

自适应支撑矢量机多用户检测

周伟达,张莉,焦李成

(西安电子科技大学雷达信号处理重点实验室,陕西西安 710071)

摘要: 最佳多用户检测器是非线性检测器,特征码不完全正交时,线性检测器很难逼近最佳检测器.通常无线通信信道具有时变性,要求多用户检测算法具有自适应性.本文提出了一种自适应支撑矢量机方法,并把它用于信道时变情况下的多用户检测.一方面由于支撑矢量机引入的结构风险不仅包括经验风险最小化,而且又包括了容量控制项,这使得支撑矢量机多用户检测推广能力较好且对训练要求的样本数也大大下降;另一方面由于支撑矢量机的非线性特性可以比线性检测器更好地逼近最佳检测器.仿真结果较好地证实了该方法的可行性和有效性.

关键词: 支撑矢量机; CDMA; 多用户检测

中图分类号: O 23. 5 **文献标识码:** A **文章编号:** 0372-2112 (2003) 01-0092-06

Adaptive SVM for Multi-User Detection

ZHOU Wei-da, ZHANG Li, JIAO Li-cheng

(Key Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: Due to non-orthogonality of signature sequence, performance of linear detector is much less than that of the optimum detector that is nonlinear. Structural risk introduced in SVMs leads to more generalization and less training samples than the other learning models and the nonlinear SVMs can approach optimum multi-user detector. In this paper, SVMs are used for multi-user detection. Considering the variation with time of the wireless channel, an adaptive SVM is presented for multi-user detection. The results of simulation demonstrate the feasibility and validity of this method.

Key words: support vector machine (SVM); CDMA; multi-user detection

1 引言

码分多址技术以其软容量、信道资源动态分配和高抗干扰能力等诸多优良特性,成为了第三代移动通讯的首选.同时也因为其高度复杂的信号处理要求引起了信号处理界的广泛关注.多用户检测技术是通讯技术中的一个新前沿,它的引入是为了更好地解决无线通讯中的同信道干扰,从而实现通信容量的增加.目前国内外已经提出许多多用户检测的算法^[1~3].

影响无线信道特性的因素很多且十分复杂,一般是时变的,尚无法准确建模.这也是目前第三代个人通信领域的一个难点.针对信道的时变性,最好就是令算法具有自适应性.目前自适应的多用户检测方法主要有:自适应 Minimum Mean Squared Error (MMSE) 多用户检测器^[4,5],自适应解相关多用户检测器^[6],自适应最小输出能量 Minimum Output Energy (MOE) 多用户检测器^[7],自适应子空间多用户检测器^[8,9]等,此外还有具体针对某一信道提出的自适应算法^[10,11].这些算法要求已知的信息各有不同,性能也各有千秋.本文提出的自适应支撑矢量机多用户检测算法仅要求少量训练序列,性能上能较

好地逼近最佳多用户检测器.统计学习理论^[12,13]是二十世纪60年代开始发展的一门研究机器学习的新学科,到90年代初已趋向成熟.以其为理论基础建立的支撑矢量机^[14]是一种新兴的学习模型.它与一般学习机相比具有更好的推广能力^[15,16]、高维处理能力、方便简洁的非线性处理能力、收敛过程无局部极小和拥有众多大规模的快速算法^[17~19].目前支撑矢量机正以其良好的应用性能吸引越来越多机器学习、模式识别、信号处理等领域学者的关注.本文提出通过对惩罚因子的控制实现自适应的支撑矢量机算法,使其适用于时变样本.

2 非线性多用户检测

考虑如下的多用户检测同步模型,匹配滤波器之前的基带信号:

$$x(t) = \sum_{k=1}^K A_k b_k(j) s_k(t - jT) + n(t), t \in [jT, jT + T] \quad (1)$$

其中 T 为字符间隔; $\{b_k(j) \in \{-1, 1\}\}$ 是第 k 个用户发送的字符序列,假定字符序列在 $\{-1, 1\}$ 中等概率取值; A_k 表示第 k 个用户的信号幅值 ($\frac{1}{2} A_k^2$ 代表接收能量); $s_k(t), t \in [0, T]$

收稿日期:2001-11-13;修回日期:2002-07-16

基金项目:国家自然科学基金(No:60073053;60133010;69831040)

为扩频序列, $n(t)$ 为单位功率谱密度的高斯白噪声, K 为用户数. 对输入信号以 T_s 进行采样, 一般取 $T_s = T/N$, 其中 N 为扩频增益, 即采样速率等于码片速率. 在 $t \in [jT, (j+1)T]$ 时间内, 采样得到如下结果 (矢量形式):

$$x = sAb + n \tag{2}$$

其中 $A = \text{diag}(A_1, A_2, \dots, A_K)$, $s = (s_1, s_2, \dots, s_k)$, $b = [b_1, b_2, \dots, b_K]^T$ 和 $E[n n^T] = I$.

异步 DS-CDMA 的模型可以转换成类似的同步模型, 只是每个异步信号须等效成两个同步信号, 其特征码的数目增加了一倍, 各个特征码出现的先验概率减少一半, 一般其特征码之间的相关性也随之增加.

2.1 最佳多用户检测

多用户检测的任务就是要估计各个用户的字符序列 $b = [b_1, b_2, \dots, b_K]^T$. 多用户检测的方法可以从另一个角度粗略地分为两类: 多用户检测的信号处理方法和多用户检测的统计模式识别方法. 多用户检测的信号处理方法通常就是在某种准则下, 如最小均方误差 (MMSE) 准则, 最小输出能量准则 (MOE), 最大信噪比准则等, 估计字符 b 和 Ab . 一般信号处理的方法都是线性的, 即由一组经过优化或者自适应优化权值的滤波器来完成估计. 同时对于一般数字 DS-CDMA 系统, 字符序列都具有二值性, 多用户检测又可以被看成如下的统计模式识别问题.

对于 K 个用户的 CDMA 系统, 多用户检测可看成是如下的行为: 设泛函集 $\{f_i | f_i(x, \dots)\}$, 参数 \dots 不仅仅限制为矢量, 即泛函集 $\{f_i | f_i(x, \dots)\}$ 可以是普通的函数集, 也可以是规则集等抽象函数集. 多用户检测就是要寻找 K 个泛函 $f_i^* = f_i(x, \dots)$ $\{f_i | f_i(x, \dots)\}$, $i = 1, \dots, K$, 使得

$$f_i^* = \arg \min_{f_i \in \{f_i(x, \dots)\}} P\{b_i = -1 | b_i = 1\} P\{b_i = 1\} + P\{b_i = 1 | b_i = -1\} P\{b_i = -1\}, i = 1, \dots, K$$

其中 $b_i = \text{sgn}(f_i(x, \dots))$, 在一般 CDMA 系统中假设先验概率 $P\{b_i = 1\} = P\{b_i = -1\} = \frac{1}{2}$ 成立, 则上式可简化如下:

$$f_i^* = \arg \min_{f_i \in \{f_i(x, \dots)\}} P\{b_i = -1 | b_i = 1\} + P\{b_i = 1 | b_i = -1\}, i = 1, \dots, K \tag{3}$$

粗略地说, 多用户检测的模式识别方法就是在目标泛函集中寻找这样一个泛函, 它把含噪样本集以最小错误概率分开. 对于线性多用户检测, 目标泛函集为线性函数集; 而目标泛函集不是线性函数集的多用户检测, 称之为非线性多用户检测.

由于多用户检测的最终任务就是以最小的误码率检测各个用户的字符序列, 所以基于最小检测错误概率的准则, 是最直接的准则, 也是最优的准则, 通常统计模式识别方法都是基于该准则的; 而其他一些信号处理常用的准则, 如最大信噪比准则, 最小均方误差 (MMSE) 准则等, 只能是间接的准则, 或者说次优的准则. Verdu 于 1986 年提出高斯信道的 DS-CDMA 最佳多用户检测器^[1], 对于 K 个用户的 DS-CDMA 系统, 最佳多用户检测可以看成是一个具有 2^K 假设的假设检验问题, 或者说具有 2^K 类的多分类问题. 假设:

$$H_1: x = sAb + n \dots, b \in \{-1, 1\}^K \tag{4}$$

$$H_{2^k}: x = sAb + n$$

其最小错误概率检测:

$$b = \arg \max_b \exp \left[- \frac{x - sAb}{2} \right] \tag{5}$$

最佳多用户检测器可以直观地解释成, 对于 K 个用户的多用户系统, 对应 2^K 个类 (不同类的 b 不同), 假设每一类的先验概率相等, 则 x 属于 2^K 个类中哪个类的概率最大, 就判 x 属于该类, 即统计模式识别中的贝叶斯方法. 最小化:

$$b = \arg \min_b x - sAb \frac{1}{2} = \arg \min_b 2b^T A s^T x - b^T A s^T s A b \tag{6}$$

当信噪比较大时, 对于用户 i 最佳多用户检测器错误概率等价于两个对立决策区最接近的假设检验之间的错误概率, 即此时的最佳多用户检测器等价于关于用户 i 最接近的对立的两类样本集之间的最优分类. 其检测的错误概率:

$$P_i^* = Q \left[\frac{\min_{b \in \{-1, 1\}^K} \min_{d \in \{-1, 1\}^K, d \neq b_i} (sAb - sAd) / 2}{\sqrt{2}} \right] = Q \left[\frac{\min_{d \in \{-1, 0, 1\}^K, d \neq 1} \sqrt{2} A s^T s A}{\sqrt{2}} \right] \tag{7}$$

所以最佳多用户检测器的渐近有效性为:

$$i = \frac{1}{A_i} \min_{d \in \{-1, 0, 1\}^K, d \neq 1} \sqrt{2} A s^T s A \tag{8}$$

图 1 绘出了双用户最佳检测器, 从图上可以看出双用户最佳检测器在一定的局部区域, 相当于两个相邻最近的高斯正态分布的最佳分离, 在整个区域上为一非线性检测器. 对于两个或两个以上用户的 CDMA 系统, 若特征码之间的相关性不为 0, 则过原点的超平面是不可能达到这种最佳检测的.




图 1 绘出了双用户最佳检测器. 图中实线圆表示以圆心为均值, 以半径为方差的随机变量, 期望用户为 1

即线性多用户检测器在最小错误概率准则下存在着先天的缺陷, 而一般非线性检测器可以轻而易举地实现近似的最佳检测. 最佳多用户检测器的计算量随用户数的增加指数增长, 而且要求已知的量非常多, 如各个用户特征码, 信号的功




图 2 绘出了径向基网络双用户检测的结果, 隐节点数为 20, 用户信号和图 1 相同.

率, 迟延等, 所以最佳多用户检测器不是一种实用的检测器. 另外现已提出的非线性检测器如图 2 所示, 神经网络多用户检测器 (包括径向基神经网络, BP 网络, Hopfield 网络等^[20, 21]), 通常能达到较小的误码率, 但要求相当数量的训练序列. 为此我们将在本文中引入自适应支撑矢量机并把它用于多用户检测. 一方面支撑矢量机巧妙地引入核函数实现了非线性分类, 训练复杂度与样本维数无关; 另一方面由于支撑矢量机在经验风险和函数集容量之间作了一个折衷, 从而防止了过拟合, 提高了推广能力. 即只需少量的训练样本可以获得较高的检测误码率.

3 自适应支撑矢量机

对于线性分类问题, Vapnik 引入了结构风险函数^[13] (Structural Risk Function), 不仅使经验风险最小 $\sum_{i=1}^l \xi_i$, 而且包括容量控制项 $\frac{1}{2} \|w\|^2$:

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (9) \\ \text{s. t.} \quad & y_i((w \cdot x_i) + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, i = 1, \dots, l \end{aligned}$$

其中 C 为惩罚因子, 可取一正常数. 经验风险最小一般意味着对训练样本的检测错误概率最小; 容量控制可防止学习机的过拟合, 从而提高推广能力. 这是一个两难问题, 好的解决方法是在这两者之间取一个折衷. 求上述规划的 Wolfe 对偶, 最终可归结为求解如下的二次凸规划^[15].

$$\max \quad W(\lambda) = \sum_{i=1}^l \lambda_i - \frac{1}{2} \sum_{i,j=1}^l \lambda_i \lambda_j y_i y_j (x_i \cdot x_j) \quad (10)$$

$$\text{s. t.} \quad \sum_{i=1}^l \lambda_i y_i = 0 \quad (11)$$

$$\lambda_i \in [0, C], i = 1, \dots, l \quad (12)$$

最优的判决函数为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \lambda_i y_i (x_i \cdot x) + b \right] \quad (13)$$

上述优化的 KKT 条件^[15, 16]为:

$$\begin{cases} \lambda_i = 0 \Rightarrow y_i f(x_i) = 1 \\ 0 < \lambda_i < C \Rightarrow y_i f(x_i) = 1 \\ \lambda_i = C \Rightarrow y_i f(x_i) < 1 \end{cases} \quad (14)$$

当且仅当对于每一个 x_i 都满足 KKT 条件 (由 Lagrange 乘子确定) 时, 才是上述规划的最优解.

通过引入 Mercer 核函数的方法得到非线性支撑矢量机, 即在式 (10) 和 (13) 中用 $K(x, y)$ 代 (x, y) . 上述的优化为一半正定的二次规划, 现已有很多成熟的算法. 对于大规模问题, 可采用一些支撑矢量机快速算法: Chunking 算法^[17], Osuna 算法^[18]和序贯最优算法^[19]. 相比于一般的学习机, 支撑矢量机具有较好的推广能力, 适用于小样本的情况. 在获取样本代价较高的情形中, 它具有更高的竞争力.

一般对样本的学习模型中, 都假设样本独立同分布, 对于样本分布时变的情况是不适用的. 在本节中我们引入自适应支撑矢量机, 以适于时变样本的情况. 注意到式 (9) 中常数 C

的引入相当于惩罚因子, 一般支撑矢量机中不同训练样本对应的惩罚因子是相同的. 在此, 对不同的训练样本引入不同的惩罚因子. 粗略地说, 训练样本对应的惩罚因子越大, 要求学习机越精确地学习该样本; 惩罚因子越小, 该样本对学习过程起的作用越小, 当惩罚因子小到一定程度时, 可以直接从训练样本集中删除不计. 多用户检测的样本为一时间序列:

$$x(t+1), \dots, x(t+i), \dots, x(t) \quad (15)$$

共 $l+1$ 个独立同分布的样本. 令每一个样本对应的惩罚因子为 $(C_1, \dots, C_i, \dots, C_0)$, 如果 $C_1 \dots C_i \dots C_0$, 则意味着样本 $x(t+1), \dots, x(t+i), \dots, x(t)$ 对训练生成的判决函数的作用随时间逐渐减小, 即相当于逐渐遗忘. 一般遗忘的速率与实际情况相关, 可在实验中具体选定. 在自适应 RLS 盲多用户检测算法中采用指数遗忘速率: $C_i = C_0 e^{-i}$, $i = 1, \dots, l$; 为一小于 1 且接近于 1 的常数. 联想到时变信号分析中, 常用加高斯窗的技术. 在本文中, 引入高斯遗忘:

$$C_i = C_0 e^{-i^2/2\tau^2}, i = 1, 2, \dots, l \quad (16)$$

其中 τ 为平均遗忘时间. 如图 3 分别绘出了不同 τ 时的指数遗忘曲线和不同 τ 时的高斯遗忘曲线, 从图中可以看出高斯遗忘曲线呈现慢速遗忘, 快速遗忘和慢速遗忘三个阶段, 而指数遗忘一开始便是快速遗忘, 直至几乎全部遗忘. 当该样本对应的遗忘因子接近于 0 时, 该样本将被直接从训练样本中删除.

如果样本服从独立同分布, 则样本的获取可以在某一时间段内完成, 支撑矢量机也仅需一次训练. 如果样本分布时变, 则样本的获取也应该是随时间逐渐积累的, 支撑矢量机也需随时间多次训练, 根据某一时刻前后获取的样本训练的支撑矢量机只适用于对该时刻附近的样本进行检验. 由于无线通信信道的时变性, 多用户检测样本分布是时变的, 这要求检测器是自适应的. 实际中多用户检测的训练信号只能是陆续发送, 而且数量是有限的只占全部信号的极小一部分. 针对这种情况, 我们一方面在支撑矢量机中引入遗忘因子自适应的训练, 同时利用前一次支撑矢量机训练的结果, 为下一次训练设定初始值, 从而加快训练速率. 支撑矢量机需求解一个线性约束的凸二次规划, 若采用一般的数学优化方法, 其求解过程与一般的迭代算法存在同样的问题: 若初始时步长较大, 则训练后期将出现振荡而消耗大量训练时间, 若初始步长较小, 则训练过程过长; 另同样针对支撑矢量机提出的 Chunking 算法, Osuna 算法和 SMO 算法, 也同样存在上述问题, 特别是在结果非稀疏的情况. 注意到支撑矢量机所需求解的二次规划的凸性, 即不存在局部极小值, 所以合理的设置初始值将有效地减小求解的计算量.




图 3 实线绘出了从 100 - 550 均匀变化的高斯遗忘曲线; 虚线绘出了从 0.982 - 1 均匀变化的指数遗忘曲线

设多用户检测第 k 时刻按码片速率采样得

到的训练样本组为 $S^k = \{S_1^k, \dots, S_l^k\}$ 包含 $l > 0$ 个样本, 检验样本组为 T^k , 第 k 次总的训练样本 $x^k = \{x_{N-1}, \dots, x_i, \dots, x_0\}$, 共 Nl 个. 支撑矢量机各样本对应的遗忘因子 $C = [C_{N-1,1}, \dots, C_{N-1,l}, \dots, C_{i,1}, \dots, C_{i,l}, \dots, C_{0,1}, \dots, C_{0,l}]^T$ 始终保持不变, 其中 $C_{i,1} = \dots = C_{i,l} = e^{-i^2/2^2}$, $i = 0, \dots, N-1$, 由式(16)给出. 第 k 次训练得到的最优 Lagrange 乘子 $\lambda^k = [\lambda_{N-1,1}^k, \dots, \lambda_{N-1,l}^k, \dots, \lambda_{i,1}^k, \dots, \lambda_{i,l}^k, \dots, \lambda_{0,1}^k, \dots, \lambda_{0,l}^k]^T$, 及 KKT 条件 KKT^k . 设第 $k+1$ 时刻新获取的训练样本组为 $S^{k+1} = \{S_1^{k+1}, \dots, S_l^{k+1}\}$, 用 k 时刻的 KKT 条件 KKT^k 对其进行测试. 如果样本组 S^{k+1} 全部满足 KKT^k , 则说明第 $k+1$ 时刻样本分布未发生较大的变化, 不必进行第 $k+1$ 次训练, 总的训练样本组 $x^{k+1} = x^k = \{x_{N-1}, \dots, x_i, \dots, x_0\}$, 以及最优 Lagrange 乘子 $\lambda^{k+1} = \lambda^k = [\lambda_{N-1,1}^k, \dots, \lambda_{N-1,l}^k, \dots, \lambda_{i,1}^k, \dots, \lambda_{i,l}^k, \dots, \lambda_{0,1}^k, \dots, \lambda_{0,l}^k]^T$, 及 KKT 条件 $KKT^{k+1} = KKT^k$ 不必更新. 否则若样本组 S^{k+1} 存在部分或全部违背 KKT^k , 则说明第 $k+1$ 时刻样本分布发生了较大的变化, 所以更新总的训练样本组: $x^{k+1} = \{x_{N-1}, \dots, x_i, \dots, x_0\}$, $x_{i+1} = x_i$, $i = 0, \dots, N-1$ 和 $x_0 = S^{k+1}$; 同时按以下方法设定第 k 次训练的 Lagrange 乘子初值为

$$\lambda^k = [\lambda_{N-1,1}^k, \dots, \lambda_{N-1,l}^k, \dots, \lambda_{i,1}^k, \dots, \lambda_{i,l}^k, \dots, \lambda_{0,1}^k, \dots, \lambda_{0,l}^k]^T$$

其中

$$\begin{cases} \text{if } \lambda_{i,j}^k > C_{i+1,l}; & i+1, l = C_{i+1,l} \\ \text{if } \lambda_{i,j}^k < C_{i+1,l}; & i+1, l = \lambda_{i,j}^k \end{cases}, i = 0, \dots, N-2; j = 1, \dots, l$$

为了使初始值 Lagrange 乘子 λ^k 为一可行解, 即 $\sum_{i=0}^{N-1} \sum_{j=1}^l y_{i,j} \lambda_{i,j}^k = 0$, $y_{i,j}$ 为对应训练样本 $x_{i,j}$ 的期望输出.

$$\sum_{i=0}^{N-1} \sum_{j=1}^l y_{i,j} \lambda_{i,j}^k = \sum_{i=0}^{N-1} \sum_{j=1}^l y_{i,j} \lambda_{i,j}^k + \sum_{j=1}^l 0 \cdot \lambda_{j,l}^k - \sum_{j=1}^l 0 \cdot \lambda_{j,l}^k = 0$$

其中 I^+ 为样本组 S^{k+1} 中违背 KKT^k 正样本 (期望输出为正) 序号集, 其数目 $|I^+| = l^+$; I^- 为样本组 S^{k+1} 中违背 KKT^k 负样本 (期望输出为负) 序号集, 其数目 $|I^-| = l^-$.

$$\begin{cases} 0, j = \left[\sum_{i=0}^{N-1} y_{i,j} \lambda_{i,j}^k \right] / l^-, j \in I^-; \\ 0, j = 0, j \in \{1, \dots, l\} \setminus I^-; \\ \text{if } \sum_{i=0}^{N-1} y_{i,j} \lambda_{i,j}^k > 0 \\ \text{否则} \begin{cases} 0, j = \left[- \sum_{i=0}^{N-1} y_{i,j} \lambda_{i,j}^k \right] / l^+, j \in I^+; \\ 0, j = 0, j \in \{1, \dots, l\} \setminus I^+; \\ \text{if } \sum_{i=0}^{N-1} y_{i,j} \lambda_{i,j}^k < 0 \end{cases} \end{cases}$$

以 λ^k 为初值, 对支撑矢量机进行训练. 循环上述过程对样本进行自适应的训练和检测.

4 实验仿真

4.1 自适应支撑矢量机用于双螺旋线的识别

双螺旋线分类是一个典型的模式识别问题^[22], 一般训练过程是批处理的. 下面我们用自适应支撑矢量机对双螺旋线

进行分类.

$$\begin{cases} \text{螺旋线 1} \\ \text{螺旋线 2} \end{cases} \begin{cases} x_1 = (2(0.1k) + 1) \cos(0.1k) \\ y_1 = (2(0.1k) + 1) \sin(0.1k) \\ x_2 = (2(0.1k) + 5) \cos(0.1k) \\ y_2 = (2(0.1k) + 5) \sin(0.1k) \end{cases}$$

上述双螺旋线均随着 k 的增加向外扩展, 假设样本是随 k 一组一组地获得的. 从图 4 中可以看出双螺旋线样本分布可以看成是随 k 变化的, 自适应支撑矢量机的分类界面也随之相应变化, 能够较好地识别训练时刻附近的样本, 这是符合设计要求的. 特别对于线性支撑矢量机本来是不可能很好地识别双螺旋线的, 自适应线性支撑矢量机就能较好地识别. 另外通过比较训练样本组内具有遗忘特性 (实线) 和不具有遗忘特性 (虚线), 可以发现具有遗忘特性的支撑矢量机对训练时刻左右的样本识别较好, 而对先前出现的样本识别较差, 这正是说明遗忘特性起了作用, 满足了设计的目的.

4.2 自适应支撑矢量机用于双用户 CDMA 识别

扩频增益为 2, 用户 1 的特征序列为 $(0, 1)$, 幅度 $A_1 = 1$; 用户的特征序列为 $(\sqrt{2}/2, \sqrt{2}/2)$ 幅度 A_2 从 1-6 连续递增; 两用户的特征序列不完全正交. 高斯白噪声方差为 $\sigma^2 = 0.5$. 从图 5 中, 我们同样可以看出, 遗忘因子已经在自适应支撑矢量机中发挥了作用, 同时我们还能发现, 自适应支撑矢量机一方面由于其非线性, 另一方面由于遗忘了先前的样本, 从而分界面更接近于最佳多用户检测器.

4.3 自适应支撑矢量机用于多用户检测

我们把自适应支撑矢量机用于 DS-SS-SSMA 多用户检测, 共作了四个实验, 文中给出的实验结果均为 30 次实验的平均.

第一个实验同步多用户检测: 特征码为 31 位 Gold 序列 (已归一), 用户数 10 个, 其中有 4 个用户的功率与期望用户功率比为 10dB, 有 5 个用户的功率与期望用户功率比 20dB; 同时使期望用户的功率进行变化, 这种变化包括一个周期为 10^5 码元周期, 幅度为期望用户幅度 0.2 倍的慢正弦变化, 一

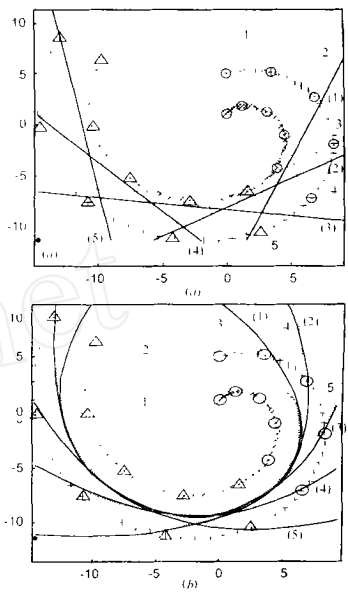


图 4 (a) 和 (b) 分别绘出了线性核和径向基核自适应支撑矢量机随 k 的增加, 5 次训练的结果. 图中圆圈圈中的样本表示某次训练的起始样本, 在该样本之前的样本已经被完全遗忘. 三角形圈中的样本表示某次训练的结束样本, 在该样本后面的样本表示此时尚未出现, 虚线为自适应支撑矢量机得到的分界面, 实线为支撑矢量机得到的分界面.

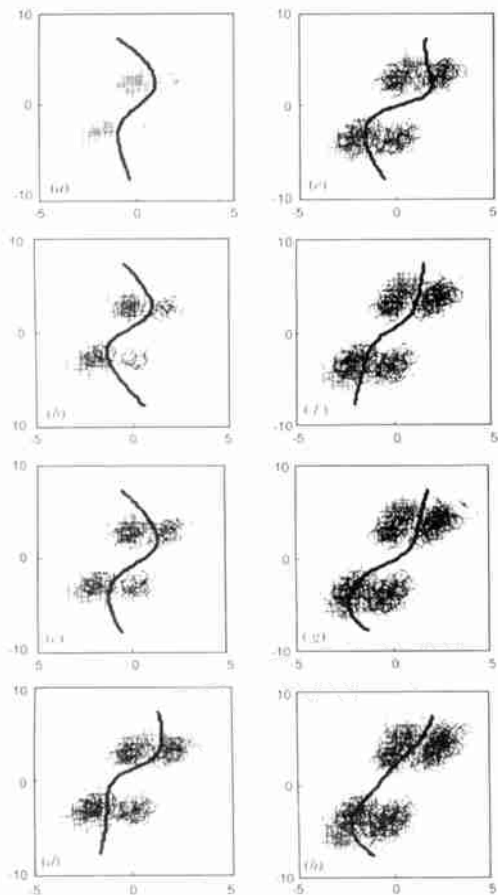


图 5 从(a)到(h)分别绘出了径向基核函数自适应支撑矢量机 8 个时刻的训练结果,图中“+”表示负训练样本,“x”表示正训练样本,“ ”表示已被遗忘的样本,即对应的遗忘因子接近于 0.粗实线为支撑矢量机得到的分界面,虚线自适应支撑矢量机得到的分界面。

个周期为 10 码元周期,幅度为期望用户幅度 0.2 倍的快正弦变化.图 6 绘出了不同信噪比 ($20\log(A_1/\sigma^2)$), A_1 为信号幅度(特征码已归一), σ^2 为噪声功率)时的检测器错误概率.图中最佳检测器曲线为相同信噪比,且期望用户功率不变时的最佳单用户(没有干扰用户)检测器错误概率的理论值.从图中可以看出,自适应支撑矢量机的多用户检测器的错误概率已非常接近相同信噪比时的最佳单用户检测器。

第二个实验异步




图 6 自适应支撑矢量机用于多用户检测,每次训练样本数为 200,检验样本数 10^5 ,图中最佳检测器为同等信噪比情况下的最佳多用户检测器的错误概率理论值.图标中分别为最佳检测器,同步检测器,异步检测器,异步多径检测器。

多用户检测:特征码为 31 位 Gold 序列(已归一),用户数 10 个,各用户的相对时延随机产生,其中有 4 个用户的功率与期望用户功率比为 10dB,有 5 个用户的功率与期望用户功率比 20dB;同时使期望用户的功率进行变化,这种变化包括一个周期为 10^5 码元周期,幅度为期望用户幅度 0.2 倍的慢正弦变化,一个周期为 10 码元周期,幅度为期望用户幅度 0.2 倍的快正弦变化.图 6 绘出了不同信噪比 ($20\log(A_1/\sigma^2)$), A_1 为信号幅度(特征码已归一), σ^2 为噪声功率)时的检测器错误概率.从图中可以看出,自适应支撑矢量机的异步多用户检测器结果稍差,这是由于异步时特征码的相关性增大造成的。

第三个实验异步多径多用户检测:特征码为 31 位 Gold 序列(已归一),用户数 5 个,各用户的相对时延随机产生,其中有 1 个用户的功率与期望用户功率比为 10dB,有 3 个用户的功率与期望用户功率比 20dB,每个用户各有三个多径信号,设多径信号的幅度与该用户大小相等;同时使期望用户的功率进行变化,这种变化包括一个周期为 10^5 码元周期,幅度为期望用户幅度 0.2 倍的慢正弦变化,一个周期为 10 码元周期,幅度为期望用户幅度 0.2 倍的快正弦变化.图 6 绘出了不同信噪比 ($20\log(A_1/\sigma^2)$), A_1 为信号幅度(特征码已归一), σ^2 为噪声功率)时的检测器错误概率.从图中可以看出,自适应支撑矢量机的异步多径多用户检测器结果比同步多用户检测还好,这说明自适应支撑矢量机多用户检测器具有合并多径的功能。

5 结论

本文对支撑矢量机中惩罚因子作了引申,提出了自适应支撑矢量机,并用于 DS-CDMA 系统的多用户检测.自适应支撑矢量机用于多用户检测有以下的优点:训练样本需求少,推广能力好,对高维样本不增加计算代价;它是直接以误码率为准则,能比所有线性检测器达到更小的误码率.其最大的缺点就是自适应支撑矢量机仍要求有训练序列,不能实现盲检测。

参考文献:

- [1] Verdú S. Multiuser Detection [M]. London: Cambridge University Press, 1996.
- [2] Madhow U, Hoesung M. MMSE interference suppression for direct-sequence spread spectrum CDMA [J]. IEEE Trans, 1994, Comm-42 (12): 3178 - 3188.
- [3] 张贤达, 保铮. 通信信号处理 [M]. 北京: 国防工业出版社, 2000. 420 - 482.
- [4] Woodward G, Vucetic B S. Adaptive detection for DS-CDMA [J]. Proc IEEE, 1998, 86(7): 1413 - 1434.
- [5] Miller S L. Training analysis of adaptive interference suppression for direct-sequence code-division multiple-access systems [J]. IEEE Trans, 1996, Comm-44(4): 488 - 494.
- [6] Chen D S, Roy S. An Adaptive multiuser receiver for CDMA systems [J]. IEEE J, 1994, SAC-12(6): 808 - 816.
- [7] Hoesung M, Madhow U, Verdú S. Blind adaptive multiuser detection [J]. IEEE Trans, 1995, IT-41(4): 944 - 960.
- [8] Zhang X D, Wei W. Blind adaptive multiuser detection based on

- Kalman filtering[J]. IEEE Trans ,2002 ,SP-50(1) :87 - 95.
- [9] Wang X ,Poor H. V Blind multiuser detection :A subspace approach [J] . IEEE Trans ,1998 ,IT-44(3) :677 - 691.
- [10] Wang X ,Poor H Y. Blind equalization and multiuser detection in dispersive CDMA channels[J] . IEEE Trans ,1998 ,Commur-45(9) :91 - 103.
- [11] Gesbert D ,Paulraj A. Blind multiuser linear of CDMA signals in frequency selective channels[A] . Proc of the International Communications Conference[C] . Pacific Grove ,CA ,Nov ,1998.
- [12] Vapnik V. Statistical Learning Theory[M] . Wiley-Interscience Publication ,1998.
- [13] Vapnik V. The Nature of Statistical Learning Theory[M] . New York : Springer-Verlag ,1995.
- [14] Vapnik V. An overview of statistical learning theory[J] . IEEE Trans ,1999 ,NN-10(5) :988 - 999.
- [15] Burges C J C. A tutorial on support vector machines for pattern recognition[J] . Data Mining and Knowledge Discovery ,1998 ,2:1 - 47.
- [16] Smola A J ,Schölkopf B. A tutorial on support vector regression[R] . NeuroCOLT Technical Report NC-TR-98-030 ,Royal Holloway College , University of London ,UK ,1998.
- [17] Vapnik V. Estimation of Dependencies Based on Empirical Data[M] (in Russia) . Nauka ,Moscow ,1979. (English translation ,New York : Springer Verlag ,1982) .
- [18] Osuna E ,Freund R ,Grosi G. Improved training algorithm for support vector machines[A] . Principe J , Gle L ,Morgan N ,Wilson E. Neural Networks for Signal Processing VII ...Proceedings of the 1997 IEEE Workshop[C] . USA :IEEE ,1997 . 276 - 285.
- [19] Platt J. Fast training of support vector machines using sequential minimal optimization[A] . Schölkopf B ,Burges C ,Smola A J. Advances in Kernel Methods ..Support Vector Learning [C] . Cambridge ,MA :MIT Press ,1999 :185 - 208.
- [20] 姬翔 ,钟义信. 一种神经网络多用户检测器[J] . 电子学报 ,1999 ,27(12) :105 - 106.
- [21] 李春光 ,廖晓峰 ,等. 基于径向基神经网络的 CDMA 多用户检测方法[J] . 信号处理 ,2000 ,16(3) :206 - 210.
- [22] Craven & Shavlik 29 Lang K J ,Witbrock M J. Learning to tell two spirals apart[A] . Proceedings of the 1988 Connectionist Models Summer School [C] . Morgan Kaufmann ,1988 . 52 - 59.

作者简介:

周伟达 男,1974年出生于浙江省海宁市,现为西安电子科技大学在读博士生,研究领域包括:机器学习、统计学习理论和智能信号处理. Email :zhou . weida @yahoo . com . cn

张莉 女,1975年出生于贵州省绥阳县,现为西安电子科技大学在读博士生,主要研究方向有数据挖掘、模式识别和神经网络.