

有色非高斯背景下微弱信号的 Rao 有效绩检验

王平波, 蔡志明

(海军工程大学电子工程学院, 湖北武汉 430033)

摘要: 混合高斯 Rao 有效绩检验是实现有色非高斯背景下微弱信号检测的渐近最佳检测器, 预白化和高斯化技术的应用使得它的检测性优于传统的匹配滤波器. 在使用混合高斯自回归模型描述检测问题之后, 基于功率谱密度和概率密度参数估计, 引入预白化和高斯化滤波器, 构建起模块化的、实用的混合高斯 Rao 有效绩检测器. 然后对其检测性能进行了深入分析, 揭示了预白化和高斯化技术改善检测性能的机理所在. 最后给出了一组湖试数据检测实例.

关键词: 混合高斯自回归模型; Rao 有效绩检验; 广义似然比检验; 预白化; 高斯化

中图分类号: TJ630 **文献标识码:** A **文章编号:** 0372-2112(2007)03-0534-05

The Rao Efficient Scores Test of Weak Signals in Colored Non-Gaussian Background

WANG Ping-bo, CAI Zhi-ming

(Electronic Engineering College, Navy Engineering University, Wuhan, Hubei 430033, China)

Abstract: The Rao efficient scores test is an asymptotic optimal detector to test weak signals in colored non-Gaussian background. Since applying technologies of prewhitening and gaussianization, it can get better detecting performance than conventional match filter. Gaussian mixture autoregressive model is addressed with the test problem being described. Estimations of parameters for this model are required for construct of the detector. Based on these parametric estimations, the filters of prewhitening and gaussianization are applied in constructing the practical modular Rao efficient scores test. With its detecting performance being analyzed deeply, the causes why technologies of prewhitening and gaussianization can improve detecting performance are brought to light. Finally, a test instance with lake trial data is illustrated.

Key words: gaussian mixture autoregressive model; rao efficient scores test; GLRT; prewhiten; Gaussianization

1 引言

在传统的主动信号检测中, 干扰背景多被看作为白高斯的, 这种背景下信号的最佳检测即匹配滤波(或副本相关). 但实际应用中的某些检测的干扰背景, 比如主动声纳中的混响、主动雷达中的杂波等, 由于数据中有突出的冲激存在, 它们的概率密度函数(PDF)往往具有重尾(Heavy tails)特性, 因此是非高斯的; 同时又由于与发射信号具有较强的相关性, 它们的功率谱密度(PSD)往往与发射或回波信号相似, 是非白的. 实践表明, 对于这种非白非高斯干扰背景下信号的检测, 传统的匹配滤波检测效果会大为降低. 近十几年来, 为解决有色非高斯背景下的信号检测问题, 国内外业界作了大量的研究工作, 找到了一系列全新或改良的检测途径, 比如在传统似然比检测中加入了未知参数估计的广义似然比检验(GLRT)^[1, 2]、与之近似适合小信噪比简化了参数估计

的 Rao 有效绩检验(简记作 REST, 有时简称为 Rao 检测)^[3]、与传统高斯假设检测完全不同改而利用高阶检验统计量(HOS)的 HOS 检测^[4]、基于鲁棒性预白采用双边门限的 RAR 和 RSWS 检测^[5]等等. 这些检测方法各有优劣, 具有符合各自对背景 PSD/PDF 假设的适用范围. 综合考虑之下, 我们认为 Steven Kay 等人所研究的 GLRT/REST 是一种不错的检测方案.

在[1~3, 6]等文献中, Steven Kay, Debasis Sengupta 等人基于仿真研究了非高斯背景下的 GLRT 及其在小信噪比下的近似, 即 REST, 给出了理论表述式和相关框图. 但是, 他们仅限于理论性探讨, 并未对检测器结构根据功能作进一步的模块化划分致使他们所提出的检测器框架看起来复杂而凌乱. 而且他们的研究都基于 PDF 参数已知(或部分已知)的仿真数据, 而对于实际应用, 无论预白还是后续检测, 首先遭遇的就是未知的 PDF 参数, 他们所提出的检测框架显然就无能为力. 事实

上, 摒除具体的理论推导只看结果, GLRT/REST 秉承了传统的检测思路并延伸下去: 对非白背景进行白化、对非高斯背景进行高斯化, 然后再进行相关检测, 这应当不啻为一种解决问题的好办法。只要数据 PSD/PDF 建模准确, GLRT/REST 应当能够取得与高斯条件下的匹配滤波接近的检测效果, 是有色非高斯背景下信号的次最佳(或者渐近最佳)检测器。

在考察引进 Kay 等人的 REST 有关最初理论之后, 本文中我们进一步地, 使用混合高斯自回归模型描述背景统计特性和检测问题; 明确了非高斯 PDF 参数估计在 REST 中的位置和地位; 讨论 REST 的检测性能时, 厘清了预白化和非高斯假设分别能够带来的信噪比改善; 根据功能对 REST 框架进行了划分和重组, 使检测器结构模块化、简明化, 便于实际应用; 在上述改进的基础上, 我们把 REST 成功应用到了实际数据检测中, 给出了一组湖试数据 Rao 检测实例。

2 检测问题描述

使用混合高斯自回归模型(GMAR)^[8]来描述有色非高斯背景下微弱信号(采用幅度未知的确知信号形式)的检测问题, 其二元假设如式(1)所示。

$$\begin{cases} H_0: y_n = - \sum_{j=1}^p a_j y_{n-j} + u_n \\ H_1: y_n = \mu s_n - \sum_{j=1}^p a_j (y_{n-j} - \mu s_{n-j}) + u_n \end{cases} \quad (1)$$

这里, $n = 1, 2, \dots, N$; $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$ 为观测样本; $\mathbf{a} = [a_1, a_2, \dots, a_p]^T$ 是观测样本功率谱的 P 阶 AR 描述; $\mathbf{s} = [s_1, s_2, \dots, s_N]^T$ 是确定性信号序列; μ 是信号加权常数, 可以之调节信噪比, 这也是信号唯一的未知参数, 就微弱信号检测而言, μ 值很小。 $\mathbf{u} = [u_1, u_2, \dots, u_N]^T$ 为具有式 2 所示二阶零均值混合高斯 PDF 的非高斯白激励序列。

$$f(u_n) = (1 - \varepsilon)f_B(u_n) + \varepsilon f_I(u_n) \quad (2)$$

其中: $f_B(u_n) = (1/\sqrt{2\pi\sigma_B^2})\exp\{-u_n^2/(2\sigma_B^2)\}$ 为高斯分布 $\sigma(0, \sigma_B^2)$ 的 PDF, 可用以描述数据中背景(噪声)部分统计特性, σ_B^2 一般较小; $f_I(u_n) = (1/\sqrt{2\pi\sigma_I^2})\exp\{-u_n^2/(2\sigma_I^2)\}$ 为高斯分布 $\sigma(0, \sigma_I^2)$ 的 PDF, 可用以描述数据中冲激(混响、杂波等随机脉冲)部分统计特性, σ_I^2 一般较大。为混合参数, 取值在 0 到 1 之间。显然 \mathbf{u} 的方差为 $\sigma^2 = (1 - \varepsilon)\sigma_B^2 + \varepsilon\sigma_I^2$ 。

简单地通过调整 GM 参数组 $\mathbf{g} = [\varepsilon, \sigma_B^2, \sigma_I^2]^T$ 和 AR 参数组 $\mathbf{a} = [a_1, a_2, \dots, a_p]^T$, GMAR 模型就可以拟合很广一类有色非高斯干扰背景的统计特性, 相应地式 1 就可以描述很广一类有色非高斯背景下的信号检测问题。

由 H_0 显然有如式(3)所示的反 AR 预白滤波器表达式。

$$u_n = \sum_{j=0}^p a_j y_{n-j}, \quad (a_0 \gg 1) \quad (3)$$

同样的预白滤波器加诸信号, 则有预白后的信号序列:

$$v_n = \sum_{j=0}^p a_j s_{n-j} \quad (4)$$

则 H_1 假设显然又可写作意义更加明确的式(5)。

$$u_n + \mu v_n = \sum_{j=0}^p a_j (y_{n-j} + \mu s_{n-j}) \quad (5)$$

3 检测器构建

文献[1, 2]中的 GLRT 应用于式(1)所述的检测问题, 可表述为式(6)。

$$l_G = \frac{\prod_{n=P+1}^N f\left(\sum_{j=0}^p \hat{a}_j (y_{n-j} - \hat{\mu} s_{n-j}); \hat{\mathbf{g}}\right)}{\prod_{n=P+1}^N f\left(\sum_{j=0}^p a_j y_{n-j}; \mathbf{g}\right)} \quad (6)$$

这里, 符号 $\hat{\cdot}$ 、 $\hat{\cdot}$ 分别表示 H_0 、 H_1 下的估计; 符号 Π 表示联乘; $\hat{a}_0 = \hat{a} = a_0 \triangleq 1$ 。显然 GLRT 需要对参数区分 H_0 、 H_1 作两次分类估计, 这不仅会令检测器结构复杂化、导致运算量巨大, 而且会由于实际中无法辨明有无回波使得 H_0 、 H_1 分类估计难以进行, 从而导致检测器难以被实际应用。文献[3]中接着研究了 GLRT 的简化技术, 指出在小信噪比下(也就是微弱信号下)完全可以使用 H_0 下的估计代替 H_1 下的估计, 相应地, GLRT(2 倍自然对数形式)可以等效为如式(7)所示的 Rao 有效性能检验。

$$l_R = \frac{\left[\sum_{n=P+1}^N \left(\sum_{j=0}^p \hat{a}_j s_{n-j} \right) \left(\sum_{j=0}^p \hat{a}_j y_{n-j} \right) \Gamma \left(\sum_{j=0}^p \hat{a}_j y_{n-j}; \varepsilon \right) \right]^2}{\sigma_B^4 I_f(\varepsilon) \sum_{j=0}^p \left(\sum_{j=0}^p \hat{a}_j s_{n-j} \right)^2} \quad (7)$$

这里, Γ 为一个可反映非高斯性的加权函数^[7]; I_f 为观测数据可反映 PDF 均值或位置的 Fisher 信息量^[10]。显然, 在 REST 中, 已不再需要 H_1 的估计量。与式(6)相比, 式(7)已经简化了许多, 但离实用却还有一定差距。

首当其冲的问题是, 式(7)把背景方差 σ_B^2 、冲激方差 σ_I^2 想当然地当作已知, 仿真研究中当然可以预设(事实上 Kay 等人正是这样做的), 但实际应用中这是不可能已知的, 即使使用经验值也是不可靠的, 因为大多数的非高斯背景同时具有非平稳性。其次, 从式(7)看, 加权函数 Γ 、Fisher 信息量 I_f 似乎仅与 PDF 中单一的一个参数 ε 有关, 实际应用中却并非如此, 它们同时还是 σ_B^2 、 σ_I^2 的函数。文献[7]中声称的可极大降低运算量、使用滤波器窗函数逼近 Γ 的方法在实际中也行不通, 因

为在 σ_B^2, σ_I^2 未知的情况下 $\varepsilon \sim \Gamma$ 曲线的形状本身就难以确定, 何谈逼近. 最后, 式(7)虽然体现出了检测中的预白化模块, 但却没有准确体现出高斯化模块, 更没有体现出 AR 模型与混合高斯模型二者之间的关系, 显得结构紊乱.

由于存在这些缺陷, 式(7)所示的 REST 还是难以在实际检测中应用. 事实上, 如果我们把数据的概率密度建模引进到 REST 中, 再使用高斯化滤波取代式(7)中花哨而不实用的加权函数 Γ , 然后在结构上作些调整, 问题就能迎刃而解了. 改良后的 REST 如式(8)所示, 相应的结构框图如图 1 所示. 这里 \hat{g} 为 PDF 混合高斯模型 (GM) 参数估计值(向量); \hat{a} 为 PSD 自回归模型 (AR) 参数估计值(向量); $u_n(y_n; \hat{a}), v_n(s_n; \hat{a})$ 分别为预白后的观测数据和副本信号, 把 \hat{a} 代入式 3、4 中就能得到它们相应的表述式; U 为高斯化滤波函数, 它强调小样本、抑制大样本来增强数据的高斯性, 其响应仅与 \hat{a} 有关, 输入混合高斯序列, 输出高斯或接近高斯的序列, 具体形式既可以从 Γ 变化而来, 也可从高斯分布逆函数变化而来; 计算 I_f 时把 ε 之外的 PDF 参数也考虑进来了.

$$l_R = \frac{\left\{ \sum_{n=P+1}^N v_n(s_n; \hat{a}) \cdot U[u_n(y_n; \hat{a}); \hat{g}] \right\}^2}{\sigma_B^2 I_f(\hat{g}) \cdot \sum_{n=P+1}^N v_n^2(s_n; \hat{a})} \quad (8)$$




图 1 混合高斯 Rao 检测器框图

关于功率谱密度 AR 模型参数估计, 可以采用传统的最小二乘算法(比如: 自相关法、协方差法、Burg 算法、Marple 算法等), 虽然这类算法往往具有较快的速度, 但由于忽略了非高斯三阶矩以上信息精度会有所不足. 文献[10]中的最大似然估计、文献[2, 7]中的加权最小二乘估计, 考虑了非高斯信息, 能够提高参数 a 的估计精度(实用中这些算法也还需要改进, 因为它们同样假设 σ_B^2, σ_I^2 已知). 关于概率密度 GM 模型参数估计, 也有很多方法可用, 比如: 最大似然算法、动态簇算法、EM 算法^[8]等等, 也应当根据具体需要来作选择. 值得注意的是, 参数 g 的估计应当是对预白化后的序列 u 进行的, 因为逆过程(即有色化)会改变 PDF, 直接基于观测数据 x 的 PDF 参数估计是不准确的. 这样一来, 为获得更高的参数估计精度, 在 AR 参数 a 与 GM 参数 g 的估计之间应当形成一定耦合, 图 1 中两个模块之间的中空箭头就是这个意思. 从这个意义上看, 文献[9]中

提出的 EMAX 算法不啻为一种很好的 PSD/PDF 参数一体化估计方案.

观测数据支路的功率均一化通过高斯化后的数据 U 与 $\sigma_B^2 \int_f$ 相除实现, 拷贝副本支路的能量归一化通过预白化的数据 v_n 与其能量方根 $\sqrt{E_v}$ 相除实现, 它们的作用是令检测输出趋向恒虚警.

$$l_{RG} = \frac{\left\{ \sum_{n=P+1}^N [v_n(s_n; \hat{a}) \cdot u_n(y_n; \hat{a})] \right\}^2}{\sigma^2 \cdot \sum_{n=P+1}^N v_n^2(s_n; \hat{a})} \quad (9)$$

在传统的高斯假设下, PDF 只有一个待估未知参数 σ^2 (背景方差), 式 8 中 σ_B^2 蜕化为 σ^2 , 而 U 蜕化为 $1/\sigma^2$, 混合高斯 Rao 检验统计量 l_R 则蜕化为如式(9)所示的高斯 Rao 检验统计量 l_{RG} . 不难看出, 这实际上是一个广义(带预白器)的匹配滤波器(后接平方检波).

4 检测性能分析

前文业已指出, REST 检测量 l_R 是 GLRT 检测量 $2\ln l_G$ 的近似, 所以也满足如式(10)所示的 χ 分布^[3]. 从而可得到 REST 地检测概率 P_d 、虚警概率 P_f 就如式 11 所示. 这里, F_r 是自由度为 1 的分布函数, Q 为标准正态分布的超越概率函数, γ 为 Rao 检测器门限.

$$\begin{cases} H_0: & l_R \sim \chi^2(1, 0) \\ H_1: & l_R \sim \chi^2(1, \lambda) \end{cases} \quad (10)$$

$$P_d = F_r\{l_R > \gamma | H_1\} = Q(\sqrt{\gamma} - \sqrt{\lambda}) + Q(\sqrt{\gamma} + \sqrt{\lambda}) \quad (11)$$

$$P_f = F_r\{l_R > \gamma | H_0\} = 2Q(\sqrt{\gamma})$$

考察式 11 可知:

(1) 根据指定的虚警概率 P_f 通过查表就可以得到相应的理论门限值 γ . 例如, 若 $P_f = 0.01$, 则 $\gamma = 6.635$.

(2) 在给定虚警概率(或门限)的前提下, 检测概率 P_d 是非中心参数 λ 的单调递增函数.

而 λ 的表达式如式(12)所示. 其中, $\theta_s = [a, \varepsilon]$ 为冗余参数, $I_{1\mu}, I_{1\sigma}, I_{0\mu}$ 皆为 Fisher 信息阵元素中的量. 显然, $\lambda \leq \lambda_s = \mu^2 I_{1\mu}(0, \theta_s)$, 当 θ_s 已知或检测量确知时, λ 取得上限 λ_s .

$$\lambda_s = \mu^2 [I_{1\mu}(0, \theta_s) - I_{1\sigma}^T(0, \theta_s) I_{0\sigma}^{-1}(0, \theta_s) I_{0\sigma}(0, \theta_s)] \quad (12)$$

对于式 7、8 所示的 Rao 检测器, 可得:

$$\lambda_s = s_0^T R^{-1} s_0 \cdot \sigma^2 I_f(\varepsilon) \quad (13)$$

其中, $s_0 = \mu$ 是包含幅度信息的信号向量, R 是背景序列的协方差矩阵. 分别以 B_w, B_c 简记式(11)中点乘号左右参量, 考察协方差矩阵 R 的构成, 则不难推得, B_w 相当于一理想预白滤波器依次级联一平方器和一卷积器后的输出信干比(信号与干扰功率比), 由此得到 λ_s 相应的结构框图如图 2 所示.




图 2 λ_c 构成示意图

不难理解, B_W 反映了信号和干扰功率谱密度对检测性能的影响。当 $N \rightarrow \infty$ 时, B_W 有如式 14 所示的极限表述。这里, f 是圆周频率; S_0 、 D 分别表示信号与干扰的功率谱。

$$B_W = s_0^T R^{-1} s_0 \int_{-1/2}^{1/2} \frac{|S_0(f)|^2}{D(f)} df \quad (14)$$

可以看到, 当信号功率谱与干扰功率谱形状接近时, B_W 较小; 相反地, 当信号功率集中在噪声功率谱值较小的频段内时, B_W 会较大。这一规律对我们有两方面启示:

(1) 在实际应用中应根据这一规律选择信号形式: 使得信号能量集中在噪声功率谱值较小的频段内, 以获得最大的输出信噪比 $10 \lg B_W$, 从而增大 λ , 提高检测概率。

(2) 在确定的信号形式下 ($|S_0|^2$ 已定), 为取得较高的 B_W 值, 需令干扰功率谱密度 D 尽量小, 最理想的情形是, 在频率-PSD 平面上, D 是一条最低的水平线, 即, 干扰是低功率的白谱。我们在检测中采用预白化, 就是为了要实现这一目标。

分别以下标 o 、 w 表示预白前后的相应量, 则由预白而获得的信干比“奖励”可表示为:

$$\Delta_W = 10 \lg(B_{Ww} - B_{Wo}) = 10 \lg(s_0^T R_w^{-1} s_0 - s_0^T R_o^{-1} s_0) \quad (15)$$

至于式(13)中右侧第二项 B_G , 取 $10 \lg$ 后, 就是混合高斯 Rao 检测器, 区别于高斯 Rao 检测器, 由于采用了非高斯假设而获得输出信干比“奖励” Δ_G , 有:

$$\Delta_G = 10 \lg B_G = 10 \lg(\sigma^2 I_f) \quad (16)$$

若采用高斯假设, 则 $B_G = 1$, $\Delta_G = 0 \text{ dB}$, 故传统的高斯 Rao 检测器不能获得这种信干比奖励。换言之, 混合高斯 Rao 检测比高斯 Rao 检测优越之处在于: 对于同样的信号和非高斯干扰背景, 为了获得同样的检测效果, 理论上前者所需信干比要比后者低 $\Delta_G \text{ dB}$ 。

下面是一组仿真实例。信号: 采用几何梳状谱(GC)信号, 中频为 1.7kHz, 带宽为 1kHz, 梳齿个数为 12; 干扰: 采用混合高斯色噪声, 首先使用柏努里试验法产生混合高斯白噪声 ($\sigma_B^2 = 1$, $\sigma_I^2 = 81$, $\epsilon = 0.3$), 然后使用 AR 拟合指定功率谱(限带单参数指数模型, 3dB 频带同于信号, 每倍频程衰减率为 7dB)的方法有色化之。根据设定的信干比 SNR 将信号加权叠加到干扰背景上, 形成混合输入序列。分别通过混合高斯 Rao 和高斯 Rao 检测器后得到如图 3 所示的 ROC 曲线(虚警概率为 0.01, 250 蒙特卡罗试验, 每次试验 2048 点, 合 250ms; 检测中并未像文[3]中那样直接使用 σ_B^2 、 σ_I^2 真值, 而是完全按照图 1 所示的 REST 框架进行)。

根据当前的信号、背景设置情况, σ^2 为 25、 I_f 约为

0.56。由式(16)可得混合高斯 Rao 检测比高斯 Rao 检测获得的信干比奖励应为 11.4dB(注意: 无论高斯 REST 还是非高斯 REST 都经过了预白, 所以我们应当比较式 16 所示的 Δ_G)。而考察图 3 亦可看到, 对同一检测概率, 混合高斯 Rao 检测器所需信噪比低于高斯 Rao 检测器约 11dB, 符合理论期望。




图 3 混合高斯 Rao 与高斯 Rao 检测性能比较

5 检测实例

图 4 是一段松花湖上试验数据常规波束形成后分




图 4 一段湖试数据检测灰度图

别经过匹配滤波、混合高斯 Rao 检测灰度图. 发射信号为正线性调频信号, 脉冲宽度 $T = 20\text{ms}$, 信号带宽 $B = 4\text{kHz}$, 中心频率 $f_c = 22\text{kHz}$; 数据采样频率 $f_s = 108\text{kHz}$; 接收阵为 17 元线阵, 在距离发射阵 34m、正横方向处掩埋一目标(氧气瓶). 接收数据在波束形成后对直达波与不可能存在回波的发射脉冲后沿部分强混响进行了截断处理. 检测采用滑动窗技术, 窗长等于脉冲宽度, 相关运算采用频域 FFT 算法. 各灰度图的横坐标为距离 d (单位: m), 纵坐标为水平入射角 θ (单位: 度, 0° 为正横方向), 以亮度强弱表示数据值大小.

考察图 4 可见, 仅从波束形成后的数据(*a* 图)中看不出回波的位置所在. 而从直接的匹配滤波输出(*b* 图)看, 目标期望位置处(34m, 0°) 虽然略有亮区, 但被发射后沿混响造成的亮区所干扰, 而且, 同样由于发射后沿强混响的作用, (19m , 0°) 处出现了一个伪目标. 但这些问题在混合高斯 Rao 检测输出(*c* 图)中就都不存在了, 发射后沿混响的影响被有效抑制(灰度图前端不再有亮区), 而回波则被有效强调, 目标期望位置处的亮区非常明显. 而且, 多次后续检测(即依次使用后续两发射脉冲间的数据进行的检测)表明, 这一结果具有良好的重复性. 因此可以结论, 目标被成功检测到.

显然, 正是由于混合高斯 Rao 检测器采用了非高斯假设下的白化和高斯化技术, 检测结果才得以远优于普通的高斯 Rao 检测器(相当于广义匹配滤波检测器).

6 结束语

有色非高斯背景下微弱信号的 REST, 是根据“小信噪比”假设, 用 H_0 下参数估计代替 H_1 下参数估计, 对这一检测问题下的渐近最佳检测器 GLRT 进行简化从而获得的. 因此, 只要满足“小信噪比”假设, REST 也是这一问题下的一种渐近最佳检测器. 我们把 PDF 混合高斯模型参数估计、高斯化滤波、功率/能量均一化等模块引入并据此重组了 Kay 等人的 REST 框架, 形成了目前这样一种基于 PSD/ PDF 参数耦合估计、同时兼具预白化/高斯化两个主模块、最终表现为易于实现的相关检测形式的 REST 框架. 我们知道, 对于大多数实际的信号检测情形而言, “小信噪比”条件是能够得到满足的. 所以, 使用我们改良的 REST 应用于实际的水声、雷达等信号检测中是完全可行的, 文中的湖试实例也说明了这一点.

理论分析和实验研究都表明, 正是由于采用了预白化和高斯化两个模块, REST 的检测效果才得以高于普通的匹配滤波器(或相关接收机). 与后者相比, 为获得同样的检测概率, 采用预白化技术使得前者所需信干比降低约 Δ_{W} dB, 而采用非高斯假设使得前者所需信干比再降低约 Δ_{C} dB. 我们知道, 预白化和高斯化的效

果与谱估计、概率密度参数估计的精度紧密相关, 要获得良好的预白化和高斯化效果, 就必须提高背景功率谱密度、概率密度的建模精度. 再兼顾到实际应用中的硬件条件限制, 寻求一种高精度、高效率的 PSD/ PDF 耦合参数估计方法是势在必行的.

参考文献:

- [1] Steven Kay. A asymptotically optimal detection in incompletely characterized non gaussian noise[J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1989, 37(5): 627-633.
- [2] Debasis Sengupta, Steven Kay. Parameter estimation and GLRT detection in colored non Gaussian autoregressive processes[J]. IEEE Transaction on Acoustics, Speech and Signal Processing, 1990, 38(10): 1661-1676.
- [3] Steven Kay, Debasis Sengupta. Detection in incompletely characterized colored non Gaussian noise via parametric modeling [J]. IEEE Transactions on Signal Processing, 1993, 41(10): 3066-3070.
- [4] Brian M Sadler, Georgios B Giannakis, Kehr Shin Lii. Estimation and detection in non gaussian noise using higher order statistics[J]. IEEE Transactions on Signal Processing, 1994, 42(10): 2729-2741.
- [5] A J Efron, Hasik Jeon. Detection in impulsive noise based on robust whitening[J]. IEEE Transactions on Signal Processing, 1994, 42(6): 1572-1576.
- [6] Steven Kay, John Salisbury. Improved active sonar detection using autoregressive prewhiteners[J]. JASA, 1990, 87(4): 1603-1611.
- [7] Steven Kay, Debasis Sengupta. Statistically/computationally efficient estimation of non gaussian autoregressive processes[A]. ICASSP'87, Dallas, USA, 1987. 45-48.
- [8] R A Redner, H F Walker. Mixture densities, maximum likelihood, and the EM algorithm[J]. SIAM Review, 1984, 26(2): 195-239.
- [9] Shawn M Verbout. Parameter estimation for autoregressive gaussian mixture processes: the EMAX algorithm[J]. IEEE Transactions on Signal Processing, 1998, 46(10): 2744-2756.
- [10] Debasis Sengupta, Steven Kay. Efficient estimation of parameters for non gaussian autoregressive processes[J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1989, 37(6): 785-794.

作者简介:

王平波 男, 1976 年生于山东日照, 博士研究生, 研究方向为水声信号处理. E-mail: blackberet@163.com; blackberet@126.com

蔡志明 男, 1963 年生于福建福州, 博士生导师, 从事水声信号处理研究与教学工作.