

## 基于子空间跟踪的 DSSS 通信系统抗窄带干扰研究

张春海 朱江 张尔扬

(国防科技大学电子科学与工程学院 长沙 410073)

**摘要:** 对接收信号自相关矩阵分析表明, 窄带干扰的能量集中在一个低秩子空间(干扰子空间)内, 扩频信号和噪声的能量均匀散布在整个特征空间, 通过跟踪接收信号自相关矩阵大特征值对应特征矢量构成的干扰子空间, 可实现对窄带干扰的有效抑制。文中采用 RRLS 算法跟踪干扰子空间, 并根据干扰子空间最小特征值与噪声功率的比值自动确定干扰子空间的维数。分析和仿真表明子空间跟踪窄带干扰抑制算法实现复杂度低, 数值稳定性好, 性能优于传统的自适应横向滤波器。

**关键词:** 直接序列扩频; 抗窄带干扰; 子空间跟踪; 奇异值分解

**中图分类号:** TN914.42, TN911.4

**文献标识码:** A

**文章编号:** 1009-5896(2007)05-1159-04

## Subspace Tracking-Based Research on Narrowband Interference Suppression in DSSS Communication Systems

Zhang Chun-hai Zhu Jiang Zhang Er-yang

(College of Electronic Science and Engineering, National Univ. of Defense Technology, Changsha 410073, China)

**Abstract:** The analysis of correlation matrix of the received signal proves that the energy of narrowband interference is compressed in the low rank subspace, interference subspace, and the energy of DSSS signal and AWGN uniformly distribute. The narrowband interference suppression can be realized by tracking the interference subspace and projecting the received signal vector to the orthogonal subspace of it. The algorithm proposed here is low complexity, numerical stability and better performance than traditional Adaptive Transversal Filter (ATF).

**Key words:** Direct-Sequence Spread-Spectrum (DSSS); Narrowband interference suppression; Subspace tracking; Singular value decomposition

### 1 引言

直接序列扩频(DSSS)技术具有良好的保密性、灵活的信道分配以及较强的抗多径、多址干扰能力, 在个人通信网(PCN)、无线局域网(WLAN)、第三代移动通信、卫星通信以及军事通信等领域得到广泛的应用。直接序列扩频码分多址(DS-CDMA)通信已成为全球移动通信系统的发展方向, 以WCDMA、CDMA2000 和TD-SCDMA为主流的第三代移动通信系统标准化建议确立了CDMA技术在未来移动通信中的稳固地位。扩频技术本身具有一定的抗干扰能力, 但是当干扰强度超过干扰容限时, 采用信号处理技术来抑制干扰可以在不增加发送/接收机硬件复杂性以及信道带宽的情况下, 进一步提高系统的抗干扰能力<sup>[1,2]</sup>。时域抗干扰技术主要利用宽带信号相关性较弱, 窄带信号相关性强的特点, 通过从观测数据中减去利用横向滤波器对窄带干扰的估计来抑制干扰。由于干扰的统计特性未知或随时间变化, 通常采用自适应滤波器实现对干扰进行估计, 并且观测数据中存在强窄带干扰, 其自相关矩阵特征值扩展较大, 传统的LMS算法

收敛速度慢, 跟踪能力差, 而RLS算法计算复杂度高, 数值稳定性差。

Tufts等提出利用数据矩阵的奇异值分解(SVD)方法来估计噪声中的有用信号<sup>[3]</sup>, Rice等将这种方法应用于非扩频通信中, 提出SVD方法优于传统的陷波器<sup>[4]</sup>, 孙丽萍等将SVD方法应用于直接序列扩频系统抗单音干扰, 并取得良好的效果<sup>[5]</sup>。但当子空间维数较大时, 直接对数据矩阵进行奇异值分解(SVD)或者自相关矩阵进行特征值分解(EVD)的计算复杂度较大, 难以在实际系统中实时实现, 因此本文提出利用子空间跟踪法对干扰子空间进行迭代跟踪, 并通过将观测数据矢量向干扰子空间的正交补空间进行投影, 抑制接收信号中的窄带干扰。分析和仿真结果表明, 子空间跟踪法收敛速度快, 计算复杂度低, 性能优于传统的自适应横向滤波器(ATF)。

### 2 系统模型

在讨论扩频通信抗干扰技术之前, 首先给出直接序列扩频通信系统的数学模型及信号模型, 通常考虑 BPSK 调制 DSSS 系统模型, 如图 1 所示, 接收机信号由扩频信号、窄带干扰和加性高斯白噪声 3 部分组成, 其连续时间表示为

$$x(t) = s(t) + j(t) + \eta(t) \quad (1)$$




图1 接收机基带部分框图

式中  $s(t)$  为扩频信号的波形,  $j(t)$  为窄带干扰,  $\eta(t)$  为接收机的观测噪声, 假设观测噪声是均值为零, 功率为  $\sigma_\eta^2$  的加性高斯白噪声(AWGN), 其中 DSSS 信号  $s(t)$  可表示为

$$s(t) = \sqrt{P_s} \sum_{n=-\infty}^{\infty} b(n)c(t - nT_b) \quad (2)$$

式中  $P_s$  为接收到扩频信号的功率,  $b(n) \in \{+1, -1\}$  为第  $n$  个接收符号,  $c(t)$  为扩频信号的特征波形:

$$c(t) = \sum_{l=0}^{G_p-1} c(l)\psi(t - lT_c) \quad (3)$$

其中  $G_p$  为系统的扩展比, 扩频码  $c(l) \in \{+1, -1\}$ , 码片波形  $\psi(t) = \text{rect}_{T_c}(t)/\sqrt{T_c}$ ,  $\text{rect}_{T_c}(t)$  为在区间  $[0, T_c]$  上支撑的矩形脉冲。

经过码片波形匹配滤波器, 对接收信号以码片速率进行采样, 得到接收信号的离散时间序列如下:

$$x(n) = s(n) + j(n) + \eta(n) \quad (4)$$

由于扩频信号、背景噪声与窄带干扰之间相互独立, 接收信号的自相关函数可表示为

$$\rho_x(m) = \rho_s(m) + \rho_j(m) + \rho_\eta(m) \quad (5)$$

假定 PN 码具有理想的相关特性, 以码片速率采样得到的扩频信号序列不同样本之间是不相关的, 即

$$\rho_s(m) = E\{s(n)s^*(n+m)\} = P_s\delta(m) \quad (6)$$

同样, 背景噪声为加性高斯白噪声, 自相关函数为

$$\rho_\eta(m) = E\{\eta(n)\eta^*(n+m)\} = \sigma_\eta^2\delta(m) \quad (7)$$

### 3 奇异值分解窄带干扰抑制

音频(单音或多音)干扰是DSSS系统抗干扰中应用较多的窄带干扰模型<sup>[2]</sup>, 音频窄带干扰信号可建模为  $Q$  个正弦信号之和, 其数学表达式为

$$j(n) = \sum_{l=1}^Q \sqrt{P_l} e^{j(2\pi f_l n + \theta_l)} \quad (8)$$

式中  $P_l$  和  $f_l$  分别代表第  $l$  个正弦序列的功率和归一化频率,  $\{\theta_l\}$  是在  $[0, 2\pi)$  上均匀分布的随机相位, 干扰的自相关函数为

$$\rho_j(m) = \sum_{l=1}^Q P_l e^{j2\pi f_l m} \quad (9)$$

定义  $N$  维窄带干扰矢量

$$\mathbf{j}(n) = [j(n), j(n-1), \dots, j(n-N+1)]^T \quad (10)$$

干扰的  $N$  阶自相关矩阵为

$$\mathbf{R}_j = E\{\mathbf{j}(n)\mathbf{j}^H(n)\} = \sum_{l=1}^Q P_l \mathbf{g}_l \mathbf{g}_l^H \quad (11)$$

式中

$$\mathbf{g}_l = [1, e^{j2\pi f_l}, \dots, e^{j2\pi(N-1)f_l}]^T \quad (12)$$

显然  $\mathbf{g}_l^H \mathbf{g}_l = N$ , 由式(13)可知, 多音干扰自相关矩阵的秩为  $\text{rank}(\mathbf{R}_j) = Q$ , 等于不同频率干扰的个数, 当  $N$  大于  $Q$  时, 干扰的  $N$  阶自相关矩阵  $\mathbf{R}_j$  为奇异矩阵。同理可证, 若  $j(n)$  由  $Q$  个实正弦信号组成, 则  $\mathbf{R}_j$  的秩最大为  $2Q$ 。

由以上分析可知, 音频干扰的能量被集中在一个秩  $q$  ( $q \leq Q$ ) 的低秩子空间内, 通常窄带干扰的功率远远大于扩频信号和噪声的功率, 即  $P_j \gg P_s + \sigma_\eta^2$ , 对接收信号的自相关矩阵  $\mathbf{R}_x = E\{\mathbf{x}(n)\mathbf{x}^H(n)\}$  进行特征分解可得

$$\mathbf{R}_x = \mathbf{U} \mathbf{A} \mathbf{U}^H = \begin{bmatrix} \mathbf{U}_j & \mathbf{U}_\eta \end{bmatrix} \begin{bmatrix} \mathbf{A}_j & \\ & \mathbf{A}_\eta \end{bmatrix} \begin{bmatrix} \mathbf{U}_j^H \\ \mathbf{U}_\eta^H \end{bmatrix} \quad (13)$$

式中  $\mathbf{A}_j = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_q)$  包含自相关矩阵最大的  $q$  个特征值并且从大到小排列,  $\mathbf{U}_j = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_q]$  包含与之对应的  $q$  个正交特征矢量,  $\mathbf{U}_j$  张成的子空间  $\Gamma_j = \text{span}(\mathbf{U}_j)$  为干扰子空间。  $\mathbf{A}_\eta = (P_s + \sigma_\eta^2) \mathbf{I}_{N-q}$ ,  $\mathbf{U}_\eta = [\mathbf{u}_{q+1}, \mathbf{u}_{q+2}, \dots, \mathbf{u}_N]$  分别对应  $N-q$  个小特征值  $P_s + \sigma_\eta^2$  和相应的特征矢量,  $\mathbf{U}_\eta$  张成的子空间  $\Gamma_\eta = \text{span}(\mathbf{U}_\eta)$  为噪声子空间, 将接收信号矢量  $\mathbf{x}(n)$  向噪声子空间投影, 或者减去其在干扰子空间上的投影可实现对窄带干扰的抑制, 可见对低秩干扰子空间的估计是特征子空间法抗干扰的关键。

实际应用中, 常采用式(14)的递推方法来估计接收信号的自相关矩阵:

$$\hat{\mathbf{R}}(n) = \beta \hat{\mathbf{R}}(n-1) + \mathbf{x}(n)\mathbf{x}^H(n) \quad (14)$$

式中  $0 < \beta \leq 1$  为遗忘因子, 根据接收信号可构造观测数据矩阵  $\mathbf{A}(n)$  如下:

$$\mathbf{A}(n) = [\sqrt{\beta^n} \mathbf{x}(0), \sqrt{\beta^{n-1}} \mathbf{x}(1), \dots, \sqrt{\beta^0} \mathbf{x}(n)] \quad (15)$$

数据矩阵  $\mathbf{A}(n)$  的奇异值分解(SVD)为

$$\begin{aligned} \mathbf{A}(n) &= \mathbf{U}(n) \mathbf{\Sigma}(n) \mathbf{V}^H(n) \\ &= [\mathbf{U}_j(n) \mathbf{U}_\eta(n)] \begin{bmatrix} \mathbf{\Sigma}_j(n) & 0 \\ 0 & \mathbf{\Sigma}_\eta(n) \end{bmatrix} \mathbf{V}^H(n) \end{aligned} \quad (16)$$

自相关矩阵的估计可由数据矩阵表示为

$$\hat{\mathbf{R}}(n) = \mathbf{A}(n) \mathbf{A}^H(n) = \mathbf{U}(n) \mathbf{A}(n) \mathbf{U}^H(n) \quad (17)$$

由式(17)和矩阵的性质可知, 奇异值矩阵是特征值矩阵的正平方根, 即  $\mathbf{\Sigma}(n) = \sqrt{\mathbf{A}(n)}$ , 文献[5]给出了基于对数据矩阵直接进行 SVD 分解的单音干扰抑制算法, 其基本思想是, 当接收机接收到一帧数据样本(假定帧长度为  $L$ )后, 将  $L$  个观测数据样本按照式(15)排列得到观测数据矩阵, 其中取遗忘因子  $\beta = 1$ , 对观测数据矩阵  $\mathbf{A}$  进行 SVD 分解, 由于(实)单音干扰的能量集中在一个秩为 2 的干扰子空间内, 将奇异值矩阵中最大的两个奇异值置零, 利用处理后的奇异值矩阵重构数据矩阵, 即可实现对单音干扰的抑制。

### 4 子空间跟踪窄带干扰抑制技术

基于奇异值分解的窄带干扰抑制算法需要对数据矩阵

进行奇异值分解, SVD 的运算量大、算法复杂、工程实现较困难; 另外 SVD 的窄带干扰抑制方法是一类批处理方法, 即在获得一定长度的观测数据后进行一次处理, 显然这种处理方法只适用于扰参数或统计特性不随时间变化的情况下, 而在干扰参数或统计特性随时间变化时, 性能将显著下降, 针对这一问题, 本文采用子空间跟踪法来逼近和跟踪干扰子空间。

定义干扰子空间  $q$  个列矢量组成的  $N \times q$  矩阵  $\mathbf{W}$ , 令  $\mathbf{R}_x = E\{\mathbf{x}\mathbf{x}^H\}$  表示  $N \times 1$  维接收信号矢量的自相关矩阵, 目标函数为

$$J(\mathbf{W}) = E\{\|\mathbf{x} - \mathbf{W}\mathbf{W}^H\mathbf{x}\|^2\} = E\{\mathbf{x}^H\mathbf{x}\} - 2E\{\mathbf{x}^H\mathbf{W}\mathbf{W}^H\mathbf{x}\} + E\{\mathbf{x}^H\mathbf{W}\mathbf{W}^H\mathbf{W}\mathbf{W}^H\mathbf{x}\} \quad (18)$$

注意到

$$E\{\mathbf{x}^H\mathbf{x}\} = \sum_{i=1}^N E\{|x_i|^2\} = \text{tr}(E\{\mathbf{x}\mathbf{x}^H\}) = \text{tr}(\mathbf{R}_x) \quad (19)$$

$$E\{\mathbf{x}^H\mathbf{W}\mathbf{W}^H\mathbf{x}\} = \text{tr}(E\{\mathbf{W}^H\mathbf{x}\mathbf{x}^H\mathbf{W}\}) = \text{tr}(\mathbf{W}^H\mathbf{R}_x\mathbf{W}) \quad (20)$$

$$E\{\mathbf{x}^H\mathbf{W}\mathbf{W}^H\mathbf{W}\mathbf{W}^H\mathbf{x}\} = \text{tr}(E\{\mathbf{W}^H\mathbf{W}\mathbf{x}\mathbf{x}^H\mathbf{W}\mathbf{W}^H\mathbf{W}\}) = \text{tr}(\mathbf{W}^H\mathbf{R}_x\mathbf{W}\mathbf{W}^H\mathbf{W}) \quad (21)$$

目标函数可用迹函数表示为

$$J(\mathbf{W}) = \text{tr}(\mathbf{R}_x) - 2\text{tr}(\mathbf{W}^H\mathbf{R}_x\mathbf{W}) + \text{tr}(\mathbf{W}^H\mathbf{R}_x\mathbf{W}\mathbf{W}^H\mathbf{W}) \quad (22)$$

下面考虑最小化问题  $\min J(\mathbf{W})$ , Yang 证明了以下定理<sup>[6]</sup>:

**定理 1**  $\mathbf{W}$  是  $J(\mathbf{W})$  的一个平衡点, 当且仅当  $\mathbf{W} = \mathbf{U}_q\mathbf{Q}$ , 其中  $\mathbf{U}_q \in C^{N \times q}$  由自相关矩阵  $\mathbf{R}_x$  的  $q$  个不同的特征向量组成,  $\mathbf{Q} \in C^{q \times q}$  为任意酉矩阵, 在每个平衡点, 目标函数  $J(\mathbf{W})$  的值等于特征向量不在  $\mathbf{U}_q \in C^{N \times q}$  的那些特征值之和。

**定理 2** 目标函数  $J(\mathbf{W})$  的所有平衡点都是鞍点, 除非  $\mathbf{U}_q \in C^{N \times q}$  由自相关矩阵  $\mathbf{R}_x$  的  $q$  个主特征向量组成, 在这一情况下,  $J(\mathbf{W})$  达到全局最小点。

定理 1 和定理 2 表明了以下事实:

(1) 定理 1 表明, 当  $\mathbf{W}$  的列空间等于干扰子空间, 即  $\text{col}(\mathbf{W}) = \text{span}(\mathbf{U}_j)$  时, 目标函数  $J(\mathbf{W})$  达到全局极小值, 并且目标函数没有其他的任何局部极小值。

(2) 虽然定义目标函数和无约束极小值问题时, 没有要求  $\mathbf{W}$  的列正交, 但是两个定理表明, 目标函数  $J(\mathbf{W})$  极小化将自动导致  $\mathbf{W}$  为半正交矩阵, 即满足  $\mathbf{W}^H\mathbf{W} = \mathbf{I}$ 。

(3) 虽然  $\mathbf{W}$  不是唯一确定的, 但投影矩阵  $\mathbf{P} = \mathbf{W}(\mathbf{W}^H\mathbf{W})^{-1}\mathbf{W}^H = \mathbf{W}\mathbf{W}^H = \mathbf{U}_j\mathbf{U}_j^H$  是唯一确定的, 也就是说, 不同的解张成相同的列空间。

因此, 具有正交性约束和齐次性约束的目标函数  $J(\mathbf{W})$  极小化求解问题等价于特征值分解问题。然而在实际应用中, 接收信号的统计特性可能是随时间变化的, 自相关矩阵

的特征值和特征向量也是随时间变化的, 目标函数的瞬时梯度为

$$\nabla J(\mathbf{W}(n)) = [-2\mathbf{R}_x(n) + \mathbf{R}_x(n)\mathbf{W}(n-1)\mathbf{W}^H(n-1) + \mathbf{W}(n-1)\mathbf{W}^H(n-1)\mathbf{R}_x(n)]\mathbf{W}(n-1) \quad (23)$$

将  $\mathbf{R}_x(n) = \mathbf{x}(n)\mathbf{x}^H(n)$  代入式(23), 并利用半正交约束条件  $\mathbf{W}(n)\mathbf{W}^H(n) = \mathbf{I}$ , 可得到求解极小化问题的梯度下降法

$$\mathbf{y}(n) = \mathbf{W}^H(n)\mathbf{x}(n) \quad (24)$$

$$\mathbf{W}(n) = \mathbf{W}(n-1) + \mu[\mathbf{x}(n) - \mathbf{W}(n-1)\mathbf{y}(n)]\mathbf{y}^H(n) \quad (25)$$

但这一更新  $\mathbf{W}(n)$  的梯度下降算法收敛速度慢, 跟踪子空间的能力比较差, 更好的方法是使用递推最小二乘(RLS)算法。假设  $l = 1, 2, \dots, n$  时刻, 最优权值不变, 定义指数加权的标函数

$$J'(\mathbf{W}(n)) = \sum_{l=1}^n \beta^{n-l} \|\mathbf{x}(l) - \mathbf{W}(n)\mathbf{W}^H(n)\mathbf{x}(l)\|^2 = \sum_{l=1}^n \beta^{n-l} \|\mathbf{x}(l) - \mathbf{W}(n)\mathbf{y}(l)\|^2 \quad (26)$$

式中  $0 < \beta < 1$  为遗忘因子,  $\mathbf{y}(l) = \mathbf{W}^H(n)\mathbf{x}(l)$ , 由自适应滤波理论可知, 最小化问题  $\min J'(\mathbf{W}(n))$  的最优解为 Wiener 滤波器

$$\mathbf{W}(n) = \mathbf{R}_{xy}(n)\mathbf{R}_{yy}^{-1}(n) \quad (27)$$

上式中指数加权样本平均互相关矩阵  $\mathbf{R}_{xy}(n)$  和自相关矩阵  $\mathbf{R}_{yy}(n)$  可以递推出

$$\mathbf{R}_{xy}(n) = \sum_{l=1}^n \beta^{n-l} \mathbf{x}(l)\mathbf{y}^H(l) = \beta\mathbf{R}_{xy}(n-1) + \mathbf{x}(n)\mathbf{y}^H(n) \quad (28)$$

$$\mathbf{R}_{yy}(n) = \sum_{l=1}^n \beta^{n-l} \mathbf{y}(l)\mathbf{y}^H(l) = \beta\mathbf{R}_{yy}(n-1) + \mathbf{y}(n)\mathbf{y}^H(n) \quad (29)$$

将式(28)和式(29)代入式(27), 并利用矩阵求逆引理, 可以得到迭代最小二乘权值(RLS)更新过程, Yang 提出预测逼近子空间(PAST)法<sup>[6]</sup>。文献[7]利用自联合神经网络模型, 推导了一种稳健的RLS算法(RRLS), 对于最大的  $K$  个特征值和特征矢量估计问题, RRLS算法给出如下<sup>[7]</sup>:

初始化  $\tilde{\mathbf{w}}_m(0), m = 1, 2, \dots, K$  为小随机矢量

$$\mathbf{x}_1(n) = \mathbf{x}(n)$$

FOR  $m = 1, 2, \dots, K$  DO

$$\hat{\mathbf{w}}_m(n-1) = \tilde{\mathbf{w}}_m(n-1) / \|\tilde{\mathbf{w}}_m(n-1)\|$$

$$y_m(n) = \hat{\mathbf{w}}_m^H(n-1)\mathbf{x}_m(n)$$

$$\tilde{\mathbf{w}}_m(n) = \beta\tilde{\mathbf{w}}_m(n-1) + y_m^*(n)\mathbf{x}_m(n)$$

$$\mathbf{x}_{m+1}(n) = \mathbf{x}_m(n) - y_m^*(n)\hat{\mathbf{w}}_m(n-1)$$

其中  $\tilde{\mathbf{w}}_m(n)$  为第  $n$  次迭代对第  $m$  个大特征值对应特征矢量的非归一化估计,  $\hat{\mathbf{w}}_m(n)$  是对  $\tilde{\mathbf{w}}_m(n)$  的归一化, RRLS 算法收敛速度比传统的 LMS-ATF 快, 并且更新一次权值仅需要  $4qN$  次乘法运算, 相对于 RLS-ATF ( $3N^2 + 7N$  次乘法)大大降低了运算量。实际应用中, 干扰子空间的秩  $q$  是未知的, 用

$$\sigma^2(n) = \|\mathbf{x}_{m+1}(n)\|^2 / (N - K) \quad (30)$$

作为第  $n$  次迭代后对噪声功率的估计, 由于窄带干扰功率远远大于扩频信号和背景噪声的功率, 通过设置一个合理的门限 TH; 当  $y_K(n) / (\sigma^2(n) \cdot N) > \text{TH}$  时, 则增加跟踪子空间的维数; 当检测到  $y_{K-1}(n) / (\sigma^2(n) \cdot N) < \text{TH}$  时, 则相应地减小一维跟踪子空间的维数; 为保证子空间跟踪迭代过程具有足够的时间收敛, 在一个接收符号内干扰子空间的维数保持不变, 即子空间跟踪算法每迭代  $G_p$  次, 重新估计一次干扰子空间的维数  $q = K - 1$ 。

## 5 仿真结果分析

仿真中系统扩展比为 32, PN 码取  $m$  序列, 噪声功率  $\sigma_n^2 = 0.01$ , 无干扰时比特信噪比为 10dB, 信干比  $\text{SIR} = -20\text{dB}$ , 基于 LMS 算法的自适应横向滤波器(ATF), 使用抽头数  $N = 20$  的线性预测滤波器, 滤波器的失调量取 0.05, RRLS 特征子空间法子空间的维数  $N = 20$ , 遗忘因子  $\beta = 0.99$ 。

图 2 分别给出单音、多音(3 个单音干扰)时, RRLS 算法的收敛性能曲线, 为了便于比较, 图中同时给出 LMS 线性自适应预测滤波器的仿真结果。为消除单音干扰频偏的影响, 在干扰频偏在  $[0,1]$  之间均匀随机取值进行 100 次 Mont-Carlo 仿真试验进行集平均, 从图 2(a)可以看到, LMS 自适应预测滤波器需要 300 次左右迭代才能收敛, 而文中提出的 RRLS 子空间跟踪法只需要 40 次左右的迭代就可稳定的收敛, 并且 RRLS 算法的输出均方误差(MSE)小于线性预测滤波器; 图 2(b)为多音干扰条件下两种算法的收敛性能比较, 3 个单音干扰的归一化频偏分别为  $[0.037, 0.241, 0.497]$ , 分布在接收信号频谱的低、中、高 3 个频段, 从图中仿真结果可以看到, LMS 自适应算法需要 1000 次左右的迭代才能收敛, 而 RRLS 子空间跟踪法收敛速度远快于 LMS 算法, 当初始化  $q = 2$  时, RRLS 算法需要 200 次迭代便可收敛, 如果初始化  $q = 6$ , 则 RRLS 算法经过 100 次迭代便可收敛, 并且其 MSE 小于 LMS 算法。




图 2 RRLS 算法收敛特性曲线

图 3 给出 RRLS 算法在单音、多音干扰下的误码率曲线仿真结果, 为了保证算法收敛, 每次仿真从第 30 个接收符号开始统计误码率, 从图 3 中的结果可以看出, 采用 RRLS 子空间跟踪法得到的误码率与直接对观测数据矩阵进行 SVD 分解的相比略有下降, 这是由于子空间跟踪的误差引起的。对于多音干扰, 由于干扰子空间的秩较大, 因此抑制干




图 3 接收机误码率曲线

扰的同时对有用信号造成的能量损失也较大。总的来看, RRLS 子空间跟踪法可以较准确地跟踪干扰子空间, 实现对单音、多音干扰的有效抑制。

## 6 结束语

将子空间跟踪法应用在直接序列扩频(DSSS)通信系统, 以提高系统的抗窄带干扰能力, 采用稳健的最小二乘(RRLS)算法对子空间进行更新, 并根据干扰子空间最小特征值与噪声功率的比值自动确定干扰子空间的维数, RRLS 算法收敛速度快, 相对于传统的 RLS-ATF 算法大大降低了运算量, 并且算法数值稳定性好, 易于工程实现。

## 参考文献

- [1] Milstein L B. Interference rejection techniques in spread spectrum communications [J]. *Proc. IEEE*, 1988, 76(6): 657-671.
- [2] Ketchum J W and J G Proakis. Adaptive algorithms for estimating and suppressing narrow-band interference in PN spread-spectrum systems [J]. *IEEE Trans. on Communications*, 1982, 30(5): 913-924.
- [3] Tufts D W, Kumaresan R, and Kirshtein I. Data adaptive signal estimation by singular value decomposition of a data matrix [J]. *Proc. IEEE*, 1982, 70(6): 684-685.
- [4] Rice B F, Fechner M, and Wilhoite M E. Multiple tone removal from short signal receiver using singular value decomposition [C]. Conference Record of the 27th Asilomar Conference on Signals, Systems and Computers, Pacific Grove, CA, USA, 1993, (1): 325-329.
- [5] 孙丽萍, 胡光锐. 直接序列扩频通信中窄带干扰抑制的奇异值分解方法[J]. *电子与信息学报*, 2003, 25(9): 1290-1293.
- [6] Yang B. Projection approximation subspace tracking [J]. *IEEE Trans. on Signal Processing*, 1995, 43(1): 95-107.
- [7] Ouyan S, Bao Z, and Liao G. Robust recursive least squares learning algorithm for principal component analysis [J]. *IEEE Trans. on Neural Networks*, 2000, 11(1): 215-221.

张春海: 男, 1976 年生, 博士, 研究方向为 DS-CDMA 通信抗干扰技术。

朱江: 男, 1974 年生, 博士, 副教授, 主要研究方向为软件无线电、CDMA 系统多用户检测技术等。

张尔扬: 男, 1942 年生, 教授, 博士生导师, 主要研究方向为软件无线电、阵列信号处理以及通信对抗技术等。