粒子根据飞行经验,自动调整飞行状态,并判断当前是否处于最佳位置。pbest 为粒子所找到的最优个体值,表示粒子处于最佳位置。gbest 为整个群体中记录所有粒子的最佳个体极值;在每次算法迭代之中,粒子依据式(22)和式(23)来更新自己的速度和位置:

$$v_{id}^{k+1} = wv_{id}^k + c_1 \text{rand}_1(\text{pbest}_{id}^k - x_{id}^k) + c_2 \text{rand}_2(\text{gbest}^k - x_{id}^k) \quad (22)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (23)$$

其中, c_1 和 c_2 为粒子学习因子; rand_1 和 rand_2 是均匀分布在 $[0, 1]$ 之间的随机数; w 为惯性权重。

具体算法过程如下:

步骤 1:对待测电路施加激励响应并进行 AC 扫描和 Monte Carlo 分析,从频率响应数据中提取由小波系数的均值、标准差和熵构成的频率小波特征向量,再进行归一化处理,将得到的特征向量分为两个部分,其中一部分用于测试,另一部分用于训练 LSSVM。

步骤 2:初始化 LSSVM 参数 γ 和 σ 及范围,建立 LSSVM 分类模型,并初始化粒子群维数、规模、迭代次数、最小误差范围以及学习因子等。

步骤 3:根据粒子的适应度函数,见式(24),独立计算每个粒子的适应度值,确定个体历史最优值 pbest 和全局最优值 gbest。

$$J = \frac{1}{N} \sum_{i=1}^N (h(x)^d - h(x))^2 \quad (24)$$

式中, $h(x)$ 取自 LSSVM 分类函数 $f(x) = \text{sgn}\{h(x)\}$ 。

步骤 4:将确定后的 pbest 和 gbest 带入式(22)和式(23),更新粒子的速度和位置。

步骤 5:一旦迭代次数达到了先前设定的最大次数或者达到了预先设定的最小目标误差,则根据式(21),输出结果,否则执行步骤 4。

步骤 6:将优化完成后的粒子群最优位置(γ, σ)代入 LSSVM 模型中,利用测试样本重新建立分类模型,即可得到测试样本模型的分类结果。

3 仿真结果

文中的诊断电路选择 Elliptical Filter 电路,如图 1 所示。针对此电路,一般要考虑到该电路中电容值和电阻值正负漂移超过各自的标定值,负漂移记为 -50% ,正漂移记为 $+50\%$,经过灵敏度分析可确定故障元件为 $R_1, R_2, R_3, R_4, R_5, C_1, C_2, C_3$,故障模式为 $R_1 \pm 50\%, R_2 \pm 50\%, R_3 \pm 50\%, R_4 \pm 50\%, R_5 \pm 50\%, C_1 \pm 50\%, C_2 \pm 50\%$ 和 $C_3 \pm 50\%$,共 16 种故障模式,如表 1 所示,加上正常状态,共有 17 种状态类型。

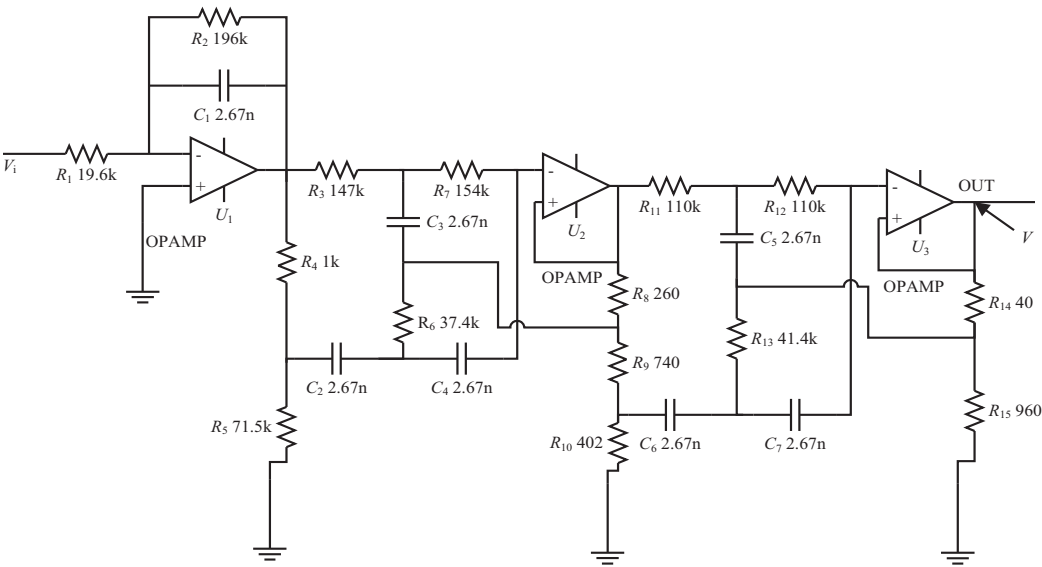


图 1 Elliptical Filter 电路

表 1 标称值及故障参数

元器件	标称值	+50%	-50%
R_1	19.6 k Ω	29.4 k Ω	9.8 k Ω
R_2	196.0 k Ω	294 k Ω	98 k Ω
R_3	147.0 k Ω	220.5 k Ω	73.5 k Ω
R_4	1.0 k Ω	1.5 k Ω	0.5 k Ω
R_5	71.5 k Ω	107.25 k Ω	35.75 k Ω
C_1	2.67 nF	4.005 nF	1.335 nF
C_2	2.67 nF	4.005 nF	1.335 nF
C_3	2.67 nF	4.005 nF	1.335 nF

在实际运用中使用 PSpice 软件仿真电路发生故障时的状态,Vi 是脉冲信号源,输出点 OUT 为可测点,依次记录下该点电压的瞬态值,然后从频率响应数据中提取由小波系数的均值、标准差和熵构成的频率小波特征向量,并对其归一化。针对在不同的元件故障情况下,采用 Monte Carlo 仿真能够得到 480 个结果,在各个故障模式下可以得到 30 组训练样本,用同样的方法,从电路获得 20 组 320 个试样本。

针对 16 种故障模式,采用二叉树法来构建 LSSVM 多分类器。该方法是将归一化后的数据作为 LSS-

VM 的输入,输出则分别是 +1 和 -1,将一类问题与不属于这一类的区分开来。文中总共需要 16 个二类 LSSVM 分类器。

为了验证该方法故障诊断的准确性和有效性,对故障诊断分别采用 LSSVM 模型和 PSO 优化后的 LSSVM 模型,比较它们各自模型下的诊断速度和精度。方法一运用 LSSVM 模型,且用网格划分来寻找最优参数,其中参数 γ 的设定范围为 $[0, 100]$,参数 σ 的设定范围为 $[-100, 100]$;方法二用 PSO 算法优化 LSSVM 模型参数,假设初始粒子为 30 个,学习因子 $c_1 = c_2 = 2$,惯性权值 $w = 0.8$,最大迭代数为 1 000。随机选取 20 组数据作为训练样本,另外 10 组数据作为测试样本。首先用训练样本分别对这两种模型进行训练,然后用训练后的模型对测试样本进行故障诊断,诊断结果如表 2 所示。

从表 2 可以看出,经过粒子群优化后的 LSSVM 诊断方法与 LSSVM 模型相比,故障诊断准确率和诊断效率都得到了一定的提高。这是因为 LSSVM 方法仅依据人工经验来确定参数值,这样得到的诊断效果往往不是最好的,而应用粒子群算法优化了多分类 LSSVM

中的参数值,则大大提高了分类能力,从而保证了诊断效率。

表2 诊断结果比较

诊断模型	LSSVM	PSO-LSSVM
γ	69.17	13.54
σ	4.16	3.01
训练时间/s	3.44	2.01
测试时间/s	0.29	0.23
平均诊断精度/%	93.16	98.75

4 结束语

文中提出了一种基于 PSO-LSSVM 使用频率特性来诊断有故障的模拟电路的方法,提取由小波系数的均值、标准差和熵构成的频率小波特征向量,采用二叉树法来构建 LSSVM 多故障诊断模型,再运用粒子群算法优化 LSSVM 模型参数。在 Elliptical Filter 模拟电路的故障诊断中,验证了该方法的可行性和实用性,提高了故障诊断的精度和效率。

参考文献:

[1] Aminian M, Inian F. Neural-network based analog-circuit fault diagnosis using wavelet transform as preprocessor[J]. IEEE Trans on Circuits and Systems,2000,47(2):151-156.

[2] Martin H T. Back propagation neural network design[M]. Beijing:China Machinery Press,2002.

[3] 林海军,张礼勇,任殿义,等. 基于 Wiener 核和 BP 神经网络的非线性模拟电路故障诊断[J]. 仪器仪表学报,2009,30(9):1946-1949.

[4] Spina R, Upadhyaya S. Linear circuit fault diagnosis using neuromorphic analyzers[J]. IEEE Transactions on Circuits and Systems II,1997,44(3):188-196.

(上接第 208 页)

[4] 贾卓燕,申瑞民. 基于 WEB 的口语考试系统的设计与实现[J]. 计算机仿真,2004,21(4):140-142.

[5] Salomon D. Data compression; the complete reference[M]. 2nd ed. New York; Springer-Verlarge,2000.

[6] 黄嘉辉. Visual Basic. NET 网络程序设计[M]. 北京:清华大学出版社,2003.

[7] Perry P. 多媒体开发指南[M]. 陈向群,译. 北京:清华大学出版社,1995.

[8] 林福宗. 多媒体技术基础[M]. 第2版. 北京:清华大学出版社,2002.

[9] Jurafsky D, Martin J H. Speech and language processing: an introduction to natural language processing, computational lin-

[5] 刘东平,董俊,蒲秀英,等. 基于小波分析和支持向量机的模拟电路故障诊断[J]. 计算技术与自动化,2012,31(1):60-63.

[6] Suykens A K, Vandewalle J. Least squares support vector machines classifiers[J]. Neural Networks Letters,1999,19(3):293-300.

[7] Kennedy J, Eberhart R C. Particle swarm optimization[C]//Proc of IEEE international conference on evolutionary computation. Piscataway, NJ: IEEE Service Center, 1998:69-73.

[8] Long Bing, Huang Jianguo, Tian Shulin. Least squares support vector machine based analog circuit fault diagnosis using wavelet transform as preprocessor[C]//Proc of ICCCAS. Fujian: IEEE, 2008:1026-1029.

[9] Wang Anna, Liu Junfang, Wang Qinwan, et al. A novel multi-classifier for fault diagnosis of analog circuit based on the unsupervised binary tree and support vector machines[C]//Proc of international multi conference of engineers and computer scientists. Hongkong: [s. n.], 2007:59-64.

[10] 杨奎河,单甘霖,赵玲玲. 基于最小二乘支持向量机的汽轮机故障诊断[J]. 控制与决策,2007,22(7):778-782.

[11] 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.

[12] 魏秀业,潘宏侠,马清峰,等. 粒子群优化的神经网络在故障诊断中的应用[J]. 振动、测量与诊断,2006,26(2):133-137.

[13] 潘昊,侯清兰. 基于粒子群优化算法的 BP 网络学习研究[J]. 计算机工程与应用,2006,42(16):41-43.

[14] 何怡刚,祝文姬,周炎涛,等. 基于粒子群算法的模拟电路故障诊断方法[J]. 电工技术学报,2010,25(6):163-171.

[15] 胡云艳,彭敏放,田成来,等. 基于粒子群算法优化支持向量机的模拟电路诊断[J]. 计算机应用研究,2012,29(11):4053-4055.

guistics and speech recognition[M]. 2nd ed. [s. l.]: Prentice Hall, 2008.

[10] Spanias A, Painter T, Atti V. Audio signal processing and coding[M]. [s. l.]: Wiley-Interscience, 2007.

[11] Bosi M, Goldberg R E, Chiariglione L. Introduction to digital audio coding and standards[M]. [s. l.]: Springer, 2003.

[12] 史玉峰,靳奉祥. 数字信息模式识别理论与应用[M]. 北京:科学出版社,2007.

[13] 贾志先. 基于支持向量机的空白试卷识别方法[J]. 山西大学学报:自然科学版,2011,34(3):351-356.

[14] 贾志先. 神经网络在空白试卷识别中的应用[J]. 计算机技术与发展,2009,19(8):208-211.

基于PSO-LSSVM的模拟电路故障诊断

作者：[陈志凡](#)，[单剑锋](#)，[宋晓涛](#)，[王文清](#)，[CHEN Zhi-fan](#)，[SHAN Jian-feng](#)，[SONG Xiao-tao](#)，[WANG Wen-qing](#)

作者单位：[陈志凡,单剑锋,王文清,CHEN Zhi-fan,SHAN Jian-feng,WANG Wen-qing\(南京邮电大学 电子科学与工程学院,江苏 南京,210003\)](#)，[宋晓涛,SONG Xiao-tao\(太原理工大学 计算机科学与技术学院,山西 太原,030024\)](#)

刊名：[计算机技术与发展](#)

英文刊名：[Computer Technology and Development](#)

年，卷(期)：2015(5)

引用本文格式：[陈志凡](#).[单剑锋](#).[宋晓涛](#).[王文清](#).[CHEN Zhi-fan](#).[SHAN Jian-feng](#).[SONG Xiao-tao](#).[WANG Wen-qing](#) [基于PSO-LSSVM的模拟电路故障诊断](#)[期刊论文]-[计算机技术与发展](#) 2015(5)