

基于支持向量回归机的 HHT 边界效应处理

李雪耀, 张汝波, 王 武

(哈尔滨工程大学 计算机科学与技术学院, 黑龙江 哈尔滨 150001)

摘 要:针对希尔伯特-黄变换中的边界效应,提出了基于支持向量回归机的时间序列预测方法.在支持向量回归机的应用当中,参数的选取对它的泛化性能有很大影响.在讨论了参数对支持向量回归机的泛化性能的影响基础上,提出了通过微粒群优化算法来优化支持向量回归机参数的方法,使得支持向量回归机在应用中能够自适应的选择最优参数,从而获得了更好的泛化性能,提高了在端点处的延拓精度,很好地抑制了端点效应.试验表明,该优化算法能够很好解决支持向量回归机的参数选取问题.通过与神经网络的延拓方法和黄等人的 HHTDPS 结果对比,基于支持向量回归机的时间序列预测方法可以更好地解决在希尔伯特-黄变换中存在的边界效应,得到的固有模态函数具有较小的失真.

关键词:边界效应;希尔伯特-黄变换;支持向量回归机;微粒群优化

中图分类号:TP18 **文献标识码:**A **文章编号:**1673-4785(2007)03-0039-06

End effects processing in HHT based on support vector regression machines

LI Xue-yao, ZHANG Ru-bo, WANG Wu

(College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China)

Abstract: In order to better restrain end effects in the Hilbert-Huang transform (HHT), a time sequence prediction technique is proposed based on support vector regression machines to improve time series prediction. In the application of support vector regression machines (SVRM), parameter selection has a great influence on generalization performance. So in this paper, the influence of parameters on the generalization of SVRM is discussed, and then a particle swarm optimization (PSO) algorithm is used to optimize parameters. Using this method, SVRM can select optimal parameters self-adaptively, so that higher generalization performance is obtained in applications, prediction accuracy is improved at both ends and the end effects are restrained effectively. In contrast to the neural network methods and HHTDPS proposed by Huang et al., the end effects can be restrained better and the Intrinsic Mode Functions have less distortion. Experiments show that this method can solve the problem of selecting parameters properly.

Key words: end effects; Hilbert-Huang transform; support vector regression machines; particle swarm optimization

希尔伯特-黄变换(Hilbert-Huang transform, HHT)是一种处理非线性非平稳信号的有效方法^[1-2],是基于对信号的经验模态分解(empirical mode decomposition, EMD)的一种方法.通过辨识信号固有的物理时间刻度,EMD能够提取出信号内所有的振动模态,即固有模态函数(intrinsic mode func-

tion, IMF),每个IMF都具有唯一的局部瞬时频率.通过对每个IMF进行希尔伯特变换,得到每一个IMF随时间变化的瞬时频率和振幅,最后可以得到信号的振幅-频率-时间分布,即信号的希尔伯特谱.由于分解是基于信号的局部特征的时间尺度,因而它能够应用在非线性和非平稳的信号处理中^[3-5].

在EMD的分解过程中,需要不断通过拟合信号的极值点得到信号在各个时刻的均值,而在边界拟合时,常会发生较大的摆动,出现边界效应问

收稿日期:2006-12-18.

基金项目:国家自然科学基金资助项目(60475016);哈尔滨工程大学
基础研究基金资助项目(HEUF04092).

题^[1]. 这种边界效应带来的误差会在求均值的过程中向内传播, 尤其对低频的 IMF 分量来说, 信号的极值点明显减少, 这种边界效应带来的影响将更加严重. 另外进行 Hilbert 变换时, 由于采用傅里叶变换而产生的频谱泄漏, 信号的 2 端也会出现严重的端点效应. 因此为了保证 HHT 的分解精度, 需要合理的解决在 HHT 中出现的端点效应. 解决办法有特征波法^[2]、波形匹配法^[7]、自回归算法^[8]、极值点延拓法^[9]、平行线延拓法^[10]、从原始数据序列构造奇偶延拓序列^[11]、镜像延拓^[6,12]及基于神经网络的时间序列预测^[13], 试验表明镜像延拓和神经网络预测的预测性能要优于其他算法^[14], 而且文献[2, 7-11]中的这些方法应用到实际的非平稳序列时预测精度都会急剧变差甚至不可用. 镜像延拓结果使得最后得到的极值点数是原来的 2 倍, 而 HHT 的计算复杂度主要取决于信号的极值点^[15], 镜像延拓使得 HHT 的时间复杂度提高为原来的 2 倍, 因此时间消耗增大很多. 神经网络的延拓可以预测非平稳序列, 但其具有局部最小值点、过学习、网络结构选取没有理论指导等缺点. 这些缺点在基于小样本的统计学习理论 (statistical learning theory, SLT) 的支持向量机中得到了很好的解决.

1 希尔伯特 - 黄变换

对一个给定的信号 $X(t)$, EMD 算法可以概括如下:

- 1) 确定出 $X(t)$ 上的所有极大值点和极小值点.
- 2) 将所有极大值点和所有极小值点分别用三次样条曲线进行拟合, 得到信号的上下包络线.
- 3) 计算出上下包络线的均值曲线.
- 4) 用原信号 $X(t)$ 中减去均值信号得到剩余分量.
- 5) 对剩余分量反复执行上述步骤直到剩余分量满足 IMF 信号的定义.
- 6) 反复执行上述筛选算法, 直到所有的 IMF 分量从原信号中筛选出来.

当 EMD 结束以后, 原信号可表示为

$$X(t) = \sum_{i=1}^n c_i + r_n. \quad (1)$$

将信号分解为固有模态函数后, 就可以分别对每一个 IMF 分量进行希尔伯特变换, 得到变化的频率和幅度. 从而原始信号可以表示成如下的形式:

$$X(t) = \operatorname{Re} \sum_{j=1}^n a_j(t) \exp(i \int f_j(t) dt). \quad (2)$$

式中: Re 是取实部. $f_j(t)$ 表示每个分量的瞬时频率, 它是一个关于时间变化的函数. 在此, 省略了信号的残余分量 r_n . 信号的幅度可以在三维空间表示

成时间和瞬时频率的函数, 时频平面上的幅度分布被称为希尔伯特时频谱 $H(\cdot, t)$, 或者简称为希尔伯特谱.

2 支持向量回归机

支持向量机 (SVMs) 是由 Vapnik 等人提出的一种新的机器学习方法^[17], 它基于小样本的统计学习理论, 支持向量机能够很好解决诸如小样本、非线性、高维和局部极小值等问题. 同时, 支持向量机还具有很高的泛化性能, 这些使得支持向量机已经成为了一个研究热点.

2.1 支持向量回归机简介

支持向量回归机 (SVRM) 的基本思想是通过一个非线性映射 ϕ 将数据 X 映射到高维特征空间 F , 并在这个空间进行线性回归. 即对于样本集:

$$S = \{(x_1, y_1), \dots, (x_l, y_l)\}, x_i \in R^n, y_i \in R, \quad (3)$$

非线性函数 ϕ 用来将原始的输入空间 R^n 映射到高维的特征空间. 回归的决策函数为

$$f(x) = \langle w, \phi(x) \rangle + b. \quad (4)$$

式中: $\phi: R^n \rightarrow F$, $w \in F$, w 为权向量, b 为阈值. 所以在高维空间 R^n 里的线性回归对于低维输入空间里的非线性回归. 通过结构风险最小化原则, 问题可以转化为求解如下的优化问题:

$$\min T(w, \xi^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*). \quad (5)$$

满足约束:

$$\begin{aligned} ((w \cdot x_i) + b) - y_i &\leq \xi_i, \\ y_i - ((w \cdot x_i) + b) &\leq \xi_i^*, \\ \xi_i, \xi_i^* &\geq 0. \end{aligned} \quad (6)$$

式中: $i=1, 2, \dots, l$. 参数 C 为正则化参数, 是松弛变量, 它等于在训练样本上的近似误差. C 和 ξ 都是需要定义的参数. 引入上式的对偶问题, 最优化问题可以写为

$$\begin{aligned} \max_{a(\cdot)} \sum_{i=1}^l y_i (a_i^* - a_i) - \frac{1}{2} \sum_{i,j=1}^l (a_i^* - a_i) (a_j^* - a_j) \\ K(x_i, x_j) - \sum_{i=1}^l (a_i^* + a_i). \end{aligned} \quad (7)$$

满足约束:

$$\sum_{i=1}^l (a_i^* - a_i) = 0 \text{ 和 } 0 \leq a_i^*, a_i \leq \frac{C}{l}. \quad (8)$$

式中: $K(\cdot)$ 为核函数, 求解该最优化问题可得到决策函数式 (4) 中的 w 和 b :

$$w = \sum_{i=1}^l (\xi_i - \xi_i^*) \phi(x_i). \quad (9)$$

$$b = \begin{cases} y_j - \sum_{i=1}^l (a_i^* - a_i) K(x_i, x_j) + \sigma_j & \begin{cases} 0, \frac{C}{l} \end{cases} \\ y_k - \sum_{i=1}^l (a_i^* - a_i) K(x_i, x_k) - \sigma_k & \begin{cases} 0, \frac{C}{l} \end{cases} \end{cases} \quad (10)$$

由上述推导可构造决策函数:

$$f(x) = \sum_{i=1}^l (a_i^* - a_i) K(x_i, x) + b. \quad (11)$$

在支持向量机中存在很多核函数可供选择使用,但常用的核函数是径向基核函数 RBF:

$$K(x_i, x_j) = \exp\left[-\frac{\|x_i - x_j\|^2}{2}\right]. \quad (12)$$

Keerthi 和 Lin 研究表明^[18]使用 RBF 核函数是一个很好的选择.文中采用了 RBF 核函数,下文中涉及到的核参数均是指 RBF 核函数中的 σ .

2.2 基于微粒群优化算法的 SVM 参数选取

在支持向量机中,存在 3 个参数: C 、 σ 和 γ . 这些参数对 SVRM 的泛化能力有很大的影响.核函数参数 σ 确定了映射函数和特征空间^[19],核参数的改变实际上是隐含地改变映射函数从而改变数据在高维特征空间分布的复杂程度.正则化参数 C 的作用是在确定的特征空间中对学习机的置信范围和经验风险的比例取折中.当 C 的取值大时,表示对经验误差的惩罚大,学习机的复杂度大而经验风险值较小.而 σ 等于在训练样本上的近似误差,一般来说, σ 较大,则支持向量较少,解越具有稀疏性.然而较大的 σ 也能够降低在训练样本上的近似精度.从这个意义上说,可以把 σ 看作对解的稀疏性和对数据的逼近程度的折中^[20].

尽管参数对 SVRM 的性能十分重要,但直到现在,参数选取仍没有得到很好的解决.很多参数选取方法都是基于经验的,以至于不能自适应于各种不同的问题.本文提出了通过微粒群优化算法来解决 SVRM 中的参数选取问题.与其他的参数选取方法相比,这种方法简单却高效.微粒群算法是基于群体智能的一种进化优化方法,由 Eberhart 和 Kennedy 于 1995 年提出^[21],它具有如下明显的特点:1) 粒子在解空间随机产生,并在整个解空间内搜索;2) 粒子具有记忆能力,以前搜索的信息不会随种群改变而被破坏;3) 粒子并行搜索,并通过各个粒子间的最优点共享信息;4) 微粒群算法具有概念简单、容易实现并且需要调整的参数少的优点.现已被应用于函数优化、神经网络训练、模糊系统控制以及其他遗传算法的应用领域.

微粒群算法采用速度—位置($v-x$)搜索模型,粒子群算法中每个粒子 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 就是解

空间(D 维)中的一个解,解的优劣程度由适应度函数 $F(x)$ 决定.每个粒子所经历的最好位置,叫做个体极值(p_{best}),整个群体所经历的最好位置,叫做全局极值(g_{best}).粒子通过这 2 个极值更新自己的速度(v_{id})和位置(x_{id}),即

$$\begin{aligned} v_{id} &= w \times v_{id} + c_1 \times \text{rand}() \times (p_{bestid} - x_{id}) + \\ &\quad c_2 \times \text{Rand}() \times (g_{best} - x_{id}), \\ x_{id} &= x_{id} + v_{id}, \quad i = 1, 2, \dots, M. \end{aligned} \quad (13)$$

式中: M 为粒子的群体规模; d 是每个粒子的维数,等于要优化的参数的个数; c_1 与 c_2 是学习因子,可视为加速常数,表示每个粒子受 p_{best} 和 g_{best} 位置吸引的加速项的权重,一般取 $c_1 = c_2 = 2$; $\text{rand}()$ 和 $\text{Rand}()$ 是 $[0, 1]$ 上的随机数; w 为惯性权重,较大则算法具有较强的全局搜索能力,较小则算法倾向于局部搜索.对于这些参数的确定,可以从文献^[22]中得到一些指导.

使用 PSO 来优化 SVRM 的参数时,适应度函数的设计要保证 SVRM 能够获得较好的泛化能力,即要使 SVRM 获得小的错误率和具有简单的结构.因此适应度函数可以定义为

$$F_i = f_{\text{error}} + K \times \frac{N_{sv}}{N} \times (1 - f_{\text{error}}). \quad (14)$$

式中: f_{error} 为以该粒子为参数的 SVRM 预测的结果与训练样本的绝对误差, N_{sv} 为支持向量的个数, N 为样本容量. $K \in [0, 1]$ 是一个调节参数,用来在精度和复杂性之间取折中.此时当支持向量的个数很少, N_{sv}/N 趋近 0 时,这种条件下支持向量机容易发生“欠学习”现象,模型的精度差、复杂度小,此时适应度函数近似为 f_{error} ,因此适应度函数使得粒子向提高模型精度的方向搜索最优参数.当支持向量的个数近似等于样本个数时,即 N_{sv}/N 趋近 1 时,这种条件下容易发生“过学习”现象,模型的精度高但复杂度很高,此时的适应度函数近似为 N_{sv}/N ,因此粒子会向降低模型的复杂度的方向搜索参数.因此该适应度函数有利于避免训练时容易发生的“欠学习”或“过学习”现象.

使用微粒群优化算法来优化 SVRM 参数的算法具体实现为

- 1) 初始化微粒群.
- 2) 根据式(14)计算每一个粒子的适应度函数值,更新群体的个体极值 p_{best} ,用个体极值中的最小值更新全局极值 g_{best} .
- 3) 对每个粒子按照式(13)更新速度和位置.
- 4) 如果未达到结束条件,转 2);如果达到结束条件则算法终止,输出得到的最优参数值.

为了能更好的测试微粒群优化算法选取支持向量机参数的有效性,本文将算法应用于分类问题上,并将结果同 R tsch^[20]进行对比,选取的分类样本均来自于 R tsch 的数据库^[20].表 1 给出了具体的试验参数和分类错误率(以 %表示).

表 1 PSO 优化 SVM 的分类结果与 R tsch 试验结果比较
Table 1 comparison between SVM and R tsch s
classification results

	微粒群算法优化结果		R tsch 试验	
	C	γ	错误率 / %	错误率 / %
Banana	236.6	0.1456	11.67	12.75
Thyroid	672	0.6775	2.67	4
Splice	4.0	16	9.89	9.79
waveform	8.0	4	10.43	10.4565

试验结果表明,经优化的 SVRM 具有更好的泛化性能,说明 PSO 算法在支持向量机的参数选取中是有效的,而且与一般的网格搜索参数相比,PSO 具有如下优点:搜索速度快而且效果好,能够通过很少的适应度计算得到具有相似性能的参数,且实现简单,不需要先验知识.

2.3 基于 SVRM 的 HHT 端点延拓算法

时间序列预测就是对历史数据进行学习,得到一个非线性映射 f ,逼近数据中隐含的非线性机制 F ,这样 f 就可以作为理想中的预测器,来对时间序列预测.若已知一个时间序列 $\{x(t)\}$,在一定的条件下,对满足特定条件的 m ,存在一个光滑映射 $f:R^m \rightarrow R$.即对

$$X_t = \{x(t), x(t-1), \dots, x(t-(m-1))\}, \tag{15}$$

存在 f ,使得下式成立:

$$Y_t = x(t+1) = f(X_t), X_t \in R^m, Y_t \in R. \tag{16}$$

式中: m 为嵌入维数,需要预先设定.因此基于 SVRM 的时间序列预测原理就是利用样本集 (X_t, Y_t) 来训练 SVRM 得到映射 f ,利用 f 进行时间序列的预测,此时 f 即 SVRM 中决策函数式(11).在确定 f 以后,就可以进行时间序列预测了.预测的长度取过信号端点外能够出现 2 个极值点即可.

文中基于 SVRM 的 HHT 端点延拓算法为

1) 将时间序列按照式(15)和式(16)映射新的序列 $S = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_t, Y_t)\}, x_i \in R^m, y_i \in R$.

2) 把 S 看作训练样本,对训练样本进行归一化预处理,用微粒群算法选择支持向量回归机的参数.

3) 利用得到的参数和训练样本对支持向量回归机进行训练,由式(11)得到决策函数 f .

4) 利用 f 对信号 2 端进行时间序列预测,实现信号的端点延拓.

对延拓之后的数据可进行拟合包络线或进行希尔伯特变换,然后再不断丢弃信号端点以外的数据从而将产生的端点效应排除在数据以外,达到抑制端点效应的目的.

3 仿真试验

在评价 SVRM 的预测的准确率时,采用平均绝对百分比误差(MAPE):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{|Y_t|}. \tag{17}$$

试验选用的信号使用的是白噪声来“污染”纯净的语音信号得来的,信噪比 SNR = 5 dB,如图 1 所示.白噪声是一个随机变化的信号,而语音信号具有典型的非平稳特征,但 SVRM 在对该信号进行时间序列预测时,仍表现出了很好的性能.为了更好的说明 SVRM 的良好预测结果,将 SVRM 与 RBF 神经网络进行了比较.分别见图 2 和图 3.




图 1 SNR = 5 dB 的原始的语音信号

Fig. 1 The original speech signal with SNR = 5 dB




图 2 SVRM 的预测结果

Fig. 2 The results of SVRM




图 3 RBF 神经网络的预测结果

Fig. 3 The results of RBF network

图 2 和图 3 中的实线是原始的语音信号,点线是预测的数据,为了更好的对预测效果进行对比,只

对信号的末端进行了预测,预测数据为 150 个,试验采取的嵌入维数是 4. 从试验看出 RBF 神经网络预测结果比 SVRM 的结果有较大的数据波动. 分别计算预测的 MAPE,得到 SVRM 的 MAPE 是 1.101 2,而 RBF 神经网络的 MAPE 为 1.347 0,这也表明了 SVRM 的预测结果要优于 RBF 的预测结果.

将本算法应用到黄变换中,得到的 IMF 信号,并与 Huang 等人的软件 HHTDPS 产生的 IMF 进行比较. 得到的结果见图 4 和图 5. HHTDPS 是 NASA 的 Huang 等人自己推出的一款 HHT 应用软件,该软件为最新版本 1.4 版. 试验中采用的是 0.760 8 s 长的语音,采样率 11 025 Hz. 为了比较,试验中对应都选取第 4、5、6 阶的 IMF 信号进行比较. 从图 5 Huang 等人软件得到的 IMF 信号可以看出, HHTDPS 在端点处存在了程度较大的偏离,尤其是第 4 和第 6 阶 IMF 的起始处,端点飞翼现象很明显. 而图 4 中经过参数优化的 SVRM 处理端点效应以后,信号的端点效应得到了有效抑制,得到的 IMF 信号在端点处的偏离程度较小.




图 4 基于 SVRM 得到的 IMFs

Fig.4 IMFs based on SVRM




图 5 由 HHTDPS 得到的 IMFs

Fig.5 IMFs obtained by HHTDPS

4 结束语

研究了使用 SVRM 来解决在 HHT 存在的边界效应. 试验结果表明使用 SVRM 的延拓效果要好

于使用神经网络的结果. 这种原因主要在于 SVRM 使用的是结构风险最小化原则,而神经网络采用的是经验风险最小化原则,所以使得 SVRM 具有比神经网络要好的泛化性能. 在 SVRM 的应用当中,参数对泛化能力有着重要的影响,大部分的参数选择方法都基于先验知识,这经常在面临新的问题时不能选择出最优的参数. 针对 SVRM 这一应用难题,提出了采取 PSO 来优化支持向量回归机的参数,从而使得 SVRM 能够自适应的选择最优参数,在预测时能够取得好的泛化性能. 试验表明,PSO 算法有助于搜索到最优参数,并通过含噪语音信号进行试验,SVRM 能够较好地对时间序列进行预测,这为解决 HHT 中存在的边界效应问题提供了一个有效的方法.

致 谢

感谢美国 NASA Goddard 中心授权使用 HHTDPS 软件.

参考文献:

- [1] HUANG N E. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proc R Soc Lond. A, 1998, 454: 903 - 995.
- [2] HUANG N E. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis[J]. proc R Soc Lond, 2003, 459: 2317 - 2345.
- [3] VEL TCHEVA A D, GU EDES S C. Identification of the components of wave spectra by the Hilbert Huang transform method[J]. Applied Ocean Research, 2004, 26: 1 - 12.
- [4] RAY R R, ZHANG R C, LANCE V D, et al. On estimating site damping with soil non-linearity from earthquake recordings[J]. International Journal of Non-Linear Mechanics, 2004, 39(9): 1501 - 1517.
- [5] HUANG H, PAN J Q. Speech pitch determination based on Hilbert-Huang transform[J]. Signal Processing, 2006, 86: 792 - 803.
- [6] 赵进平. 异常事件对 EMD 方法的影响及其解决方法研究[J]. 青岛海洋大学学报, 2001, 31(6): 805 - 814.
ZHAO Jinping. Study on the effects of abnormal events to empirical mode decomposition method and the removal method for abnormal signal[J]. Journal of Ocean University of Qingdao, 2001, 31 (6): 805 - 814.
- [7] 盖 强, 马孝江, 张海勇, 等. 一种消除局域波法中边界效应的新方法[J]. 大连理工大学学报, 2002, 42(1): 115 - 117.
GAI Qiang, MA Xiaojang, ZHANG Haiyong, et al.

- New method for processing end effect in local wave method[J]. Journal of Dalian University of Technology, 2002, 42 (1) : 115 - 117.
- [8]张郁山, 梁建文, 胡聿贤. 应用自回归模型处理 EMD 方法中的边界问题[J]. 自然科学进展, 2003, 13 (10) : 1054 - 1059.
- ZHANG Yushan, LIANG Jianwen, HU Yuxian. The processing of end effects in EMD method by autoregressive model[J]. Progresses in Nature Science, 2003, 13 (10) : 1054 - 1059.
- [9]陈 忠, 郑时雄. EMD 信号分析方法边缘效应的分析[J]. 数据采集与处理, 2003, 18(1) : 114 - 118.
- CHEN Zhong, ZHENG Shixiong. Analysis on end effects of EMD method[J]. Journal of Data Acquisition and Processing, 2003, 18 (1) : 114 - 118.
- [10]熊学军, 郭炳火, 胡筱敏, 等. EMD 方法和 Hilbert 谱分析法的应用与探讨[J]. 海洋科学进展, 2002, 20 (2) : 12 - 21.
- XIONG Xuejun, GUO Binghuo, HU Xiaomin, et al. Application and discussion of empirical mode decomposition method and Hilbert spectral analysis method[J]. Journal of Oceanography, 2002, 20 (2) : 12 - 21.
- [11]ZENG K, HE M X. A simple boundary process technique for empirical mode decomposition[A]. Proceedings IGARSS 04[C]. [s.l.], 2004.
- [12]ZHAO J P, HUANG D J. Mirror extending and circular spline function for empirical mode decomposition method[J]. Journal of Zhejiang University (Science), 2001, 2(3) : 247 - 252.
- [13]邓拥军, 王 伟, 钱成春, 等. EMD 方法及 Hilbert 变换中边界问题的处理[J]. 科学通报, 2001, 46(3) : 257 - 263.
- DENG Yongjun, WANG Wei, QIAN Chengchun, et al. Boundary processing technique in EMD method and Hilbert transform[J]. Chinese Science Bulletin, 2001, 46 (3) : 257 - 263.
- [14]许宝杰, 张建民, 徐小力, 等. 抑制 EMD 端点效应方法的研究[J]. 北京理工大学学报, 2006, 26(3) : 196 - 200.
- XU Baojie, ZHANG Jianmin, XU Xiaoli, et al. A study on the method of restraining the ending effect of empirical mode decomposition[J]. Transactions of Beijing Institute of Technology, 2006, 26(3) : 196 - 200.
- [15]KIZHNER S, BLANK K F. On certain theoretical developments underlying the Hilbert-Huang transform [A]. 2006 IEEE Aerospace Conference Proceeding[C]. [s.l.], 2006.
- [16]CHUANG C C, SU S F, JENG J T, et al. Robust support vector regression networks for function approximation with outliers[J]. IEEE Trans Neural Netw, 2002, 13(6) : 1322 - 1330.
- [17]VLADIMIR N V. The nature of statistical learning theory[M]. New York: Springer, 1995.
- [18]KEERTHI S S, LIN C J. Asymptotic behaviors of support vector machines with Gaussian kernel[J]. Neural Computation, 2003, 15 (7) : 1667 - 1689.
- [19]SCHOL KOPF B, MIKA S, BURGESS C, et al. Input space versus feature space in kernel-based methods [J]. IEEE Transactions on Neural Networks, 1999, 10(5) : 1000 - 1017.
- [20]RA TSCH G, ONODA T, MFILLER K R. Soft margins for adaBoost [J]. Machine Learning, 2001, 42(3) : 287 - 320.
- [21]KENNEDY I, EBERHAN, R C. Particle swarm optimization[A]. Proceedings of IEEE International Conference on Neural Networks[C]. Piscataway, NJ, 1995.
- [22]SHI Y, EBERHART R C. Empirical study of particle swarm optimization[A]. Proceeding of Congress on Evolutionary Computation [C]. Washington DC, USA, 1999.

作者简介:



李雪耀,男,1944年生,教授,硕士生导师. 主要研究方向为计算机听觉、模式识别和信号处理. 曾获省部级科技进步奖3项,发表论文数十篇.

E-mail:lixueyao@hrbeu.edu.cn.



张汝波,男,1963年生,博士,教授,博士生导师. 主要研究方向为智能机器人软硬件体系结构、任务规划、路径规划、自主作业技术及强噪声背景下语音信号的检测与处理等. 发表论文100多篇,60多篇被SCI、EI、ISTP收录,出版专著5部.



王 武,男,1983年生,硕士研究生,主要研究方向为强噪声背景下的语音流检测.