# 基于并行量子遗传神经网络的自诊断 智能结构传感器的优化配置<sup>\*</sup>

# 谢建宏

(南昌大学 过程装备与测控工程系,南昌 330031)

摘 要:针对压电智能复合材料层板,基于损伤检测问题,采用最小二乘小波支持向量机(LS-WSVM)网络建立 损伤检测目标函数,运用量子遗传算法对目标函数进行优化,并将LS-WSVM 以并行方式与量子遗传算法相结 合,从而构造并行量子遗传神经网络方法,实现对智能结构损伤检测传感器的优化配置。仿真结果表明,采用该 方法实现的不同数目传感器的最优布置符合工程判断,综合考虑成本与效益的因素,该方法可确定传感器对应 于其初始布置模式下的最优配置数目。对于更多传感器的初始布置模式,采用该方法可有效减少传感器的数 量,从而降低成本。相比于传统遗传算法,该方法中量子遗传算法具有较好的寻优能力和收敛速度。

关键词: 自诊断智能结构; 传感器优化配置; 并行量子遗传神经网络; 成本与效益

中图分类号: TP39; TP18 文献标志码: A 文章编号: 1001-3695(2012)03-0919-04 doi:10.3969/j.issn.1001-3695.2012.03.033

# Optimal sensor placement in self-diagnostic smart structures using parallel QGA integrated LS-WSVMs

#### XIE Jian-hong

(Dept. of Process Equipment & Measurement & Control Engineering, Nanchang University, Nanchang 330031, China)

Abstract: For piezoelectric smart composite laminated plates, this paper proposed LS-WSVM as a kind of neural network to establish the performance function of damage detection, and then applied QGA to optimize the performance function. To enhance the algorithm speed, combined LS-WSVMs adopted as parallel mode with QGA, that was, constructed a method of parallel QGA integrated LS-WSVMs to optimize sensor placement based on damage detection. Simulation results show that, the optimal placements of different number of sensors are in accordance with engineering judgments, and considering the cost-effective factor, the optimal sensors' number corresponding to its primal sensors' number can be determined through the method. For the more sensors' primal placement, the number of sensors can be reduced effectively through the method, and thus leads to cost savings. Compared with TGA, QGA in the method possesses the better searching ability and the faster convergence speed.

Key words: self-diagnostic smart structures; optimal sensor placement; parallel QGA integrated LS-WSVMs; cost-effective factor

## 0 引言

智能结构是一个多传感器体系结构,多传感器的优化配置 是关联智能结构实现损伤自诊断功能的一个重要问题,对其进 行研究具有重要的理论意义和实用价值<sup>[1,2]</sup>。迄今发展了许 多不同的优化传感器配置的方法,如最早期的 Ad hoc 优化方 法、传统的确定性优化方法等。近年来一些非确定性的智能优 化方法得到了发展,这些方法有神经网络、遗传算法、进化策 略、模拟退火、禁忌搜索以及混合优化策略等<sup>[3]</sup>。其中,遗传 算法由于其具有思想简单、易于实现、应用效果明显等优点而 被众多应用领域所接受。然而传统遗传算法(traditional genetic algorithm,TGA)由于没有利用进化中未成熟优良子群体所 提供的信息,因而限制了其进化速度。基于量子计算(quantum computation,QC)的并行性、指数级存储容量和指数级加速特 征等体现的强大运算能力<sup>[4]</sup>,为增强遗传算法的智能性,提高 其搜索效率,解决其早熟和收敛速度等问题,本文研究用于传 感器优化配置的将量子算法与遗传算法相结合的量子遗传算 法(quantum genetic algorithm,QGA)。

多传感器的优化配置技术目前主要应用于系统/模态识 别、控制工程及损伤检测三个领域。在前两个领域,传感器的 优化配置技术得到了很好的研究应用。在智能结构损伤检测 领域,优化传感器配置的研究工作很少,问题在于难以找到理 想的关联损伤物理力学特征的损伤检测目标函数<sup>[5,6]</sup>。即使 通过繁琐的数学推导得到了有关的损伤检测目标函数<sup>[7-9]</sup>,但 有的目标函数由于过于复杂,约束条件多,且有时很不实用,给 优化带来了困难。而神经网络不依赖于物理模型,可以避免繁 琐的数学推导,容易建立起损伤检测目标函数。为避免寻求损

收稿日期:2011-08-02;修回日期:2011-09-16 基金项目: 江西省自然科学基金资助项目(2010GZS0043);江西省教育厅科技计划基金 资助项目(GJJ10437)

作者简介:谢建宏(1971-),男,江西高安人,副教授,博士,主要研究方向为测控技术、智能系统、信息处理、仿生智能计算(jhxie2006@126. com).

伤检测目标函数的困难,同时也为避免传统神经网络的固有缺陷,本文针对压电智能复合材料层板,基于小波核函数的近似 正交性及其具有的能够以很高精度逼近任意非线性函数的特性,以及最小二乘支持向量机(least square support vector machine, LS-SVM),以其算法简单易实现等特点<sup>[10]</sup>,采用最小二 乘小波支持向量机(least square wavelet support vector machine, LS-WSVM)网络来建立其损伤检测目标函数,运用 QGA 对目 标函数进行优化。为加快算法的运算速度,将 LS-WSVM 以并 行方式与 QGA 相结合,从而构造并行量子遗传神经网络方法, 实现智能结构损伤检测传感器对应于其初始布置模式下的最 优配置。

### 1 最小二乘小波支持向量机

设函数  $h(x) \in L^2(R)$ ,满足允许条件:  $W_h = \int_0^\infty \frac{|H(\omega)|^2}{|\omega|}$ 

 $d\omega < \infty$  ( $H(\omega)$ )为h(x)的傅里叶变换),则称h(x)为一小波母函数。

由小波母函数h(x)进行伸缩和平移,则产生一小波函数 族 $h_{a,c}(x)$ :

$$h_{a,c}(x) = |a|^{-\frac{1}{2}}h(\frac{x-c}{a}) \quad a,c \in R, a \neq 0$$
(1)

其中:a和c分别表示伸缩因子和平移因子。

利用张量积理论<sup>[11]</sup>,对于一个多维小波函数,可以把它写成一维小波函数的乘积:

$$h(x) = \prod_{i=1}^{n} h(x_i)$$
(2)

其中: $x = (x_1, \dots, x_n)^T \in \mathbb{R}^n$ 。对于小波母函数 h(x),如果  $x, x' \in \mathbb{R}^n$ ,则内积小波核函数为

$$K(x,x') = \prod_{i=1}^{n} h(\frac{x_i - c_i}{a_i}) h(\frac{x'_i - c'_i}{a'_i})$$
(3)

根据平移不变核法则,则平移不变小波核函数为

$$K(x, x') = \prod_{i=1}^{n} h(\frac{x_i - x_i}{a_i})$$
(4)

基于小波核的最小二乘支持向量机(LS-WSVM),则是通 过预先选择的小波核函数将输入空间映射到一个高维特征空 间,并在这个特征空间中进行数据的融合。

设LS-WSVM 回归模型为

$$y(x) = \omega^{\mathrm{T}} \varphi(x) + b \tag{5}$$

该模型的优化问题为

$$\min_{\substack{\omega,b,\xi}} \quad J(\omega,\xi) = \frac{1}{2}\omega^{\mathrm{T}}\omega + \gamma \frac{1}{2}\sum_{i=1}^{l}\xi_{i}^{2}$$
  
s. t.  $y_{i} = \omega^{\mathrm{T}}\varphi(x_{i}) + b + \xi_{i}$  (6)

其中:γ>0 为实常数,控制对错分样本的惩罚程度。

为求解上述约束优化问题,构造如下 Lagrange 函数:

$$L(\boldsymbol{\omega}, \boldsymbol{b}, \boldsymbol{\xi}; \boldsymbol{\alpha}) = J(\boldsymbol{\omega}, \boldsymbol{\xi}) - \sum_{i=1}^{l} \alpha_i \left\{ \boldsymbol{\omega}^{\mathrm{T}} \boldsymbol{\varphi}(x_i) + \boldsymbol{b} + \boldsymbol{\xi}_i - y_i \right\}$$
(7)

其中: $\alpha_i$ 为 Lagrange 乘子。通过 L 对  $\omega_{,b}$ 、 $\xi_i$ 和  $\alpha_i$ 分别求偏导 并令其等于零,对式(7)进行优化并消除变量  $\omega$ 和  $\xi_i$ ,则上述 优化问题最终变为求解如下线性方程组:

$$\begin{bmatrix} 0 & 1_v^{\mathrm{T}} \\ 1_v & \Omega + I/\gamma \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}$$
(8)

其中: $1_v = [1;1;\dots;1] \in R^l, I \in R^{l \times l}$ 为单位阵,  $\alpha = [\alpha_1;\alpha_2;\dots;$ 

求解上述方程组,最终得到如下 LS-WSVM 回归模型:

$$y(x) = \sum_{i=1}^{l} \alpha_i \prod_{j=1}^{n} h(\frac{x_j - x_j^{(i)}}{a_j^{(i)}}) + b$$
(9)

其中: $x = (x_1, \dots, x_n)^{\mathrm{T}} \in \mathbb{R}^n, x_j^{(i)}$ 表示第*i*个训练样本的第*j* 个分量。

满足允许性条件的小波母函数很多,这里选用 Morlet 小波 母函数,该小波是余弦调制的高斯波,时频域分辨率都很高,其 表达式为

$$h(x) = \cos((1.75x)\exp((-x^2/2))$$
(10)

### 2 量子遗传算法

量子遗传算法(QGA)是量子计算与遗传算法相结合的产物。它建立在量子态矢量表述基础上,用量子位(quantum bit, Qubit)编码来表示染色体,用量子旋转门和量子非门来实现染 色体的更新,从而实现对目标问题的优化求解<sup>[12]</sup>。

1) 量子位编码

在 QGA 中,染色体不是用确定性的值(如二进制数、浮点数或符号等)表示,而是用量子位表示。一个量子位不仅可表示11>或10>两种状态,而且可表示这两种状态之间的任意中间态,即11>和10>的不同叠加态,因此一个量子位的状态可表示为

$$|\psi\rangle = \alpha |0\rangle + \beta |1\rangle \tag{11}$$

其中:α和β可以是复数,表示相应状态的概率幅,且满足下列 归一化条件:

$$|\alpha|^{2} + |\beta|^{2} = 1 \tag{12}$$

其中: $|\alpha|^2$ 表示|0>的概率, $|\beta|^2$ 表示|1>的概率。

对于多状态基因,则可以采用如下多量子位来编码:

$$p_{j}^{t} = \begin{bmatrix} \alpha_{11}^{t} \cdots \alpha_{1m}^{t} \\ \beta_{11}^{t} \cdots \beta_{1m}^{t} \end{bmatrix} \begin{bmatrix} \alpha_{21}^{t} \cdots \alpha_{2m}^{t} \\ \beta_{21}^{t} \cdots \beta_{2m}^{t} \end{bmatrix} \cdots \begin{bmatrix} \alpha_{n1}^{t} \cdots \alpha_{nm}^{t} \\ \beta_{n1}^{t} \cdots \beta_{nm}^{t} \end{bmatrix}$$
(13)

其中: $p_j^t$ 代表种群的第t代、第j个个体的染色体;n为染色体的基因个数;m为编码每一个基因的量子位数。

采用这种方式,一个 m 量子位含单个基因的染色体可同 时表达 2<sup><sup>m</sup></sup>种状态。由于量子位可用于表述线性叠加态,这使 QGA 比传统遗传算法(TGA)具有更好的种群多样性。而且随 着  $\alpha^2$  或  $\beta^2$  逐渐靠近 1 或 0,量子染色体逐渐收敛到单一的状 态,种群的多样性也随之减小,算法收敛。

2) 量子旋转门

TGA采用交叉、变异等操作来保持种群的多样性,而 QGA 采用量子门作用于量子态概率幅的方式来保持种群的多样性。 在 QGA 中,由于染色体的状态处于叠加或纠缠状态,因而其遗 传操作主要是将构造的量子门作用于量子叠加态或纠缠态的 基态,使其相互干涉,相位发生改变,从而改变各基态的概率 幅。量子门是一种可逆门,能表示成一种保范算子 U 对量子 位基态的运算,且该保范算子 U 满足条件 U<sup>+</sup> U = UU<sup>+</sup>,其中 U<sup>+</sup> 是 U 的厄密共轭伴随矩阵。目前,有许多种量子门,如非 门、控制非门、旋转门、哈达玛门等。在 QGA 中,主要采用量子 旋转门,即

$$U = \begin{bmatrix} \cos \theta_i & -\sin \theta_i \\ \sin \theta_i & \cos \theta_i \end{bmatrix}$$
(14)

采用量子旋转门实现更新操作表示为

$$\begin{bmatrix} \alpha'_i \\ \beta'_i \end{bmatrix} = U \cdot \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix}$$
(15)

其中: $[\alpha_i \beta_i]^T$ 为染色体中第*i*个基因, $[\alpha'_i \beta'_i]^T$ 为通过旋转 门更新后的新基因; $\theta_i(i=1, 2, ..., n)$ 为量子旋转门的旋转 角,其大小决定算法收敛的速度和效率,符号(正或负)决定算 法收敛的方向。旋转角 $\theta_i$ 的大小和方向的确定采用如下调整 策略: $\theta_i = \Delta \theta_i \cdot s(\alpha_i, \beta_i)$ 。其中 $\Delta \theta_i \pi s(\alpha_i, \beta_i)$ 分别表示旋转 的角度和方向,取值如表1所示,表中"\*"表示可以取任意 值。该调整策略将待调整个体当前测量值的适应度f(x)与已 保存的最优解的适应度f(b)进行比较,如果f(x) > f(b),则调 整个体中相应量子位,使概率幅对( $\alpha_i, \beta_i$ )向着有利于 $x_i$ 出现 的方向演化;反之,如果f(x) < f(b),调整个体中相应量子位, 使概率幅对( $\alpha_i, \beta_i$ )向着有利于b出现的方向演化。

表1 旋转角调整策略

-							
x <sub>i</sub>	$b_i$	f(x) > f(b)	$\Delta \theta$	$s(\alpha_i, \beta_i)$			
				$\alpha_i  \beta_i > 0$	$\alpha_i  \beta_i < 0$	$\alpha_i = 0$	$\beta_i = 0$
0	0	*	0	*	*	*	*
1	1	*	0	*	*	*	*
0	1	false	delta	+ 1	- 1	0	$\pm 1$
0	1	true	delta	- 1	+ 1	$\pm 1$	0
1	0	false	delta	- 1	+ 1	± 1	0
1	0	true	delta	+ 1	- 1	0	$\pm 1$

表1中,delta 为每次调整的角步长,必须合理选取,delta 值太大,算法容易陷入局部极值而出现早熟现象;delta 值太 小,算法的搜索速度就很慢,甚至会处于停滞状态。本文采用 动态调整 delta 的策略,即根据遗传代数的不同,使 delta 值的 大小在 $[0.005\pi, 0.1\pi]$ 之间动态调整,取;

delta = delta<sub>min</sub> + (delta<sub>max</sub> - delta<sub>min</sub>) cos ( $t/2t_{max}$ ) (16) 其中:t 和  $t_{max}$ 分别为当前进化代数和最大进化代数。

3)算法流程

a)初始化。产生初始种群  $P(t) = \{p_1', p_2', ..., p_k'\}$ 。其中:k是种群的大小,即种群由 k 个个体组成; $p_j'(j=1, 2, ..., k)$  为 种群的第 t 代的一个个体,由式(13)定义。在初始化时, $\alpha$ 、 $\beta$ 均可取  $1\sqrt{2}$ ,表示在初始搜索时所有状态均以相同的概率 进行。

b)根据P(t)中概率幅的取值情况构造出 $Q(t):Q(t) = [q'_1,q'_2,...,q'_k]_o$ 

c)用适应度评价函数对 Q(t)中的每个个体进行评价,并 保留此代中的最优个体。若获得了满意解,则算法终止;否则, 转入 d)继续进行。

d)使用恰当的量子旋转门U(t)更新P(t)。

e)遗传代数 t = t + 1,算法转至 b)继续进行。

#### 3 仿真实例

采用计算机数值仿真方法,对如图 1 所示的压电智能复合 材料层板进行低速冲击仿真实验。复合材料层板材料为碳纤 维/环氧树脂(Gr70%-Epoxy30%)正交各向异性材料,层板的 铺层形式为 $(0/90)_s$ ,层板的几何尺寸为: $L_x = 400 \text{ mm}, L_y = 320 \text{ mm}, L_z = 0.5 \text{ mm} \times 4$ 层。层板四边简支,且层板表面粘贴有 9 块用做传感器的压电片,压电片的布置位置如图 1 所示。





实验在复合材料层板 85 个不同位置分别进行低速冲击仿 真实验,获取不同冲击位置下的各传感器的瞬态响应信号,并 进行特征(最大值与最小值)提取。若将各传感器的信号特征 作为 LS-WSVM 网络的输入,而将与其对应的冲击损伤位置作 为 LS-WSVM 网络的输出,则可建立传感器响应与冲击损伤位 置之间的非线性关系,从而实现对冲击损伤位置的检测。由于 从每个传感器响应信号中提取了两个特征(最大值与最小 值),为此,在任一冲击位置下 9 个传感器共有 18 个特征量 (*s*(1),*s*(2),…,*s*(18)),故 LS-WSVM 网络的输入有 18 维,而 与其对应的 LS-WSVM 网络的输出——冲击损伤位置采用二 维坐标值,即横坐标值 *x* 和纵坐标值 *y*。将上述 85 组仿真实验 数据中的 49 组用于训练 LS-WSVM 网络,而另 36 组用于 LS-WSVM 网络测试网络,如表 2 所示。

表2 网络训练样本与测试样本

样本 类型	样本 个数 <u>P</u>	输入样本						
		传感器1			传感器 9		输出样本	
		$s_p(1)$	$s_p(2)$		$s_p(17)$	$s_p(18)$	$x_p$	$y_p$
训 练 样 本	1	-7.255 e - 2	2.746e - 1		-2.173e-2	1.452 e - 2	50	40
	2	-3.728e-2	3.371e-1		-1.727e-2	6.319e - 3	100	40
	48	– 1.727e – 2	6.319e-3		-3.728e-2	3.371e – 1	300	280
	49	-2.173e-2	1.452 e - 2		-7.255 e - 2	2.746e – 1	350	280
测试样	1	-1.17e-2	3.96e - 1		-1.34e-2	2.75e-3	75	60
	2	-1.17e-2	3.29e - 1		-6.19e-3	4.27e-3	125	60
	35	-6.19e-3	4.27e-3		-1.17e-2	3.29e - 1	275	260
	36	-1.34e-2	2.75e-3		-1.17e-2	3.96e – 1	325	260

应用上述 QGA,基于 LS-WSVM 损伤位置检测问题,在如 图1中所示的9个传感器的布置位置中优化布置 n(3≤n≤9, n 对应为 QGA 中个体染色体的基因个数)个传感器,以实现传 感器对应于其初始布置模式下的最优配置。为加快算法的运 算速度,LS-WSVM 采用并行方式与 QGA 相结合,从而构造并 行量子遗传神经网络方法,其优化流程如图 2 所示。优化目标 函数采用如下所示的冲击损伤位置检测误差(网络测试误差) 函数:

$$g(x,y) = \frac{\frac{1}{p_0} \sum_{p=1}^{p_0} |x_p - x_p| \cdot \frac{1}{p_0} \sum_{p=1}^{p_0} |y_p - y_p|}{A}$$
(17)

其中: $x_p$ 、 $y_p$ 为网络实际输出: $x_p$ 、 $y_p$ 为网络理想输出, $p_0 = 36$ (测试样本数):A为复合材料层板面积400 mm×320 mm。

将上述损伤位置检测误差函数的倒数作为 QGA 的适应度 函数,即f(x,y) = 1/g(x,y)。根据该适应度函数,采用上述并 行量子遗传神经网络方法,分别对传感器数目 $n=3 \sim 9$ 的情况 进行传感器的优化布置,最后得到的不同数目传感器的最优布 置位置分别如表3所示。这些结果表明,由于实验件结构及边 界条件等的对称性,故不同数目传感器的最优布置位置也基本





### 图2 并行量子遗传神经网络优化流程

不同数目传感器的最优布置位置所对应的 QGA 的适应 度、LS-WSVM 的冲击损伤位置检测误差分别如表3 所示。表3 表明,随着所选用传感器数目的增加,其最优个体(最优布置 位置)对应的适应度(损伤检测误差的倒数)也依次增大,即检 测的效益提高了,但随着传感器数目的增加,其成本也必将加 大。综合考虑成本与效益的因素,对比分析表3 中不同的传感 器数目及其对应的最优个体的适应度等数据,建立如下反映成 本(传感器数目)—效益(适应度)的综合评价指标为

$$h(x,y) = \frac{f(x,y)}{n} \tag{18}$$

其中: f(x,y)为适应度值,n为传感器数目。根据式(18)可计 算不同传感器数目时最优个体的综合评价指标(表3)。由表 3可知,当n=7时,其综合评价指标最大为324.67,即说明n= 7为传感器的最优配置数目,其相应的最优布置位置如图3所 示。图3即为对应于图1所示的传感器初始布置模式下的最 优配置。对于更多传感器的初始布置模式,采用该方法可有效 减少传感器的数量,从而降低成本。n=7时,该方法中QGA 的优化性能跟踪图如图4所示。采用TGA同样对上述问题进 行分析,得最优配置结果与QGA优化结果相同,其优化性能跟 踪图如图4所示。该优化性能跟踪图表明,相比于TGA,该 QGA 具有较好的寻优能力和收敛速度。

表 3 不同数目传感器的最优布置位置及其 相应的 f(x,y)、g(x,y)、h(x,y)

传感器 数目 n	最优布置位置 (最优个体)	适应度 <i>f</i> (x,y)	冲击损伤位置 检测误差 g(x,y)/%	综合指标 h(x,y)
3	(1,3,7), $(1,3,9)(1,7,9)$ , $(3,7,9)$	578.03	0.173	192.68
4	(1,3,7,9)	1 098.9	0.091	274.73
5	(1,3,5,7,9)	1 219.5	0.082	243.90
6	(1,2,3,7,8,9)	1 470.6	0.068	245.10
7	(1,3,4,5,6,7,9)	2 272.7	0.044	324.67
8	(1,2,3,4,5,6,7,9) (1,3,4,5,6,7,8,9)	2 439.0	0.041	304.88
9	(1,2,3,4,5,6,7,8,9)	2 857.1	0.035	317.46

#### 4 结束语

智能结构是一个多传感器体系结构,多传感器的优化配置 涉及到成本与效益的因素,对其进行研究具有重要的意义。针 对压电智能复合材料层板,基于损伤检测问题,采用最小二乘 小波支持向量机(LS-WSVM)网络建立损伤检测目标函数,运 用量子遗传算法对目标函数进行优化,并将 LS-WSVM 以并行 方式与量子遗传算法相结合,从而构造并行量子遗传神经网络 方法,实现对智能结构损伤检测传感器对应于其初始布置模式 下的最优配置。对于更多传感器的初始布置模式,采用该方法 可有效减少传感器的数量,从而降低成本。相比于传统遗传算 法,该方法中量子遗传算法具有较好的寻优能力和收敛速度。



参考文献:

- [1] 谢建宏,张为公. 智能材料结构的研究与发展[J]. 传感技术学报,2004,17(1):164-167.
- [2] AZARBAYEJANI M, EI-OSERY A I, REDA TAHA M M. Entropybased optimal sensor networks for structural health monitoring of a cable-stayed bridge[J]. Journal of Smart Structures and Systems, 2009,5(4):483-494.
- [3] 黄友锐. 智能优化算法及其应用[M]. 北京: 国防工业出版社, 2008.
- [4] TONY H. Quantum computing: an introduction [J]. Computing and Control Engineering Journal, 1996, 10(3):105-112.
- [5] STASZEWSKI W J, WORDEN K. Signal processing for damage detection, in: health monitoring of aerospace structures [M]. Chichester: John Wiley and Sons, 2004;163-206.
- [6] JOSH M B, AMIT S. Optimal sensor placement for enhancing sensitivity to change in stiffness for structural health monitoring [J]. Optimization and Engineering, 2008, 9(2):119-142.
- [7] SHI Z Y, LAW S S, ZHANG L M. Optimum sensor placement for structural damage detection [J]. Journal of Engineering Mechanics,2000,126(11):1173-1179.
- [8] GUO H Y, ZHANG L, ZHOU J X. Optimal placement of sensors for structural health monitoring using improved genetic algorithms [J]. Smart Materials and Structures, 2004, 13(3):528-534.
- [9] D'SOUZA K, EPUREANU B I. Sensor placement for damage detection in nonlinear systems using system augmentations [J]. American Institute of Aeronautics and Astronautic Journal, 2008, 46(10): 2434-2442.
- [10] XIE Jian-hong. Improved least square support vector machine for structural damage detection [C] //Proc of the 2nd International Conference on Computer Engineering and Technology. Chengdu; IEEE Computer Society, 2010;237-240.
- [11] ZHANG Q H, BENVENISTE A. Wavelet networks [J]. IEEE Trans on Neural Networks, 1992, 3(6): 889-898.
- [12] LV Y J, LIU N X. Application of quantum genetic algorithm on finding minimal reduct [C] //Proc of IEEE International Conference on Granular Computing. Washington DC: IEEE Computer Society, 2007: 728-733.