

一种快速的在线 SVM 多用户检测算法

王子磊 奚宏生 赵宇 盛延敏

(中国科学技术大学信息科学技术学院自动化系 合肥 230027)

摘要 基于传统支持向量机的多用户检测算法运算量大、耗时长,无法满足实时性要求。该文提出了一种快速的在线支持向量机多用户检测算法。该算法利用 KKT 条件判别实时增加的训练序列并构造当前训练样本集,从而能够有效地减少训练样本大小,加快训练速度。仿真实验表明,该算法在不影响分类效果的情况下大大加快了训练速度,且用于分类的支持向量较少,同时性能与传统支持向量机算法相当且明显优于 MMSE(RLS)多用户检测器。

关键词 CDMA, 在线支持向量机, 多用户检测, 快速算法

中图分类号: TN914.5, TN911.23

文献标识码: A

文章编号: 1009-5896(2006)08-1386-05

A Fast Online SVM Algorithm for Multi-user Detection

Wang Zi-lei Xi Hong-sheng Zhao Yu Sheng Yan-min

(School of Information Science and Technology, Univ. of Science & Technology of China, Hefei 230027, China)

Abstract The runtime of conventional SVM-MUD is too long to satisfy the requirement of real-time application. A fast algorithm based on online training of SVM (FOSVC) for multiuser detection is proposed in the paper. The algorithm distinguishes new added samples and constructs the current training data set using KKT condition in order to reduce the size of training samples. As a result, the training speed is effectively increased. Simulation results illustrate that the algorithm has a faster training speed and a smaller number of support vectors preserving the same quality of separating hyperplane. The performance of the FOSVC detectors is pretty much the same thing as that of SVM detectors, and much better than that of MMSE detectors.

Key words CDMA, Online SVM, Multiuser detection (MUD), Fast algorithm

1 引言

多用户检测(MUD)是码分多址(CDMA)系统中的关键技术之一,它可以有效地抑制 DS-CDMA 系统中的多用户干扰和远近效应,从而有效地增加系统的信道容量。目前国内外已经提出了许多多用户检测算法^[1-5],这些算法要求已知的信息各有不同,性能也各有千秋。MMSE 多用户检测方法^[3]因为简单而得到了广泛的应用,但性能较差,文献[4]将它与 PIC 方法结合以提高同时存在蜂窝内外干扰用户情况下的性能;神经网络方法^[5]也因其自身固有的缺点而受到限制。

90 年代以来, Vapnik 等在统计学习理论^[6]基础上发展起来的一种新的学习方法——支持向量机(SVM)^[7],它与一般学习机相比具有更好的泛化性能和非线性扩展能力,而且它的收敛过程无局部极小。近年来, SVM 方法被用来解决多用户检测问题^[8-11],它根据期望用户的信号+1 或-1 把接收到的信号分成两类,然后通过训练样本数据得到最佳分类超平面,从而能够有效地检测出期望用户信号。但是在 CDMA 系统中,由于无线信道特性复杂,多用户检测算法要求具有实时、自适应的特性,而传统的 SVM 方法由于耗时多、载荷大而不能满足实时性的需求。文献[12]中提出了一种在线支持向量分类(OSVC)方法,它能够大大地减少算法训练过程

中对内存资源的需求,但运算效率没有明显改善,尤其在训练样本数较大的情况下,计算仍然很耗时。

本文提出了一种快速的在线支持向量分类(FOSVC)算法,它利用 KKT 条件判别新增加的训练序列,选择满足条件的样本构造当前训练样本集,从而有效地减少每次训练样本的大小,提高训练速度并降低对计算内存的需求。我们还从理论上证明了 FOSVC 算法的收敛性,仿真结果也表明了该算法在基本性能和传统 SVM 相当的情况下,收敛速度更快,从而更加有利于 SVM 方法在 CDMA 系统多用户检测中的实时性实现。

2 CDMA 信号模型

在 CDMA 系统中,用户占用相同的频道带宽,不同用户通过各自发送的信号序列来区分。对于一个 K -用户异步基带信道 DS-CDMA 系统,在匹配滤波器之前接收机收到的基带信号可以写成^[3]:

$$y(t) = \sum_{k=1}^K \sum_{i=-M}^M A_k b_k^i s_k(t - iT - \tau_k) + \sigma n(t) \quad (1)$$

其中 $n(t)$ 是单位功率谱密度的高斯白噪声, σ 是噪声偏差, T 是信号长度; $b_k^i \in \{+1, -1\}$, s_k , A_k 和 $\tau_k < T$ 分别是第 k 个用户在第 i 个时刻的信号、扩频波形、接受信号幅值和相对时延,用户采样的信号长度是 $2M + 1$ 。一般信号采样周期为

$T_s = T/N$, 其中 N 为扩频增益, 写成矩阵形式可表示为^[8]

$$\mathbf{y} = \mathbf{S}\mathbf{A}\mathbf{b} + \sigma\mathbf{n} \quad (2)$$

其中

$\mathbf{A} = \text{diag}(A_1, A_2, \dots, A_K)$, $\mathbf{S} = (s_1, s_2, \dots, s_K)$, $\mathbf{b} = [b_1, b_2, \dots, b_K]^T$ 和 $E\{\mathbf{n}\mathbf{n}^T\} = \mathbf{I}$ 。

考虑同步 CDMA 模型在接收机端第 K 个匹配滤波器的输出为

$$y_k = \int_0^T y(t)s_k dt = A_k b_k + \sum_{j \neq k} A_j b_j \rho_{jk} + n_k \quad (3)$$

多用户检测问题就是把多址干扰(MAD)看作具有一定结构的有效信息, 在接收信号 y 已知的情况下, 检测出目标用户的发送信号 b 是+1 还是-1, 因此可以将接收向量分成两类: 当目标用户的信号是+1, 则接收向量属于(+1)类; 当目标用户的信号是-1, 则接收的向量属于(-1)类。从这个意义上讲, 多用户检测就可以看成一个简单的二分类问题, 而支持向量机正是解决这种分类问题的一种十分有效的方法。

3 支持向量机方法

3.1 传统的 SVM 算法

设训练序列为 (x_i, y_i) , $x_i \in R^N$, $y_i \in \{1, -1\}$, $i = 1, 2, \dots, l$ 。SVM 的目的就是找出一个能将两类数据分离的最佳分类器, 对于线性分类问题, 就是要获得超平面 $(\mathbf{w}^T \cdot \mathbf{x}) + b = 0$, 它可以归结求解参数 \mathbf{w}, b 的有约束优化问题:

$$\begin{aligned} \min & \left(\|\mathbf{w}\|^2 / 2 + C \sum_{i=1}^l \xi_i \right) \\ \text{s.t.} & y_i (\langle \mathbf{w}, \mathbf{x} \rangle + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, l \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, l \end{aligned} \quad (4)$$

其中 C 是惩罚因子, ξ_i 是样本 (x_i, y_i) 对应的松弛变量。求解上述优化问题最终可归结为求解如下的凸二次规划对偶问题^[7]:

$$\begin{aligned} \max & W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \\ \text{s.t.} & \sum_{i=1}^l y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, l \end{aligned} \quad (5)$$

并且所求的最优解必须满足 KKT 条件:

$$\alpha_i [y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1 + \xi_i] = 0 \quad (6)$$

求解式(5)得到分类超平面的权向量:

$$\mathbf{w} = \sum_{i=1}^l y_i \alpha_i \mathbf{x}_i \quad (7)$$

分类超平面的判决决策函数为

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i \in SV} \alpha_i y_i \langle \mathbf{x}, \mathbf{x}_i \rangle + b \right) \quad (8)$$

从式(7)看到, 只有 $\alpha_i \neq 0$ 对应的训练序列 (x_i, y_i) 对 \mathbf{w} 才有影响, 我们称这些训练向量 \mathbf{x}_i 为支持向量, 支持向量决定了最佳超平面。通过引入 Mercer 核函数, 即在式(5)和式(8)

中用 $K(\mathbf{x}, \mathbf{y})$ 代替 $\langle \mathbf{x}, \mathbf{y} \rangle$, 就可以得到对应的非线性支持向量机。

3.2 快速 OSVC 算法

传统的 SVM 训练方法是给定一批训练数据 $(x_i, y_i), i = 1, 2, \dots, l$, 然后通过求解一个二次规划问题得到分类超平面。这样训练样本数 l 越大, 运算负载就越大, 训练时间就越长。许多快速算法^[13,14]被提出用于求解大规模问题, 但传统的 SVM 算法仍很难适用于实时在线的应用问题, 这样就严重影响了训练样本的取值, 性能也就随之下降。对于 CDMA 中的多用户检测问题而言, 实时性能要求较高, 需要不断地更新训练序列重复训练, 这就需要一种更加切实有效的快速在线 SVM 方法来满足这种需求。

文献[12]提出了一种在线支持向量分类(OSVC)算法, 它能够在线运算, 同时在训练中比传统的支持向量分类(SVC)算法需要更少的内存资源, 但频繁的训练导致运算效率没有明显改善, 尤其是在训练样本数较大的情况下, 训练仍然很耗时。针对这个问题, 本文提出了一种快速的在线支持向量分类(FOSVC)算法。我们注意到, 在求解 SVM 的对偶问题时, 支持向量的数目相比训练样本的总数来说非常小, 通常 SVM 的二分类训练时间 T 与训练样本数 l 成超线性关系 ($T \sim l^\gamma, \gamma > 1$)^[14], 因此, 我们可以通过减少训练样本的大小来加快训练速度。在 SVM 中, 如果有样本不满足 KKT 条件则相应的解一定不是最优解, FOSVC 算法正是利用 KKT 条件判别新增加的训练序列, 选择那些违反 KKT 条件的样本来构造当前训练样本集, 从而有效地减少每次训练样本的大小, 提高训练速度并减少对计算内存的需求。

FOSVC 算法的基本思想如下: 当有一批新的训练序列 S_k 来更新当前分类器时, 首先判断已有的分类器: $f_{k-1}(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^{|SV_{k-1}|} \alpha_i^{k-1} S y_i^{k-1} K(\mathbf{x}, \mathbf{S} \mathbf{x}_i^{k-1}) + b_{k-1} \right)$ 能否使新训练数据 $(x_i, y_i) \in S_k$ 正确分类, 只有出现错误分类的时候才重新训练新的分类器。在训练新分类器的过程中, FOSVC 首先确定此组的训练样本集 W_k , 在实时性要求不高或样本序列 S_k 数目较少的情况下, W_k 可以包括先前的若干样本; 相反, 就需要选择较少的训练样本, 不失一般性, 我们在实验中选择最新的一组数据 S_k 作为训练样本集, 即 $W_k = S_k$ 。随后 FOSVC 通过迭代训练当前训练样本集 T_k 而逐渐逼近最佳分类器。在一步训练过程中, 选择那些违反当前分类器 $f_k(\mathbf{x})$ 的 KKT 条件式(6)的样本 $(x_i, y_i) \in V_k$ 和当前的支持向量 $(\mathbf{S} \mathbf{x}_i^k, S y_i^k) \in SV_k$ 组合成当前训练样本集, 以此样本集训练新的分类器。如此循环, 直到训练样本集 W_k 中所有的样本满足 KKT 条件为止(收敛性证明见 3.3 节)。

具体的算法描述如下:

(1) 获取初始训练数据 S_0 , 令训练样本集 $W_0 = S_0$; 通过训练样本集 W_0 求解式(5), 得到分类超平面 $f_0 = (\alpha_0, b_0)$ 及支持向量集 SV_0 ;

```

(2) for  $k=1,2,3,\dots$ 
     $f_k = f_{k-1}, SV_k = SV_{k-1}$ , 获取第  $k$  组训练序列  $S_k$ , 令
     $E_k = \{(x_i, y_i) \in S_k \mid (x_i, y_i) \text{ 被 } f_{k-1} \text{ 错误分类}\}$ ;
    if  $(|E_k| > 0)$ 
        确定训练样本集  $W_k$ , 令
         $V_k = \{(x_i, y_i) \in W_k \setminus W_{k-1} \mid (x_i, y_i) \text{ 违反 } f_{k-1} \text{ 的 KKT 条件}\}$ 
        while  $(|V_k| > 0)$ 
            通过当前训练样本集  $T_k = SV_k \cup V_k$  求解式(5),
            得到分类超平面  $f_k = (\alpha_k, b_k)$  及新的支持向量
            集  $SV_k$ ;
             $V_k = \{(x_i, y_i) \in W_k \setminus T_k \mid (x_i, y_i) \text{ 违反 } f_k \text{ 的 KKT 条件}\}$ ;
        end while
    endif
endfor

```

为了使训练出来的分类器具有更好的自适应性, 在训练时可以控制不同样本的影响因子 C , 文献[9]中对此方法有详细的介绍, 这里不再赘述。而本算法 C 的取值可以看作是一种特殊形式: W_k 之外的样本有 $C=0$, W_k 中的样本则具有相同的参数 C , 即我们的算法中取的 C 值。

3.3 算法的收敛性

为了更好地理解和说明算法的收敛性, 我们首先给出下面的命题。

定理 1 由 $(x_i, y_i)_{i=1}^l$ 训练出最佳分类器 $f(x)$ 以后, 训练样本集中非支持向量的样本 (x_i, y_i) 一定满足:

$$y_i f(x_i) \geq 1 \quad (9)$$

证明 设 (x_i, y_i) 为非支持向量, 则其对应的 Lagrange 乘子有 $\alpha_i = 0$, 即对分类超平面没有任何贡献。根据式(6)的 KKT 条件, 则其对应的松弛变量 $\xi_i = 0$, 则初始的约束条件可转化为: $y_i f(x_i) \geq 1 - \xi_i = 1$ 。证毕

下面通过 FOSVC 算法与分解算法(DA)的比较来证明该算法的收敛性。文献[13,15]中给出了 DA 算法的详细内容, 该算法把训练样本集分成工作集 B 和纠正集 N , 同时分解对应的参数:

$$\alpha = \begin{pmatrix} \alpha_B \\ \alpha_N \end{pmatrix}, \quad y = \begin{pmatrix} y_B \\ y_N \end{pmatrix}, \quad K = \begin{pmatrix} K_{BB} & K_{BN} \\ K_{NB} & K_{NN} \end{pmatrix} \quad (10)$$

这样就把原来的二次规划问题转换为如下的分解形式:

$$\left. \begin{aligned} & \min \left[\alpha_B^T K_{BB} \alpha_B + \alpha_B^T K_{BN} \alpha_N + \alpha_N^T K_{NB} \alpha_B + \alpha_N^T K_{NN} \alpha_N \right] \\ & - \langle c_B, \alpha_B \rangle - \langle c_N, \alpha_N \rangle \\ & \text{s.t. } \langle y_B, \alpha_B \rangle + \langle y_N, \alpha_N \rangle = 0, \quad 0 \leq \alpha_B, \alpha_N \leq C \end{aligned} \right\} \quad (11)$$

DA 算法的主要思想就是固定纠正集 N 对应的数据和参数, 求解工作集 B 上的子优化问题, 然后通过 B 与 N 之间的样本数据交换, 使子最优解逐渐趋向于全局最优解。而交换数据的过程主要包括 Build-down 和 Build-up 两个过程^[13], 大致

如图 1 所示。另外, 文献[15]中已经详细证明了 DA 算法的收敛性。

对 FOSVC 算法而言, 只要 while 循环体能够收敛即可, 而它的关键过程是在每一步中扔掉非支持向量的样本, 并且加入训练样本集 W_k 中其它违反 KKT 条件的训练样本。与 DA 算法相比较, 主要的区别是它保留了支持向量 SV_k 而移除了其它样本, 并用 KKT 条件选择加入的样本, 如图 2 所示。由定理 1 可知, 非支持向量会远离分类超平面, 它们对优化结果没有任何影响, 即 FOSVC 算法对应的 DA 参数 $\alpha_N = 0$ 。因此, FOSVC 移除非支持向量后并不影响优化的结果, 下面我们严格证明这一点, 从而说明 FOSVC 算法与 DA 算法是一致的, 同样能够收敛。

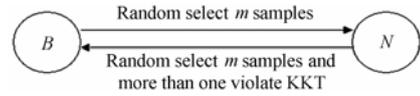


图 1 DA 算法的两个主要过程

Fig.1 Two key procedure of decomposition algorithm

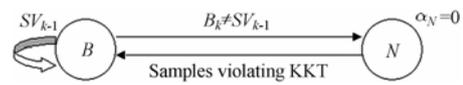


图 2 FOSVC 算法的两个核心过程

Fig.2 Two key procedure of FOSVC algorithm

定理 2 从工作集 B 中移除非支持向量的样本 $\{m\}$ 到 N 中, 子优化问题的最优解保持不变。

证明 令 $B' = B - \{m\}$, $N' = N \cup \{m\}$, $\{m\} \in B - SV \Rightarrow \alpha_m = 0$, 并注意 $\alpha_N = 0$, 则有

$$\begin{aligned} L_D(B', N') &= \frac{1}{2} \left[\alpha_B^T K_{B'B} \alpha_{B'} + 2\alpha_B^T K_{B'm} \alpha_m + \alpha_m^T K_{mN'} \alpha_{N'} \right] \\ &\quad - \langle c_{B'}, \alpha_{B'} \rangle - \langle c_{N'}, \alpha_{N'} \rangle \\ &= \frac{1}{2} \left[\alpha_B^T K_{B'B} \alpha_{B'} + 2\alpha_B^T K_{B'm} \alpha_m + \alpha_m^T K_{mm} \alpha_m \right] \\ &\quad - \langle c_{B'}, \alpha_{B'} \rangle - \langle c_m, \alpha_m \rangle \\ &= \frac{1}{2} \alpha_B^T K_{BB} \alpha_B - \langle c_B, \alpha_B \rangle = L_D(B, N) \end{aligned} \quad (12)$$

$$\langle y_{B'}, \alpha_{B'} \rangle + \langle y_{N'}, \alpha_{N'} \rangle = \langle y_B, \alpha_B \rangle + \langle y_m, \alpha_m \rangle = \langle y_B, \alpha_B \rangle = 0 \quad (13)$$

由式(12), 式(13)可见, 优化问题的目标和约束条件都没有变, 故移除后的最优解也保持不变。证毕

4 数据仿真及结果

该仿真实验是基于 Matlab 的 SVM 工具箱 osu_svm 3.00 实现的。我们使用误码率(BER)来衡量分类器的性能, 它是分类器训练的最终目标, 也是一种最优和最直接的准则。不失一般性, 假定期望用户为用户 1, 且是同步的($\tau_1 = 0$)。定义信噪比(SNR)和干扰用户与期望用户的功率关系(NFR)如下:

$$\text{SNR} = 10 \log(A_1^2 / \sigma^2) = 20 \log(A_1 / \sigma)$$

$$\text{NFR} = 10 \log(A_k^2 / A_1^2) = 20 \log(A_k / A_1)$$

其中 A_i 为用户 i 的信号幅值, σ^2 为噪声的功率谱密度。下面我们分别测试 FOSVC 算法的收敛速度和用于 CDMA 多用户

检测的性能,其中所采用的SVM方法都是线性的,且参数 $C=2$ 。每个用户的信道为Rayleigh衰弱信道,信源为独立的BPSK调制信号,扩频码采用Gold序列,扩频增益为31。

4.1 FOSVC 算法的收敛速度

下面我们把FOSVC算法与传统的SVM方法进行比较,以验证3.2节中FOSVC算法具有较快的训练速度。我们采用10个用户的同步信号,其它9个用户的功率与目标用户功率有 $NFR=20\text{dB}$,信噪比 $SNR=15\text{dB}$,噪声 $\sigma^2=0.01$,每组有训练数据300个,测试数据10000个。我们随机产生10组数据,并序列地加入到训练序列中,记录每组数据的训练时间、支持向量数及测试数据的误码率,其中7组数据的训练结果如表1和表2所示。

由表1可知,FOSVC算法的训练速度明显快于传统的SVM算法,因为FOSVC不仅在训练新样本数据时速度快,而且在训练样本能够被正确分类的情况下不需要重新训练新的分类器(如第2、4组数据)。由表2看出,FOSVC算法训练出的支持向量数要低于传统的SVM算法,这样就去除了部分冗余的支持向量,从而在使用中降低计算的复杂度。

表1 FOSVC与传统SVM训练时间的比较

Tab.1 Training time of FOSVC and traditional SVM

训练样本	1	2	3	4	5	6	7
FOSVC(ms)	46	0	172	0	266	234	204
传统 SVM(ms)	281	312	563	422	578	531	438

表2 FOSVC与传统SVM支持向量数的比较

Tab.2 Number of SVs of FOSVC and traditional SVM

训练样本	1	2	3	4	5	6	7
FOSVC	18	18	23	23	24	24	24
传统 SVM	23	25	27	24	28	25	25

4.2 FOSVC 用于多用户检测的性能

我们把FOSVC算法分别用于同步多用户检测和异步多用户检测两种情况,通过考察在不同信噪比下误码率及两者的关系来检测算法的效果。在实验中,我们比较了FOSVC、传统SVM、MMSE(RLS)及MMSE/PIC^[4]4种算法,其中最后一种算法假定式(2)中的 S, A 等所需参数已经被无误差地估计出来,并且采用文献[4]中的完全PIC最优解形式;而前3种方法无需知道任何参数,采用训练数据来直接得到线性多用户检测器。实验中共有10个用户,其中4个干扰用户的功率为 $NFR=4\text{dB}$,其它5个干扰用户的功率与目标用户相同。每组有训练数据200个,测试数据10000个,每一个信噪比下的结果为10组数据训练结果的平均值。

同步多用户检测:在此情况下假定所有的用户都是同步的,即有 $\tau_i=0, i=1, \dots, 10$ 。图3给出了4种分类器在同步检测中误码率和信噪比之间的关系图。由此可以看出,FOSVC算法和传统SVM在不同SNR下具有相当的误码率,两者的误码率均随着SNR的增大快速地降为零,并接近

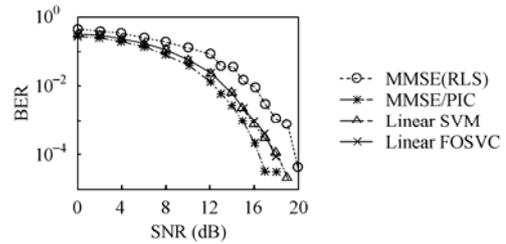


图3 同步多用户检测中目标用户误码率和信噪比之间的关系

Fig.3 BER Vs. SNR in synchronously MUD

MMSE/PIC 无误差参数估计下的最优解,且明显地优于基于训练的MMSE(RLS)多用户检测器。

异步多用户检测:在这种情况下假定其它9个干扰用户都是异步的,它们相对目标用户的时延为(0~31)随机产生的码片间隔,而且假定MMSE/PIC还要精确知道每个用户的时延信息。图4给出了不同分类器在异步检测中误码率和信噪比之间的关系曲线图。由图可知,各种分类器的误码率和信噪比的关系与在同步多用户检测中非常类似,FOSVC和传统的SVM算法同样具有很低的误码率,而MMSE/PIC因假定无误差地知道所有需要的信息而具有最低的误码率。但在相同的SNR下,它们的误码率比在同步多用户检测中的误码率略大,因为在异步情况下,扩频码之间的相关性有所增大。

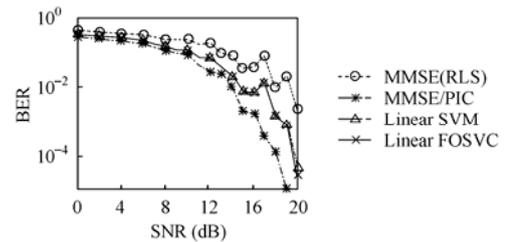


图4 异步多用户检测中目标用户误码率和信噪比之间的关系

Fig.4 BER Vs. SNR in asynchronously MUD

5 结束语

本文针对多用户检测的特点,提出了一种快速的在线支持向量机多用户检测算法。与传统的SVM方法相比,该算法不仅具有更快的收敛速度,占用更少的内存资源,而且具有更少支持向量和相当的误码率;与MMSE(RLS)方法相比,它用较少的训练样本获得更佳分类器。

参考文献

- [1] Verdú S. Multiuser Detection[M]. London: Cambridge University Press, 1998: 154-387.
- [2] 张贤达, 保铮. 通讯信号处理[M]. 北京: 国防工业出版社, 2000: 420-482.
- [3] Madhow U, Honing M. MMSE interference suppression for direct-sequence spread spectrum CDMA[J]. *IEEE Trans. on Communications*, 1998, 46(8): 3178-3188.
- [4] Host-Madsen A, Kyung-Sean Cho. MMSE/PIC multiuser detection for DS/CDMA systems with inter-and intra-cell interference[J]. *IEEE Trans. on Communications*, 1999, 47(2):

- 291-299.
- [5] Kechriotis G, Manolakos E S. Hopfield neural network implementation in the optimal CDMA multiuser detector[J]. *IEEE Trans. on Neural Networks*, 1996, NN-7(1): 131-141.
- [6] Vapnik V. *Statistical Learning Theory*[M]. New York: Wiley-Interscience Publication, 1998: 401-491.
- [7] Nello C, John S T. *An Introduction to Support Vector Machines*[M]. London: Cambridge University Press, 2000: 93-122.
- [8] Gong X H, Kuh A. Support vector machine for multiuser detection in CDMA communications[A]. *Conference Record of the Thirty-Third Asilomar Conference on Signals, Systems, and Computers* [C]. Vol.1, 24-27 Oct., 1999: 680-684.
- [9] 周伟达, 张莉, 焦李成. 自适应支撑矢量机多用户检测[J]. *电子学报*, 2002, 31(1): 92-97.
- [10] 刘枫, 张太猛, 孙建成. 基于修改核函数的 RLS-SVM 多用户检测算法[J]. *电子与信息学报*, 2003, 25(8): 1130-1134.
- [11] 杨恒, 张贤达. Rayleigh 信道下的支持向量机多用户检测方法. *电子与信息学报*, 2002, 24(2): 257-260.
- [12] Lau K W, Wu Q H. Online training of support vector classifier[J]. *Pattern Recognition*, 2003, 36(8): 1913-1920.
- [13] Osuna E, Freund R, Girosi F. An improved training algorithm for support vector machines[A]. *Neural Network for Signal Processing*[1997] VII. Proceedings of the 1997 IEEE Workshop, USA, 24-26 Sept., 1997 [C]: 276-285.
- [14] Platt J. Fast training of support vector machines using sequential minimal optimization[A]. In: Schölkopf B., Burges C.J.C., and Smola A.J. (Eds.) *Advances in Kernel Methods-Support Vector Learning*, Cambridge, MA, MIT Press. 1999: 185-208.
- [15] Chang C C, Hsu C W, Lin C J. The analysis of decomposition methods for support vector machines[J]. *IEEE Trans. on Neural Networks*, 2000, 11(4): 1003-1008.
- 王子磊: 男, 1981 年生, 博士, 研究方向为 CDMA 系统多用户检测和智能天线的智能算法研究.
- 奚宏生: 男, 1950 年生, 教授, 博士生导师, 研究方向为离散动态系统、自适应滤波理论、通讯网络流量控制和管理、网络入侵检测技术及其应用.