基于非线性频谱特征及核主元分析的模拟 电路故障诊断方法

韩海涛 1,2 马红光 1 曹建福 2 张家良 2

(1.第二炮兵工程大学 101 教研室 西安 710025 2.西安交通大学机械制造系统工程国家重点实验室 西安 710049)

摘要 针对模拟电路基于非线性输出频域响应函数(NOFRF)模型进行故障特征提取时,具 有维数多、数据量大的特点,提出了采用核主元分析(KPCA)和多类别支持向量机(MSVM)进行 故障模式判别的新方法(KPCA-MSVM)。该方法首先采用 KPCA 对特征向量进行维数压缩、消 除变量之间的非线性;其次构造 MSVM 分类器,在 PSpice 环境下通过蒙特卡罗仿真生成模拟 电路在各种故障状态下的数据,对 MSVM 分类器进行训练,将训练好的 MSVM 分类器用于模 拟电路的故障状态识别。通过对 Sallen-Key 带通滤波器模拟电路的故障诊断结果表明,该故障 诊断方法对模拟电路参数型故障有很好的识别、定位能力并具有速度快和准确率高的特点。

关键词: 非线性输出频域响应函数 核主元分析 支持向量机 故障特征 故障诊断 中图分类号: TN47/TP206.1

Fault Diagnosis Method of Analog Circuits Based on Characteristics of the Nonlinear Frequency Spectrum and KPCA

Han Haitao^{1,2} Ma Hongguang¹ Cao Jianfu² Zhang Jialiang²

(1. The Second Artillery Engineering University Xi'an 710025 China 2. Xi'an Jiaotong University State Key Laboratory for Manufacturing Systems Engineering Xi'an 710049 China)

Abstract For the characteristics that there existed much dimensions and big data volume in extracting fault signatures based on the model of nonlinear output frequency response function (NOFRF), a novel fault diagnosis method, which adopted kernel principal component analysis and multi-class support vector machine(KPCA-MSVM), is proposed to identify different fault states. Firstly, kernel principal component analysis(KPCA) is used to compress data dimension and eliminate nonlinearity among the variables. Secondly, multi-class support vector machine(MSVM)classifier is constructed, and the datum of all kinds of fault states, which were used to train MSVM classifier, are generated by Monte Carlo simulation with PSpice software. The trained MSVM classifier is used to identify different fault state. Via fault diagnosis for sallen-key band pass filter, the results indicate that KPCA-MSVM has good ability to identify and locate parametric faults for analog circuits, and has virtues of fast speed and high precision.

Keywords: Nonlinear output frequency response functions, kernel principal component analysis, support vector machine, fault signature, fault diagnosis

1 引言

国家自然科学基金资助项目(61174207, 61074072)。

收稿日期 2011-03-04 改稿日期 2011-12-08

电路仅占 20%,但整个设备中 80%的故障来自于模 拟电路,因此模拟电路的故障诊断至关重要 ^[1,2]。 目前数字电路故障诊断方法比较成熟,而模拟电路 的故障诊断方式还处于研究阶段 ^[3],这主要是由于 模拟电路的故障现象的多样性、元件参数的离散性 以及存在的非线性等原因 ^[4]。

基于 Volterra 级数的非线性频谱分析是一种新 型的故障诊断方法,其主要思想是 在线获得对象的 传递频谱特性, 通过对 传递频谱特性的变化进行分 析来判断是否处于故障状态,这种方法物理意义明 确、鲁棒性好。 目前基于 Volterra 级数的非线性频 谱分析方法主要有广义频域响应函数 GFRF (generalized frequency response functions) [5]和非线性输 出频域响应函数 NOFRF (nonlinear output frequency functions)^[6]模型,NOFRF 是针对 response GFRF 具有维数灾难、辨识困难的缺点提出来的一 种新的频域分析方法。本文采用 NOFRF 模型对非 线性模拟电路进行建模,并提取 NOFRF 核的频谱 信息以此作为故障特征。由于 NOFRF 模型理论上 都具有无限阶次,基于此进行故障特征提取维数非 常大,不利于数据的实时处理。主元分析 (PCA) 是一种数据维数压缩的有效方法, 然而 PCA 是基 于线性降维,但实际模拟电路本质上是非线性的。 文献[7]提出了 PCA 的改进算法——核主元分析 (KPCA)。文献[8]为了模拟人的行为实现智能控 制,提出了一种基于 KPCA 和加权支持向量机 (SVM) 精简输入向量的建模方法。模拟电路故障 诊断的实质是模式识别问题,由 Vapnik^[9]提出的 SVM 是模式识别中新发展起来的方法, 它是一种 建立在统计学习理论上的机器学习方法, 在解决小 样本、非线性及高维模式识别问题中表现出特有的 优势[10],具有良好地学习能力和推广能力,在故障 诊断方面的应用研究日益得到重视。文献 [11-13]基 于 SVM 研究了模拟电路的故障诊断, 取得了较好 的诊断效果。

本文针对模拟电路提出一种新的故障检测与诊断方法,主要思想是基于 NOFRF 模型在线获取模拟电路的频谱特征,进行故障特征提取,然后采用 KPCA 对其进行维数压缩及归一化处理,将压缩好的数据送往 MSVM 分类器进行训练或者故障模式 判别。实验结果表明了该方法的有效性。

2 基于 NOFRF 的故障特征提取

非线性系统的输入、输出关系可以用 Volterra 级数表示

$$y_n(t) = \sum_{n=1}^{\infty} \int_{-\infty}^{\infty} \mathsf{L} \int_{-\infty}^{\infty} h_n(\tau_1, \tau_2, \mathsf{L}_n, \tau_n) \prod_{i=1}^n u(t - \tau_i) \mathrm{d}\tau_i$$
(1)

式中, $h_n(\tau_1, \tau_2, \dots, \tau_n)$ 为第 n 阶 Volterra 时域核 或称为广义脉冲响应函数,对其进行多维傅里叶变 换可以得到

$$H_n(\omega_1, \omega_2, \mathsf{L}_{,,\omega_n}) = \int_{-\infty}^{\infty} \mathsf{L}_{,-\infty} \int_{-\infty}^{\infty} h_n(\tau_1, \tau_2, \mathsf{L}_{,,\tau_n}) \cdot e^{-j(\omega_1\tau_1 + \omega_2\tau_2 + \mathsf{L}_{+\omega_n\tau_n})} d\tau_1 d\tau_2 \mathsf{L}_{,-\infty} d\tau_2$$
(2)

式中, $H_n(\omega_1, \omega_2, \dots, \omega_n)$ 称为第 *n* 阶 Volterra 频 域核或 GFRF。

GFRF 是多维的频域核, NOFRF 是 GFRF 描述 的一维变换, 其定义为

$$G_{n}(j\omega) = \frac{\int_{\omega_{1}+,\dots,+\omega_{n}=\omega} H_{n}(j\omega_{1},\mathsf{L},j\omega_{n})\prod_{i=1}^{n} U(j\omega_{i}) \mathrm{d}\sigma_{n\omega}}{\int_{\omega_{1}+,\dots,+\omega_{n}=\omega} \prod_{i=1}^{n} U(j\omega_{i}) \mathrm{d}\sigma_{n\omega}}$$

(3)

NOFRF 模型理论上由无限阶核函数组成,而实际非线性系统的辨识模型可用有限阶近似描述

$$Y(j\omega) = \sum_{n=1}^{N} Y_n(j\omega) = \sum_{n=1}^{N} G_n(j\omega) U_n(j\omega) \qquad (4)$$

式中, *N* 为系统的最大阶次 (需要根据系统的非线 性度来确定); *U_n*(j*ω*)为 NOFRF 的第 *n* 阶输入, 且 *U_n*(j*ω*)不为零,其定义为

$$U_{n}(j\omega) = \int_{\omega_{1}+,\dots,+\omega_{n}=\omega} \prod_{i=1}^{n} U(j\omega_{i}) d\sigma_{n\omega}$$
(5)

基于 NOFRF 模型进行故障特征提取,选取前 N 阶 NOFRF 核中每阶核在某些频域点的幅值作为 分析对象,假设每阶核取 *M* 个频域点,那么提取故 障特征量维数为 *N* • *M*。如果 *N* 与 *M* 取值比较大会 造成特征向量的维数很大,而且经分析基于 NOFRF 特征向量的各变量之间呈一定的非线性。

3 KPCA 算法

由第1节分析可知基于 NOFRF 进行故障特征 提取特征向量维数比较高,高维数不但会增加计算 的复杂性,而且会给合理地分析和解释问题带来困 难。PCA 是在线性降维的思想下产生的处理高维数 据的方法,可以将多变量进行有效压缩。然而实际 模拟电路本质上是非线性的,因此利用 PCA 显然 是不合适的。KPCA 是处理多变量非线性的有效工 具, 它的主要思想是将原始空间的数据通过一个非 线性映射,映射到高维空间中,使原本非线性的问 题线性化, 然后采用 PCA 进行降维处理, 因此改 进的 PCA 方法——KPCA 能更好处理模拟电路的故 障诊断问题。KPCA常用的核函数[14,15]有多项核函 数 $k(x_i, x_i) = [(x_i \bullet x_i) + 1]^d$ 、Sigmoid 核函数 $k(x_i, x_i) = \tanh(\beta)$ $(x_i \cdot x_i)$ +b)及高斯核函数 $k(x_i, x_i) = \exp(-\gamma |x_i - x_i|^2)$ 。高斯核函数具有三个特点: ①由于它是一个归一化核,使计算过程简单; (2)高斯核只有一个调整参数; (3)多项式核函数 (包含其特殊形式 ——线性核函数)是高斯核函数 的特殊形式,且 Sigmoid 核函数与高斯核函数在某 些参数情况下具有相似的特性。因而 在没有参数调 优的情况下,具有平滑特性的高斯核是最好的选择, 所以本文采用高斯核作为 KPCA 的核。

KPCA 的主要思想就是对映射到特征空间中的 数据做主元分析。设原始空间中的数据, $x_i \in R^N$, i=1, 2, ..., M, $x_i=[x_{i1}, x_{i2}, ..., x_{iN}]^T$ 为第 i 次观 测的特征向量,其维数为 N。将 x_i 通过非线性映射 D映射到特征空间 F,原始数据 x_i 在特征空间 F 的 像为 $D(x_i)$,然后对映射到特征空间中的数据再运用 PCA 进行主元提取。图 1 所示说明了线性 PCA 及 KPCA 的原理,图 1a 在二维空间中各变量之间呈线 性,PCA 寻找主元的示意图,图中箭头的方向代表 数据方差最大的方向,为第一主元,图 1b KPCA 通过非线性映射 D,将原始数据由二维映射 到了二十维,使原来呈非线性的数据线性化,然后 再寻找主元。



图 1 PCA 与核 PCA 的对比

Fig.1 Comparison between PCA and KPCA

假设
$$\sum_{k=1}^{M} \boldsymbol{\Phi}(x_{ki})$$
为零,因此高维特征空间中的样

本协方差矩阵为[9]

$$\boldsymbol{C} = \frac{1}{M} \sum_{i=1}^{M} \boldsymbol{\Phi}(\boldsymbol{x}_i) \boldsymbol{\Phi}(\boldsymbol{x}_i)^{\mathrm{T}}$$
(6)

对 C 进行特征分解

式中, λ 是矩阵 *C* 的特征值; v 是与 λ 对应的特征向量。将式(2)两边与 $\Phi(x_k)$ 作内积

$$\lambda(\Phi(\mathbf{x}_k) \cdot \mathbf{v}) = (\Phi(\mathbf{x}_k) \cdot C\mathbf{v}) \tag{8}$$

 $\lambda v = Cv$

由再生核理论可知,存在 a_i使得

$$\boldsymbol{v} = \sum_{i=1}^{n} a_i \boldsymbol{\Phi}(\boldsymbol{x}_i) \tag{9}$$

将式 (6) 和式 (9) 代入式 (8),得到 $\lambda \sum_{i=1}^{M} a_i (\Phi(\mathbf{x}_k) \cdot \Phi(\mathbf{x}_i))$ $= \frac{1}{M} \sum_{i=1}^{M} a_i (\Phi(\mathbf{x}_k) \cdot \sum_{j=1}^{M} \Phi(\mathbf{x}_j)) (\Phi(\mathbf{x}_j) \cdot \Phi(\mathbf{x}_i)) \quad (10)$

, 由核函数的性质^[10],可通过核直接计算内积, 而不用计算映射到高维空间向量的内积

$$k_{ii} = k(\mathbf{x}_i, \mathbf{x}_i) = \boldsymbol{\Phi}(\mathbf{x}_i) \cdot \boldsymbol{\Phi}(\mathbf{x}_i)$$
(11)

因此有

$$M\lambda \mathbf{K}\mathbf{a} = \mathbf{K}^2 \mathbf{a} \tag{12}$$

即

$$\overline{\lambda}a = Ka$$
 (13)
式中, $\overline{\lambda} = M\lambda$ 。那么第 *k* 个主元为

(14)

$$p_k = \mathbf{v}^k \cdot \boldsymbol{\Phi}(\mathbf{x}) = \sum_{i=1}^M a_i^k (\boldsymbol{\Phi}(\mathbf{x}_i) \cdot \boldsymbol{\Phi}(\mathbf{x})) = \sum_{i=1}^M a_i^k k(\mathbf{x}_i, X)$$

式中, $X=[x_1, x_2, \dots, x_m]; v^k$ 表示矩阵 C 第 k 个特征矢量; a_i^k 表示矩阵 K 的第 k 个特征矢量的第 i 个元素。

为了方便起见,假定观察样本已中心化,中心 化容易在原输入空间中实现,而很难在高维映射空 间 **F** 中实现,因此对 *K_{ii}* 采用下式进行修正

$$\mathbf{R}_{ij}^{\prime 0} = K_{ij} - \frac{1}{M} \sum_{m=1}^{M} l_{im} K_{mj} - \sum_{n=1}^{M} K_{in} l_{nj} + \frac{1}{M^2} \sum_{m,n=1}^{M} l_{im} K_{mn} l_{nj}$$
(15)

式中,对于任意的 i 和 i, $l_{ij}=1$ 。

通常用累积贡献率作为主元的评价标准,来决 定采用多少个主元能充分代表原数据的信息,用 $\sum_{i=1}^{k} \bar{\lambda}_{i} / \sum_{i=1}^{m} \bar{\lambda}_{i}$ 来描述。

4 MSVM 分类器构造

目前 SVM 已成为二值分类中最有效的方法, 怎么将二值分类方法扩展到多值分类问题仍是目前 研究的课题。现主要有两种构造 MSVM 的方法: ①"一对多"(One-Vs-Rest, OVR),该算法将 其中一个类别的样本作为一类,其 他不属于该类别 的样本作为另一类,依次进行训练; ②"一对一"

(One-Vs.-One, OVO),是由 Kreβel^[16]针对 OVR 中存在的不足提出来的,该方法在 *k* 类训练 样本中构造所有可能的两分类机,每个分类机仅在 *k* 个类别中的两类训练样本上训练,结果共构造 *K*(*K*-1)/2 个分类机。如训练区分第 *i* 类和第 *j* 类样 本之间的分类机,可以求解如下问题

$$\min_{\boldsymbol{\omega}^{ij}, b^{ij}, \boldsymbol{\xi}^{ij}} \frac{1}{2} \left\| \boldsymbol{\omega}^{ij} \right\|^2 + C \sum_{j=1}^{l} \boldsymbol{\xi}_t^{ij}$$
s.t.
$$\begin{cases} \boldsymbol{\omega}^{ij} \cdot \boldsymbol{\varphi}(\mathbf{x}_j) + b^{ij} \geq 1 - \boldsymbol{\xi}_j^{ij} \quad if \ y_j = i \\ \boldsymbol{\omega}^{ij} \cdot \boldsymbol{\varphi}(\mathbf{x}_j) + b^{ij} \leq -1 + \boldsymbol{\xi}_j^{ij} \quad if \ y_j = j \\ \boldsymbol{\xi}_j^{ij} \geq 0, \qquad i, j = 1, 2, L, l \end{cases}$$
(16)

式中, *o***^{jj}** 为超平面的法向量, 由 *o***^{jj}** 和 *b^{ij}* 共同决定 分类的超平面; *C* 为惩罚参数; *ξ^{ij}* 为松弛变量;

$$X_j$$

为样本; yi 为样本标签。

对于 K(K-1)/2 个分类机, 必然有 K(K-1)/2 个 决策函数。第 *i* 类和第 *j* 类之间的决策函数为

$$f(x) = \operatorname{sgn}(\omega^{ij} \cdot \varphi(x) + b^{ij}) \tag{17}$$

本文采用 OVO 方法构造 SVM 分类器完成模拟 电路的故障模式判别。

5 基于 KPCA-MSVM 的模拟电路故障诊

断

5.1 KPCA-MSVM

基于 NOFRF 的模拟电路故障特征提取具有维数多、数据量大的特点,而且特征 矢量的各变量之间具有一定的非线性,采用 KPCA-MSVM 方法可以有效解决这些问题。 KPCA 不仅消除了变量之间的非线性,而且压缩了特征 矢量的维数,而 MSVM 分类器可以对模拟电路的多类型故障进行识别,图 2 说明了基于 KPCA-MSVM 故障诊断的过程,该方法包括以下步骤。

步骤 1: 对处于各种状态(包括故障和正常状态)下的目标电路进行激励,然后基于 NOFRF 模型进行故障特征提取。

步骤 2:采用 KPCA 对各种状态下电路的特征 矢量进行维数压缩及归一化处理,将处理后的特征 矢量送往 SVM 分类器,对其进行训练。

步骤 3: 对处于某一状态(包括故障和正常状态)下的待测电路进行激励,然后基于 NOFRF 模型进行故障特征提取。

步骤 4: 采用 KPCA 对特征 矢量进行维数压缩 及归一化处理,将处理后的特征 矢量送往 SVM 分 类器,对故障模式进行判别。



图 2 基于 KPCA-MSVM 模拟电路故障诊断结构示意图

Fig.2 Sketch map of analog circuit fault diagnosis based on KPCA-MSVM

5.2 实例仿真

以 Sallen-Key 带通滤波器为分析对象,电路如 图 3 所示。针对此电路,主要考虑待测电路中的参 数型故障,电容和电阻在标称值的 ±5%容差范围 以变化认为是正常的;当电阻和电容元件值超过标 称值的容差范围时认为发生故障,当在标称值的 5%~ 50%容差范围内变化时,此故障为正漂移,记为 $R\uparrow$ 或 $C\uparrow$;当在标称值的为 –50%~–5%容差范围内 变化时,为负漂移记为 $R\downarrow$ 或 $C\downarrow$ 。在 PSpice 电路仿 真软件下对电路进行灵敏度分析确定 $R_3 \sim R_5$ 为分 析对象,故障模式为 $R_3\uparrow$ 、 $R_3\downarrow$ 、 $R_4\uparrow$ 、 $R_4\downarrow$ 、 $R_5\uparrow$ 、 $R_5\downarrow$ 共 6 种故障模式。电路中结点 1 为输入结点, 结点 4 为输出结点。实验硬件平台为 AMD 双核 2.81GHz, 2GB 内存微机,软件平台为 LIBSVM^[17]、PSpice 和 Matlab R2008a。



图 3 Sallen-key 带通滤波器 Fig.3 Sallen-key band pass filter

对电路进行扫频分析:对该电路施加单音激励 信号,使激励信号的频率从 1Hz 开始增加到 1MHz,获取电路输出响应幅度与激励信号频率之间 的关系图,如图 4 所示,横坐标为频率,纵坐标为 幅度,可以观察到该电路具有带通特性,对 1kHz 以下及 1MHz 以上的信号具有滤除的作用,因 此在通带范围内选择 1kHz、3kHz、10kHz、 25kHz、60kHz、100kHz 和 370kHz 组成的多音信 号作为激励源,对该带通滤波器进行激励。激励信 号的幅度为 1V,相位为零,如下所示:

$$s = \sum_{i=1}^{7} \cos(2\pi f_i t)$$
 (18)

式中, $f_1 \sim f_7$ 依次取 1kHz、3kHz、10kHz、 25kHz、60kHz、100kHz 和 370kHz。



图 4 电路输出响应最大幅度与激励信号频率之间的关系 Fig.4 Relationship between the maximum amplitude of

circuit's output response and input stimulus' frequency

对电路的 7 种状态进行蒙特卡罗(monte carlo)仿真,电路在每种状态下各仿真 50 次,仿 真时间长度为 1.5ms。前 30 次仿真的结果用于对 SVM 分类器进行训练,后 20 次用于测试。对电路 输出状态进行采样,采样频率为 10MHz。

采用 NOFRF 模型对电路的输入输出信号进行 分析。提取前4阶核函数,核函数的辨识分为成批 [6]及自适应方法[18]。本文采取在线自适应 方法提取 前4阶核函数,在 R₄↑的情况下辨识出的结果如图 5 所示,图 5a~图 5d 分别为第1阶、第2阶、第 3 阶及第 4 阶 NOFRF 核辨识的结果,从图上可以 看出随着阶次的增加核的幅度逐渐减小。每阶核函 数取的频域点为 f_1 , …, f_7 , 将这 7 个频域点的幅 值作为分析对象,那么 4 阶核函数共 28 个值,即 提取的特征矢量为 28 维。利用 KPCA 对特征矢量 维数进行压维,经计算分析采用前两个主元,累积 贡献率可达 99.93%,即可满足要求。将压缩后的数 据送往支持向量机进行故障模式识别。表中对两种 诊断方法从耗时及分类精度的对比 : 一种方法是直 接对数据进行归一化处理,送 MSVM 进行故障模 式判别; 另一种方法是本文提出的 KPCA-MSVM.





图 5 在 *R*₄↑的情况下 NOFRF 前 4 阶核辨识的结果 Fig.5 Identification results of former 4 order kernels of NOFRF in *R*₄↑

表 基于 MSVM 及 KPCA-MSVM 方法两种诊断结果的 对比

Tab. Comparison of fault diagnosis results between MSVM and KPCA-MSVM

	MSVM		KPCA-MSVM
故障类别	线性核	高斯核, r=1	线性核
	C=1 000	C=1 000	C=1 000
正常	96.67%	100%	100%
$R_3\downarrow$	90%	100%	100%
$R_3\uparrow$	100%	100%	100%
$R_4 \downarrow$	100%	96.67%	96.67%
$R_4\uparrow$	96.67%	100%	100%
$R_5 \downarrow$	86.67%	100%	100%
$R_5\uparrow$	86.67%	96.67%	93.33%
平均准确率	90	98.57	98.16
(%)			
耗时/ms	4.288	5.075	2.152

表中的参数 C 代表 SVM 的惩罚因子, r 为高 斯核参数,由表中的第 2 列和第 3 列可以看出, MSVM 分类器分别采用线性核和高斯核分别对数据 进行处理,由于特征 矢量各变量之间有一定的非线 性度,采用线性核的分类精度显然要低于采用高斯 核的分类精度,这是因为采用高斯核在一定程度消除了变量之间的非线性度,所以分类精度有了大的改善。经过 KPCA 处理的数据,数据维数由 二十八维降到了二维,在很大程度上减少了运算量。但由于有一部分信息损失,经 MSVM 分类器后分类精度略有下降,但耗时明显减半。由于 KPCA 去掉了数据间的非线性度,因此 KPCA-MSVM 选用线性核,而未经 KPCA 处理的数据采用线性核分类精度明显比较差,表的实验结果表明了本文所提方法的有效性。

6 结论

本文针对基于 NOFRF 模型进行故障特征提取 时的特点,提出了一种模拟电路故障诊断的新方法 ——KPCA-MSVM。该方法采用 KPCA 对故障特征 进行维数压缩,消除变量之间的非线性度,并采用 OVO 构造 MSVM 分类器进行故障模式判别。通过 对 Sallen-Key 带通滤波器的故障诊断表明,该方法 在分类精度略有下降的情况下,可以大大减少诊断 时间。此外该方法可推广至具有非线性元器件模拟 电路的故障诊断,是一种实用的故障诊断方法。

参考文献

- Milor L S. A tutorial introduction to research on analog and mixed-signal circuit testing[J]. IEEE Transactions on Circuits and System II: Analog and Digitial Signal Processing, 1998, 45:1389-1407.
- [2] Wang P, Yang S Y. A new diagnosis approach for handling tolerance in analog and mixd-signal circuits by using fuzzy math[J]. IEEE Transaction on Circuits and Systems, 2005, 52(10): 2118-2127.
- [3] 王军锋,张维强,宋国乡.模拟电路故障诊断的多 小波神经网络算法 [J]. 电工技术学报,2006,21(1): 33-36.

Wang Junfeng, Zhang Weiqiang, Song Guoxiang. Fault diagnosis algorithm of analog circuit based on multiwavelet neural network[J]. Transaction of China Electrotechnical Society, 2006, 21(1): 33-36.

 [4] 彭良玉,禹旺兵.基于小波分析和克隆选择算法的 模拟电路故障诊断 [J].电工技术学报,2007,22(6): 12-16.

Peng liangyu, Yu Wangbing. Fault diagnosis of analog circuit based on wavelet analysis and clonal

selection algorithm[J]. Transaction of China Electrotechnical Society, 2007, 22(6): 12-16.

- [5] Lang Z Q, Billings S A. Output frequency characteristics of nonlinear system[J]. International Journal of Control, 2007, 80(6): 843-855.
- [6] Lang Z Q, Billings S A. Energy transfer properties of non-linear systems in the frequency domain[J]. International Journal of Control, 2005, 78(5):345-362.
- Schölkopf B, Smola A, Müller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5):1299-1319.
- [8] 钟秉翔,李太福,汪德彪等.基于 KPCA 的功能模 拟智能控制系统模型研究 [J]. 辽宁工程技术大学学 报,2010,29(5):810-813.
 Zhong Bingxiang, LI Taifu, Wang Debiao, et al. Modeling on intelligent control system with function simulation based on KPCA[J]. Journal of Liaoning
- [9] Vapnik V, Lerner A. Pattern recognition using generalized portrait method[J]. Automation and Remote Control, 1963, 24(6):774-780.

Technical University, 2010, 29(5): 810-813.

- [10] 邓乃杨,田英杰著.数据挖掘中的新方法—支持向量机[M].北京:科学出版社,2004:100-122.
- [11] 孙永奎. 基于支持向量机的模拟电路故障诊断方法 研究[D]. 成都: 电子科技大学, 2009.
- [12] Cui J, Wang, Y R. A novel approach of analog circuit fault diagnosis using support vector machines classifier[J]. Measurement, 2011, 44: 281-289.
- [13] 毛先柏. 基于支持向量机的模拟电路故障诊断研究 [D]. 武汉: 华中科技大学, 2009.
- [14] 蒋少华,桂卫华,阳春华等.基于核主元分析与支持向量机的监控诊断方法及其应用 [J].中南大学学报,2009,40(5):1323-1328.

```
Jiang Shaohua, Gui Weihua, Yang Chunhua, et al.
Method based on kernel principal component analysis
and support vector machine and its application[J].
Journal of Central South University, 2009, 40(5):
1323-1328.
```

- [15] 许洁,胡寿松. 基于 KPCA 和 MKL-SVM 的非线性 过程监控与故障诊断 [J]. 仪器仪表学报, 2010, 31(11): 2428-2433.
 Xu Jie, Hu Shousong. Nonlinear process monitoring and fault diagnosis based on KPCA and MKL-SVM[J]. Chinese Journal of Scientific Instrument, 2010, 31(11): 2428-2433.
- [16] Kreßel U. Pairwise classification and support vector machine[M]. MA: MIT Press Cambridge, 1999: 255-268.
- [17] Chang C C, Lin C J. Libsvm: a library for support vector machines[EB/OL]. Software available at 2001, thttp: //www.csie.ntu.edu.tw/~cjlin/libsvm.
- [18] 韩海涛,曹建福,马红光,等.非线性输出频域响应 函数的自适应辨识算法及其应用 [J].西安交通大学 学报,2011,45 (10):77-81.
 Han Haitao, Cao Jianfu, Ma Hongguang, et al. Adaptive identification algorithm of nonlinear output f requency response functions and its application[J],

Journal of Xi'an Jiaotong University, 2011, 10(45): 77-81.

作者简介:韩海涛 男,1983年出生,博士研究生,主要研究方向 为非线性系统故障诊断、状态监测以及机器学习算法。 马红光 男,1959年出生,教授,博士生导师,主要研究方向为信号与信息 处理、电子对抗及复杂系统故障诊断。