

# 脉冲噪声环境的一种递归全局最小平均 P-范数算法

常冬霞,冯大政

(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: 本文给出了适应于  $\alpha$ -稳定噪声环境的一种递归全局最小平均 P-范数算法,其可用于递归计算自适应滤波和系统辨识问题的全局最小平均 P-范数算法. 针对  $\alpha$ -稳定噪声的冲击性,本文所提出的自适应算法采用了有名的 power 迭代法,并通过计算机仿真比较了有关算法的性能.

关键词:  $\alpha$ -稳定噪声; FIR 自适应滤波; 递归全局最小平均 P-范数

中图分类号: TN911. 3 文献标识码: A 文章编号: 0372-2112 (2003) 03-0426-03

## An Recursive Total Least Mean P-Norm Algorithm Applied in Alpha-Stable Noise Environments

CHANG Dong-xia, FENG Da-zheng

(Key Lab for Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: A recursive total least  $l_p$ -norm (RTLMP) algorithm is developed to recursively compute the total least  $l_p$ -norm solution for adaptive finite impulse response (FIR) filters. Due to the existence of the non-Gaussian  $\alpha$ -stable noise, the performance of signal processing algorithms designed under the Gaussian assumption may degrade seriously. In this paper, a new adaptive algorithm based on the classical power iteration is developed which can minimize the  $l_p$  norm of the error function. The performance of the algorithm is evaluated via simulations. It is shown that the new algorithm achieves superior convergence rate.

Key words:  $\alpha$ -stable noise; adaptive FIR filter; recursive total least  $l_p$ -norm

### 1 引言

自从  $\alpha$ -稳定分布引入信号处理领域以来,已经出现了多种自适应滤波方法<sup>[1,2,5]</sup>,所有这些方法都可以归为最小均方(LMS)算法.但是,由于  $\alpha$ -稳定信号不存在有限的二阶和二阶以上的矩<sup>[3]</sup>,因此这些算法与传统的 LMS 算法并不完全相同,它们均用最小离差准则代替了传统的 LMS 算法中的最小二乘准则.所谓的最小离差准则即使误差的  $l_p$ -范数最小,在最小离差准则下,很多的学者已经作了许多的工作,但现存的多种算法均存在着无法克服的缺点,因此,我们仍需要寻找更好的方法.

本文给出了一种类似于递归总体最小二乘(RTLS)算法的递归总体最小平均 P-范数(RTLP)算法,在估计的过程中采用了 power 迭代法,并应用矩阵求逆引理克服了直接求逆的繁琐计算,在文章的最后给出了计算机仿真,显示了该算法性能的优越性.

给定一个具有有限脉冲响应的未知系统,假设输入和输出皆存在噪声,则自适应 FIR 滤波依据输入和输出测量值估计的未知系统的脉冲响应如图 1 所示.

假设未知系统的有限脉冲响应是  $N \times 1$  维向量:




图1 考虑输入向量噪声  $n_1(k)$  的脉冲响应估计图

$$h = [h_0, h_1, \dots, h_{N-1}]^T \quad (1)$$

$h$  可以是时变的,但这里假设它为常量,所谓的“期望”信号由下式给出:

$$d(k) = X^T(k) h + n_0(k) \quad (2)$$

其中,观测噪声  $n_0(k)$  是参数为  $(\alpha, \beta) = (\alpha_0, 0, 1)$  的  $\alpha$ -稳定白噪声,且与输入向量独立,输入向量为:

$$X(k) = [x(k), x(k-1), \dots, x(k-N+1)]^T \quad (3)$$

由于未知系统的输入必须和期望信号一起采样和量化,因此会产生宽带的量化噪声污染自适应滤波器的输入,而且外界干扰也会使输入产生噪声.因此,这里采用的 FIR 自适应滤波器信号模型更具一般性.

## 2 与 FIR 自适应滤波相关的全局最小 $l_p$ -范数问题

考虑下面的 FIR 系统辨识问题,设有个含有噪声的独立变量:

$$r(k) = [x(k) + n_1(k), x(k-1) + n_1(k-1), \dots, x(k-N+1) + n_1(k-N+1)]^T \quad (4)$$

其中:  $n_1(k)$  是离差为  $\sigma^2$  的  $S(1)$  稳定噪声,且有一个含有噪声的非独立变量  $d(k)$ . 因此,  $k$  时刻的  $(N+1)$  维推广观测数据向量为:

$$\bar{r}(k) = [r(k), d(k)]^T \quad (5)$$

$$h(k) = [h_0, h_1, \dots, h_{N-1}]^T \quad (6)$$

是待寻找的递归参数. 定义  $(N+1)$  维的扩展向量:

$$\bar{w} = [w, w_N]^T \quad (7)$$

其中:  $w = [w_0, w_1, \dots, w_{N-1}]^T$ , 则 FIR 模型的系统辨识问题可以表示为:

$$\bar{w}^T \bar{r}(k) = 0, \quad k = 1, 2, \dots, L \quad (8)$$

RLMP 解源于如下优化问题:

$$\bar{w} = \arg \min_w E \left\{ \frac{|\bar{w}^T \bar{r}(k)|^p}{\bar{w}^T \bar{r}(k)} \right\} \quad (9)$$

$$\begin{bmatrix} W_{LMP} \\ -1 \end{bmatrix} = - \frac{\bar{w}}{w_N} \quad (10)$$

其中:  $\bar{w}$  是  $(N+1)$  维递归参数矢量,  $\bar{r}$  为加权矩阵, 对应于不同的加权矩阵可得到不同的算法<sup>[6]</sup>, 本文取为:

$$\bar{r} = \begin{bmatrix} I & 0 \\ 0 & 1 \end{bmatrix} \quad (11)$$

其中:  $I$  是  $N \times N$  维单位矩阵,  $\alpha = \sigma^2 / \sigma^2$  是与输入和输出噪声相关的常数, 当噪声的参数先验未知时, 通常可简单的取  $\alpha = 1$ .

我们可以将问题(9)等价于下面的极值化问题:

$$\begin{aligned} \bar{w} = \arg \min_w E \{ |\bar{w}^T \bar{r}(k)|^p \} \\ \text{s. t. } \bar{w}^T \bar{r}(k) = 0 \end{aligned} \quad (12)$$

其中  $\alpha$  为任意常数, 取期望估计为仅依赖于当前时刻数据的无记忆估计  $E\{|\bar{w}^T \bar{r}(k)|^p\} = |\bar{w}^T \bar{r}(k)|^p$ , 则问题(12)可简化为:

$$\bar{w} = \arg \min_w |\bar{w}^T \bar{r}(k)|^p \quad (13)$$

$$\bar{w}^T \bar{r}(k) = 0 \quad (14)$$

为了得到所需要的自适应算法, 可以引入确定性目标函数:

$$J(n) = \sum_{k=0}^n \sum_{k=0}^{n-k} |e(k)|^p = \sum_{k=0}^n \sum_{k=0}^{n-k} |\bar{w}^T \bar{r}(k)|^p \quad (15)$$

上式可变为:

$$\begin{aligned} J(n) &= \sum_{k=0}^n \sum_{k=0}^{n-k} |\bar{w}^T \bar{r}(k)|^{p-2} \bar{w}^T \bar{r}(k) \bar{r}^T(k) \bar{w} \\ &= \bar{w}^T \sum_{k=0}^n \sum_{k=0}^{n-k} u(k) \bar{r}(k) \bar{r}^T(k) \bar{w} = \bar{w}^T \bar{R}(n) \bar{w} \end{aligned}$$

其中:

$$\begin{aligned} u(k) &= |\bar{w}^T \bar{r}(k)|^{p-2} \\ \bar{R}(n) &= \sum_{k=0}^n \sum_{k=0}^{n-k} u(k) \bar{r}(k) \bar{r}^T(k) \end{aligned} \quad (16)$$

为了追踪系统的非平稳性我们可将式(16)表示为递推形式,

即:

$$\bar{R}(n) = \bar{R}(n-1) + u(n) \bar{r}(n) \bar{r}^T(n) \quad (17)$$

其中  $\lambda$  为遗忘因子, 它使得新到的数据较之旧数据更为重要, 这里是  $0 < \lambda < 1$  常数, 它决定算法的有效记忆长度. 当  $\lambda = 1$  时, 算法具有无限长记忆. 当  $\lambda < 1$  时, 算法的有效记忆长度为  $m = -1/\log \lambda \cong 1/(1-\lambda)$  个数据点. 为了说明这一情况, 我们可以暂时考虑  $|e(k)|^p = 1$  的情形. 则

$$J(n) = \sum_{k=0}^n \lambda^{n-k} = (1 - \lambda^{n+1}) / (1 - \lambda)$$

我们定义有效记忆长度为  $n+1 = m$ ,  $m$  必须满足  $J(m)/J(n) > 0.9$ . 这样,  $1 - \lambda^m = 0.9$ . 当  $\lambda$  非常接近于 1 时,  $\log(1 - \lambda) \cong -\lambda - 1$ . 通常在具体的算法中可据经验对  $\lambda$  进行赋值. 为了求得  $\bar{w}_{opt}$  采用 power 迭代法<sup>[4]</sup>, 即:

$$\bar{w}(n+1) = \bar{R}^{-1}(n+1) \bar{w}(n)$$

这样我们就需要对广义相关矩阵  $\bar{R}(n)$  求逆, 通常我们并不采用先求  $\bar{R}(n)$  然后再求逆的方法, 而是应用矩阵求逆引理直接求得  $\bar{R}^{-1}(n)$ . 对式(17)应用矩阵求逆引理可得:

$$\begin{aligned} \bar{R}^{-1}(n) &= \frac{1}{\lambda} \bar{R}^{-1}(n-1) \\ &\quad - \frac{1}{\lambda} \frac{\bar{R}^{-1}(n-1) u(n) \bar{r}(n) \bar{r}^T(n) \bar{R}^{-1}(n-1)}{u(n) \bar{r}^T(n) \bar{R}^{-1}(n-1) \bar{r}(n)} \end{aligned} \quad (18)$$

为了方便可以令:

$$\begin{aligned} P(n) &= \bar{R}^{-1}(n) \\ a(n) &= \lambda + u(n) \bar{r}^T(n) P(n-1) \bar{r}(n) \\ g(n) &= \frac{1}{a(n)} P(n-1) \bar{r}(n) \end{aligned}$$

则式(18)可写为:

$$P(n) = \frac{1}{\lambda} P(n-1) - \frac{1}{\lambda} u(n) P(n-1) g(n) \bar{r}^T(n) P(n) \quad (19)$$

又由约束条件式(12)可知, 在每次迭代过程中权向量保持  $l_p$ -范数不变, 所以

$$\bar{w}(n) = \bar{w}(n) / \bar{w}(n) \frac{1}{\lambda^{n-1}}$$

这样我们就可以给出 RLMP 算法的紧凑形式.

算法 1(RLMP 算法)

初始化:  $\bar{w}(0) = [0, \dots, 0]^T$ , 其中  $0$  为  $1 \times N$  维行向量,  $P(0) = \lambda^{-1} I$ , 其中  $\lambda$  为很小的正数,

For  $k = 1$  to  $L$

$$\begin{aligned} u(k) &= |\bar{w}^T \bar{r}(k) \bar{r}(k)|^{p-2} \\ a(k) &= \lambda + u(k) \bar{r}^T(k) P(k-1) \bar{r}(k) \\ g(k) &= \frac{1}{a(k)} P(k-1) \bar{r}(k) \\ P(k) &= \frac{1}{\lambda} P(k-1) - \frac{1}{\lambda} u(k) g(k) \bar{r}^T(k) P(k-1) \\ \bar{w}(k) &= P(k) \bar{w}(k-1) \\ \bar{w}(k) &= \bar{w}(k) / \bar{w}(k) \frac{1}{\lambda^{k-1}} \\ \bar{w}(k) &= [w_0, w_1, \dots, w_{N-1}] / w_N \end{aligned}$$

其中  $w_i, i = 0, 1, \dots, N-1$  为  $\bar{w}$  的元素.

## 3 仿真结果

为了比较 RLMP 和 RLMP 自适应算法的性能, 考虑脉冲

响应为:

$$h = [-0.3, -0.9, 0.8, -0.7, 0.6]^T \quad (20)$$




图2  $\alpha = 1.2, p = 1.18$ , 两种自适应算法的性能比较




图3  $\alpha = 1.5, p = 1.45$ , 两种自适应算法的性能比较

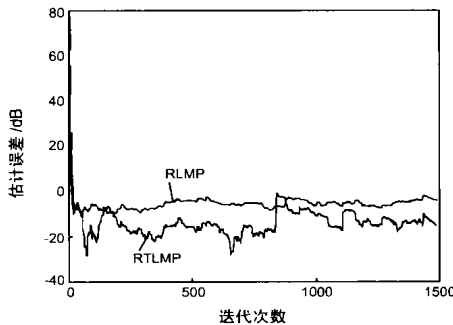


图4  $\alpha = 1.8, p = 1.76$ , 两种自适应算法的性能比较

的未知系统. 系统由高斯白噪声激励, 输入噪声和输出噪声分别是特征指数  $\alpha_0$  和  $\alpha_1$  且方差  $\sigma_0 = \sigma_1 = 1$  的对称  $\alpha$ -稳定分布噪声. 如图 1 所示, 估计均方误差定义为:

$$E(n) = 20 \log_{10} \|w(n) - h\|_2$$

其中  $w(n)$  是脉冲响应的估计. 分别给出了在相同信噪比和不同特征指数情况下的误差曲线图, 仿真中均取  $SNR = 5\text{dB}$ .

通过仿真可以看出 RTLMP 算法的性能较 RLMP 算法的性能有了一定的提高, 同时随着特征指数的增大, 两种自适应算法的性能将越来越接近. 本文只对 RTLMP 算法进行了初步的研究, 对于递归总体最小 P-范数估计子的性质仍有待进一步研究.

#### 参考文献:

- [ 1 ] C L Nikias, M Shao. Signal Processing with Alpha-Stable Distributions and Applications[M]. New York: Wiley, 1995.
- [ 2 ] O Ankan, M Belge, E Cetin, E Erzin. Adaptive filtering approaches for non-gaussian stable process [A]. Proc ICASSP '95 [C]. New York: IEEE, 1995, 2: 1400 - 1403.
- [ 3 ] M Shao, C L Nikias. Signal processing with fractional lower order moments: Stable process and their application [J]. Proc IEEE July, 1993, 81(7): 986 - 1009.
- [ 4 ] R Vaccaro. On adaptive implementations of Pisarenko's harmonic retrieval [A]. Proc ICASSP '85 [C]. New York: IEEE, March 1984. 6. 1.1 - 6.1.4.
- [ 5 ] S Haykin. Adaptive Filter Theory (2nd ed) [M]. New York: Prentice Hall, 1996.
- [ 6 ] C E Davila. An Efficient Recursive Total Least Squares Algorithm for FIR Adaptive Filtering [J]. IEEE Trans Signal Processing, Feb 1994, 42(2): 268 - 280.

#### 作者简介:

常冬霞 女, 1977 年 12 月出生于河北衡水, 西安电子科技大学硕士研究生, 主要研究方向为自适应信号处理.

冯大政 男, 1959 年 12 月出生于陕西紫阳, 博士, 现为西安电子科技大学教授, 博士生导师, 主要研究方向有: 信号处理, 智能信号处理和雷达成像.