

一种基于混合 RJMCMC 方法的宽带信号 DOA 估计方法

金美娜 赵拥军 盖江伟
(解放军信息工程大学 郑州 450002)

摘要: 该文基于被动多传感器阵列, 在可逆跳转马尔可夫链蒙特卡罗方法基础上引入随机游走抽样理论, 提出一种混合 RJMCMC 方法, 通过将局部采样与全空间采样相结合, 可以在更短的时间内得到更好地服从目标分布的随机数, 结合信号和噪声的统计特性以及贝叶斯参数估计理论可实现宽带信号源数目和波达方向联合估计。仿真结果证明, 该文方法能更为快速、准确地估计出信号源个数和波达方向。

关键词: 阵列信号处理; 贝叶斯原理; 混合 RJMCMC 抽样; 信号源数目估计; 波达方向估计

中图分类号: TN911.23

文献标识码: A

文章编号: 1009-5896(2010)02-0504-05

DOI: 10.3724/SP.J.1146.2009.00051

DOA Estimation of Wideband Signals Based on Hybrid RJMCMC Method

Jin Mei-na Zhao Yong-jun Ge Jiang-wei

(PLA Information and engineering University, Zhengzhou 450002, China)

Abstract: In this paper, an efficient hybrid sampling algorithm introducing the random walk method into the reversible jump Markov Chain Monte Carlo (RJMCMC) method is developed to jointly detect and estimate the wideband signals impinging on passive sensors, which combines the local sampling and the whole space sampling, and can get random number more obeying to target distribution in a shorter time. The method is proposed on the basis of Bayesian theory, and the statistical characteristic of the noise and signals. The accuracy and the validity of this method are well verified by the simulation.

Key words: Array signal processing; Bayesian theory; Hybrid RJMCMC; Source number detection; Direction of arrival estimation

1 引言

和传统的高分辨方位估计方法相比, 基于信号参数的最大后验概率密度估计的贝叶斯高分辨方位估计方法性能十分突出, 有较大的研究价值。贝叶斯高分辨估计方法是利用信号和噪声参数的联合后验概率密度函数实现对信号的谱估计^[1,2]。

2005年, William NG等人构建了一种时域阵列信号处理插值模型, 应用贝叶斯高分辨方位估计方法, 结合可逆跳转马尔可夫链蒙特卡罗方法(Reversible Jump Markov Chain Monte Carlo, RJMCMC)可同时估计出信号源数目和波达方向(DOA, Direction of Arrival)^[3]。但文献[3]在模型构建时将低通信号的重构方法直接用于带通信号, 因此构造插值矩阵时产生误差, 导致整个算法的估计精度不高。此外, 由于RJMCMC方法需要在多维空间跳转, 因此求解过程比较复杂, 运算量非常大。

基于被动多传感器阵列, 本文给出了一种更为有效的应用带通信号重构理论进行建模的方法, 并在RJMCMC方法基础上引入随机游走抽样理论, 提

出了混合RJMCMC抽样技术, 结合贝叶斯高分辨方位估计方法可实现宽带信号源数目与DOA联合估计。和文献[3]中的方法相比, 本文在没有增加算法复杂度的基础上提高了波达方向的估计精度, 并且减少了算法的运行时间。

2 信号模型

假定有 K 个宽带信号 $s_0(t), \dots, s_{K-1}(t)$, 信号的频率范围分别为 $f_k \in [f_k^l, f_k^u]$, $f_k^u = f_k^l + \Delta f_k$, $k = 0, \dots, K-1$, 以入射角 $\varphi = [\phi_0, \phi_1, \dots, \phi_{K-1}]^T$ 到达间距为 $d = \lambda/2$ 的 M 元均匀直线阵上。基于信号重构理论, 应用理想重构器(ideal reconstructor), 用采样信号可以重构原信号^[3], 即

$$s(t) = \sum_{l=-\infty}^{\infty} s(lT_s)\psi(t-lT_s) \quad (1)$$

其中 T_s 表示采样周期, $\psi(t)$ 为sinc函数, 即

$$\psi(t) = \frac{\sin(\pi t/T_s)}{\pi t/T_s} \quad (2)$$

在时域建模, 可以得到 M 个传感器的输出矢量 $\mathbf{y}(n)$ ^[3]

$$\mathbf{y}(n) = \mathbf{H}_0(\tau)\mathbf{a}(n) + \sum_{l=1}^{L-1} \mathbf{H}_l(\tau)\mathbf{a}(n-l) + \sigma_\omega \boldsymbol{\omega}(n) \quad (3)$$

其中 $\mathbf{a}(n) \triangleq [s_0(n), s_1(n), \dots, s_{K-1}(n)]^T$ 表示 K 个入射信号的幅度, $\omega(n)$ 表示环境噪声, σ_ω 表示噪声方差, $\mathbf{H}_l(\tau) \in \mathbf{R}^{M \times K}$, $l = 0, \dots, L-1$ 表示插值矩阵, 插值矩阵中包含信号的时延信息为

$$\boldsymbol{\tau} = [\tau_0, \tau_1, \dots, \tau_{K-1}]^T \quad (4)$$

$$\tau_k = (d/c) \sin \phi_k \quad (5)$$

插值矩阵的具体形式如下:

$$\mathbf{H}_l(\boldsymbol{\tau}) = [\mathbf{h}_l(\tau_0), \mathbf{h}_l(\tau_1), \dots, \mathbf{h}_l(\tau_{K-1})] \quad (6)$$

$$\mathbf{h}_l(\tau) \triangleq [h_l(0), h_l(\tau), \dots, h_l((M-1)\tau)]^T \quad (7)$$

$$h_l(m\tau) \triangleq \psi(lT_s - m\tau) \quad (8)$$

但通过研究发现这一重构方法不准确, 且难以确定采样信号的频率, 因此本文给出另外一种带通信号重构方法^[4], 定义

$$\varphi(t) = \text{sinc}\left(\frac{\pi}{2T_s}t\right) \cos\left(\frac{\pi}{T_s}\left(2k + \frac{1}{2}\right)t\right) \quad (9)$$

采样频率 f_s 满足

$$\lim_{\varepsilon \rightarrow 0} \frac{f^l}{n + \varepsilon} > f_s > \frac{2f^u}{2n + 1}, \quad n = 0, 1, \dots, n_{\max} \quad (10)$$

$$n_{\max} = \max \left\{ \frac{f^l}{2(f^u - f^l)} \right\} \quad (11)$$

用 $\varphi(t)$ 代替式(8)中的 sinc 函数 $\psi(t)$, 并扩大插值矩阵的范围得到新的插值矩阵 $\tilde{\mathbf{H}}_l(\boldsymbol{\tau})$, $l = -L+1, \dots, L-1$. 此时, 重写式(3)得

$$\mathbf{y}(n) = \tilde{\mathbf{H}}_0(\boldsymbol{\tau})\mathbf{a}(n) + \sum_{l=-L+1}^{L-1} \tilde{\mathbf{H}}_l(\boldsymbol{\tau})\mathbf{a}(n-l) + \sigma_\omega \boldsymbol{\omega}(n) \quad (12)$$

定义向量 $\mathbf{z}(n)$

$$\begin{aligned} \mathbf{z}(n) = & \mathbf{y}(n) - \sum_{l=-L+1}^{-1} \tilde{\mathbf{H}}_l(\boldsymbol{\tau})\mathbf{a}(n-l) \\ & - \sum_{l=1}^{L-1} \tilde{\mathbf{H}}_l(\boldsymbol{\tau})\mathbf{a}(n-l) \end{aligned} \quad (13)$$

对比式(12)得

$$\mathbf{z}(n) = \tilde{\mathbf{H}}_0(\boldsymbol{\tau})\mathbf{a}(n) + \sigma_\omega \boldsymbol{\omega}(n) \quad (14)$$

式(14)就是本文所构建的基于信号重构理论的阵列信号模型。由于该方法直接利用时延信息, 因此该模型同时适用于宽带信号和窄带信号。而且这种建模方法不受信号相关性的限制, 因此也适用于相干源。

3 估计方法

3.1 信号源数目和时延的边缘后验概率密度函数

假定噪声向量为独立的高斯随机变量, 定义连续 N 次快拍为 $\mathbf{Z} = [\tilde{\mathbf{z}}(1), \dots, \tilde{\mathbf{z}}(N)]$, 得到 N 次快拍的总似然函数为

$$l(\mathbf{Z} | \mathbf{a}(\bullet), \boldsymbol{\tau}, \sigma_\omega^2, k) = \prod_{n=1}^N \frac{1}{(2\pi\sigma_\omega^2)^{M/2}} \times \exp \left\{ \frac{-1}{2\sigma_\omega^2} (\mathbf{z}(n) - \tilde{\mathbf{H}}_0(\boldsymbol{\tau})\mathbf{a}(n))^T \times (\mathbf{z}(n) - \tilde{\mathbf{H}}_0(\boldsymbol{\tau})\mathbf{a}(n)) \right\} \quad (15)$$

其中 k 表示信号源数目的估计值, 应用贝叶斯原理得到后验概率密度函数为

$$\begin{aligned} \pi(\mathbf{a}(\bullet), \boldsymbol{\tau}, \sigma_\omega^2, k | \mathbf{Z}) \propto & p(\mathbf{Z} | \mathbf{a}(\bullet), \boldsymbol{\tau}, \sigma_\omega^2, k) \\ & \times p(\mathbf{a}(\bullet) | k, \boldsymbol{\tau}, \sigma_\omega^2) p(\boldsymbol{\tau} | k) p(\sigma_\omega^2) p(k) \end{aligned} \quad (16)$$

假定采样信号 $\mathbf{a}(n)$ 的先验分布为零均值的高斯变量, 协方差矩阵服从最大熵原则^[3]

$$p(\mathbf{a}(\bullet) | k, \boldsymbol{\tau}, \delta^2 \sigma_\omega^2) \sim N \left(0, \delta^2 \sigma_\omega^2 \left[\tilde{\mathbf{H}}_0^T(\boldsymbol{\tau}) \tilde{\mathbf{H}}_0(\boldsymbol{\tau}) \right]^{-1} \right) \quad (17)$$

选择 $\boldsymbol{\tau}$ 的先验分布为均匀分布

$$p(\boldsymbol{\tau} | k) \sim U[-T_{\max}, T_{\max}]^k \quad (18)$$

选择 σ_ω^2 的先验分布为逆-伽马分布

$$p(\sigma_\omega^2) \sim IG \left(\frac{\nu_0}{2}, \frac{\gamma_0}{2} \right) \quad (19)$$

选择 k 的先验分布为泊松分布

$$p(k) = (\Lambda/k!) \exp\{-\Lambda\} \quad (20)$$

其中 Λ 为信号源数目的期望值。由于我们要得到的是信号时延 $\boldsymbol{\tau}$ 和信号源数目 k , 信号幅度 $\mathbf{a}(n)$ 和噪声方差 σ_ω^2 不是我们感兴趣的变量, 通过积分对式(16)进行化简

$$\pi(\boldsymbol{\tau}, k | \mathbf{Z}) \propto \int_0^\infty \int_{-\infty}^\infty (\mathbf{a}, \boldsymbol{\tau}, \sigma_\omega^2, k | \mathbf{Z}) d\mathbf{a} d\sigma_\omega^2 \quad (21)$$

得到后验概率密度函数

$$\begin{aligned} \pi(\boldsymbol{\tau}, k | \mathbf{Z}) \propto & \frac{1}{(1 + \delta^2)^{Nk/2}} \left(\frac{\Lambda}{2T_{\max}} \right)^k \frac{\exp\{-\Lambda\}}{k!} \\ & \times \left(\gamma_0 + \text{tr}(\mathbf{P}_{\tilde{\mathbf{H}}_0}^\perp(\boldsymbol{\tau}) \hat{\mathbf{R}}_{zz}) \right)^{-(MN + \nu_0)/2} \end{aligned} \quad (22)$$

其中

$$\text{tr}(\mathbf{P}_{\tilde{\mathbf{H}}_0}^\perp(\boldsymbol{\tau}) \hat{\mathbf{R}}_{zz}) = \sum_{n=1}^N \mathbf{z}^T(n) \mathbf{P}_{\tilde{\mathbf{H}}_0}^\perp(\boldsymbol{\tau}) \mathbf{z}(n) \quad (23)$$

$$\mathbf{P}_{\tilde{\mathbf{H}}_0}^\perp(\boldsymbol{\tau}) = \mathbf{I} - \frac{\tilde{\mathbf{H}}_0(\boldsymbol{\tau}) \left[\tilde{\mathbf{H}}_0^T(\boldsymbol{\tau}) \tilde{\mathbf{H}}_0(\boldsymbol{\tau}) \right]^{-1} \tilde{\mathbf{H}}_0^T(\boldsymbol{\tau})}{(1 + \delta^{-2})} \quad (24)$$

3.2 混合 RJMCMC 方法

3.2.1 MCMC 方法 马尔可夫链蒙特卡罗方法 (Markov Chain Monte Carlo, MCMC)^[4] 方法以动态构造 Markov 链为基础, 是一类通过遍历性约束来实现模拟目标分布的随机模拟方法。目前应用最为广泛的 MCMC 方法主要有两种: Metropolis-Hastings(M-H)和 Gibbs.M-H 是比 Gibbs 更一般的方法, 具体实现步骤如下:

(1) 选择易于抽取样本的提议函数为 $q(\bullet)$;

(2)假设目前 Markov 链所在状态为 x , 从 $q(\cdot|x)$ 中产生一个新状态 x^* , 计算接受概率

$$\alpha(x^*, x) = \min\{\gamma(x^*, x), 1\} \quad (25)$$

其中 $\gamma(x^*, x)$ 定义为

$$\gamma(x^*, x) = \frac{\pi(x^*)q(x|x^*)}{\pi(x)q(x^*|x)} \quad (26)$$

(3)随机产生一个随机数 $u \sim U_{[0,1]}$, 如果 $u \leq \alpha(x^*, x)$, 则接受提议状态, Markov 链的状态变为 x^* , 否则拒绝提议状态, Markov 链仍然停留在状态 x 。

从理论上讲, 提议函数 $q(\cdot)$ 的选取是任意的, 但在实际计算中, 提议函数的选取对于算法效率的影响是相当大的。一般认为提议函数的形式与目标分布越接近, 则模拟的效果越好。一般的 M-H 方法, $q(x^*|x) = q(x^*)$, 提议样本 x^* 和 x 是独立的, 因此称作独立 Markov 链 M-H 方法。此时, 提议样本在整个状态空间采样, 由于产生提议样本的范围太宽导致很多状态被拒绝, 以致在没有达到收敛前往往会出现近似收敛的情况。

如果提议函数 $q(\cdot)$ 不仅满足对称性, 而且只与 $x^* - x$ 有关, 那么 M-H 方法就演变为通常意义下的随机游走采样方法。随机游走采样方法是最简单的 M-H 方法, 应用也最为广泛。此时, 提议函数 $q(x^*|x) = q(x^* - x) = q(y)$, 即提议样本 $x^* = x + y$ 。 $q(y)$ 通常选择为均匀分布或正态分布。假设 $q(y)$ 为均值为零的多维正态分布密度函数, 也就是说 $y \sim N(0, \Sigma)$ (Σ 是任意的正定矩阵)。

3.2.2 RJMCMC 方法 MCMC 方法的一个主要问题是无法保持正确的平稳分布实现从一个空间向另一个空间的跳转。为了解决这个问题, Green 于 1995 年提出了 RJMCMC 方法^[5], 该方法是 MCMC 的一个重要发展, 是一般的状态空间 M-H 方法。使用 RJMCMC 方法完成贝叶斯计算, 可以实现模型阶数和感兴趣参数的联合估计^[6]。假设参数空间为 $\cup_{k=0}^{k_{\max}} k \times \Phi_k$, 其中 Φ_k 是阶数为 k 的参数子空间, k_{\max} 为参数空间的最大维数。每次迭代, 根据不同的模型阶数, 从提议函数中产生提议样本, 接受概率和式(26)类似

$$\gamma((\tau^*, k^*), (\tau, k)) = \frac{\pi(\tau^*, k^*)q(\tau, k|\tau^*, k^*)}{\pi(\tau, k)q(\tau^*, k^*|\tau, k)} \times J((\tau^*, k^*), (\tau, k)) \quad (27)$$

$J((\tau^*, k^*), (\tau, k))$ 表示雅克比变换, 使不同维数参数空间的总概率平衡, 从而满足在不同维数空间跳转的可逆性, 本文 $J((\tau^*, k^*), (\tau, k)) = 1$ ^[3]。

RJMCMC 方法包括 3 个过程: 出生, 死亡和

更新。每个过程发生的概率分别用 b_k , d_k 和 u_k 表示, 对于所有的 k 值, $b_k + d_k + u_k = 1$, 定义如下^[5]:

$$b_k = c \min\left\{\frac{p(k+1)}{p(k)}, 1\right\}, \quad d_{k+1} = c \min\left\{\frac{p(k)}{p(k+1)}, 1\right\} \quad (28)$$

其中 $p(\cdot)$ 表示 k 维模型的先验分布, 见式(20)。 c 决定在空间跳转的速率, 一般选择 $c = 0.5$, 使得跳转概率在 0.5 到 1 之间。具体步骤描述如下:

(1)初始化: 设定 $\Phi^{(i=0)} = (\tau^{(i=0)}, k^{(i=0)})$, 其中 i 表示迭代次数, τ 表示待估计参数, k 表示模型阶数;

(2)第 i 次迭代;

(a)随机产生 $u \sim U_{[0,1]}$, 根据式(28)计算 $b_{k^{(i)}}$ 和 $d_{k^{(i)}}$, $k^{(i)}$ 是第 i 次迭代的模型阶数;

(b)if $u < b_{k^{(i)}}$, 进入出生过程: 跳转到高维空间, $k^{(i+1)} = k^{(i)} + 1$, $\tau_{k+1}^{(i+1)} = [\tau_k^{(i)}, \tau_c]$, 其中 $\tau_k^{(i)}$ 表示第 i 次迭代的时延向量, τ_c 是随机产生的一个新时延;

(c)else if $u < b_{k^{(i)}} + d_{k^{(i)}}$, 进入死亡过程: 跳转到低维空间, $k^{(i+1)} = k^{(i)} - 1$, 随机去掉第 j 个时延 τ_j^i , 得到提议时延 $\tau_{k-1}^{(i+1)} = [\tau_{1:j-1}^{(i)}, \tau_{j+1:k}^{(i)}]$;

(d)else, 进入更新过程: 空间维数不变, $k^{(i+1)} = k^{(i)}$, 产生 $k^{(i+1)}$ 个时延, 提议时延记为 $\tau_k^{(i+1)}$;

(3) $i \rightarrow i + 1$, 回到步骤(2)。

RJMCMC 方法在出生过程就相当于 M-H 方法, 但由于 RJMCMC 方法需要在多维空间跳转, 因此运算量较大, Markov 链达到收敛需要的时间比较长。

3.2.3 混合 RJMCMC 方法 在求解复杂问题时, 只用一种采样方法往往不能达到理想的估计结果, 混合 MCMC 方法作为 MCMC 方法的一个发展方向给我们提供了一个更好的解决问题的途径^[7,8]。为了提高算法估计性能和求解效率, 本文提出了一种混合 RJMCMC 方法, 即在 RJMCMC 方法的基础上, 提议样本的选取不再单一采用某一种抽样方法, 而是将独立 Markov 链 M-H 方法和随机游走采样两种方法相结合。由于转移核和采样方法的不同, 它们分别具有不同的收敛特性: 随机游走采样属于局部采样因此收敛速度相对较慢, 相反, 独立 Markov 链采样属于全空间采样因此收敛速度相对较快。结合局部采样与全空间采样的不同特性提高算法性能, 即利用独立 Markov 链采样的大范围快速收敛特性提高算法收敛速度, 利用随机游走采样小范围采样的准确性提高算法的估计精度。设 λ 为一实数, 满足 $0 < \lambda < 1$, 在没有任何先验知识的情况下, 本文选取 $\lambda = 0.5$, 混合 RJMCMC 方法的具体步骤如下:

(1)出生过程($k < k_{\max}$ 有效, $k_{\max} = M$, M 表示阵元个数): 在 $[-T_{\max}, T_{\max}]$ 范围内随机产生一个新的时延值 τ ;

(2)死亡过程($k > 0$ 有效): 从现有状态中随机去掉一个时延值 τ ;

(3)更新过程: 模型阶数保持不变, 更新时延值。

(a)采样 $u \sim U_{[0,1]}$

(b)If $u < \lambda$, 执行独立马尔科夫链采样方法, 提议函数为 $q_1(\mathbf{x}^*|\mathbf{x}^i)$, $q_1(\bullet)$ 和当前的状态相独立, 根据式(18)选择其为 k 维均匀分布;

(c)Else, 执行随机游走采样方法, 提议函数为 $q_2(\mathbf{x}^*|\mathbf{x}^i)$, 选择 $q_2(\mathbf{x}^*|\mathbf{x}^i) \sim N(\mathbf{x}^i, \Sigma)$;

由此可见, 混合 RJMCMC 方法可以使独立马尔科夫链 M-H 方法和随机游走采样这两种采样方法相互渗透, 在没有增加算法复杂度的基础上提高算法收敛速度, 避免在 Markov 链未达到收敛之前出现近似收敛的情况, 并且可以提高算法的估计性能。

4 仿真结果

实验中使用阵元个数 $M=16$ 的均匀直线阵列, 阵元间距为半波长。假设噪声为高斯白噪声, 入射信号为 3 个宽带相干信号, 入射角分别为 -15° , 5° 和 25° , 信号频率范围分别为 $[98, 128]$ MHz, $[100,$

$130]$ MHz, $[101, 129]$ MHz, 信噪比 $\text{SNR}=5$ dB, 观测序列长度即快拍数 $N=64$, 迭代次数为 $N_d = 1000$ 次。

图 1 给出了模型阶数的估计结果, 可见迭代 100 次左右时模型阶数已经达到了稳态, 得到正确的信号源数目 3。图 2 为信号时延估计随迭代次数的变化, 在迭代 300 次左右 Markov 链基本到达平稳分布。作为对比, 图 3 给出了使用独立 Markov 链采样方法时, 信号的时延估计随迭代次数的变化。可见此时需要 3500 次左右的迭代马尔科夫链才能收敛, 收敛所需时间要远远大于本文所给出的混合 MCMC 方法, 并且在 500 次迭代之后, 很长一段时间马尔科夫链没有出现跳变, 如果就此判定马尔科夫链已经达到平稳分布, 得到信号时延估计结果的误差要大于 3500 次迭代之后的估计结果, 这也是本文给出混合 MCMC 方法, 即在独立 Markov 链采样方法中引入随机游走采样方法的一个重要原因。表 1 给出了信号时延和波达方向的估计值和真实值的比较。

为了将本文方法的估计误差和理论下限 CRLB 相比, 在不同信噪比下分别做 100 次蒙特卡罗实验, 并在相同条件下对文献[3]中的方法进行仿真, 结果如图 4 所示。可见, 本文所提的混合 RJMCMC 方法在高信噪比下非常接近 CRLB, 估计精度要比文献[3]中的方法提高很多。




图 1 信号源数目估计




图 2 信号时延估计(混合 RJMCMC 方法):
(虚线表示真实值, 实线表示估计值)




图 3 信号时延估计(独立 Markov 链采样方法)
(虚线表示真实值, 实线表示估计值)

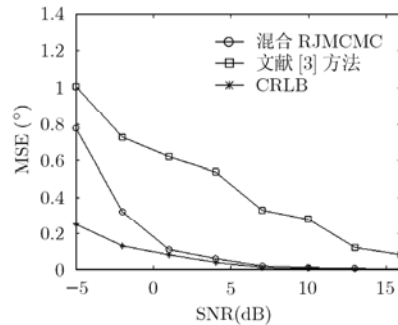


图 4 检测概率在不同快拍数随信噪比的变化

表 1 真实值和估计值的比较

参数	真实值	估计值 (混合 MCMC)	估计值 (独立 Markov 链)	相对 误差 混合 (%)	相对 误差 独立 (%)
τ_1	$-9.95e^{-10}$ s	$-9.85e^{-10}$ s	$-1.04e^{-9}$ s	1.0	4.5
τ_2	$3.35e^{-10}$ s	$3.44e^{-10}$ s	$4.02e^{-10}$ s	2.7	20.0
τ_3	$1.625e^{-9}$ s	$1.667e^{-9}$ s	$1.610e^{-9}$ s	2.6	1.0
ϕ_1	-15°	-14.8°	-15.7°	1.3	4.7
ϕ_2	5°	5.1°	6.0°	2.0	20.0
ϕ_3	25°	25.6°	24.7°	2.4	1.2

5 结束语

本文基于被动多传感器阵列, 利用信号的时延信息和带通信号重构理论通过构建插值矩阵在时域建模。从贝叶斯理论出发, 把待估计量视为随机变量, 引入待估计量的先验知识, 可求出信号源数目和时延的联合后验概率。求解时, 在 RJMCMC 方法基础上, 引入随机游走采样理论, 提出了一种混合 RJMCMC 方法, 可同时判断模型阶数和估计参数, 即实现信号源数目和波达方向联合估计。混合 RJMCMC 结合了 RJMCMC 方法和两种 M-H 采样方法的特点, 大大提高了算法的估计精度, 随着信噪比的提高估计性能逐渐接近于 CRLB, 并且在没有增加算法复杂度的基础上大大提高了求解效率。

参 考 文 献

[1] Ruanaidh J J K and Fitzgerald W J. Numerical Bayesian Methods Applied to Signal Processing [M]. New York:

Springer-Verlag, 1996: 69-95.

- [2] Huang Jian-guo, Chen Jian-feng, Liu Chun-ming, and Djuric P M. A Bayesian approach to higher resolution direction-of-arrival estimation[C]. Proceedings of the Fourth International Conference on Signal Processing, Beijing, China, October, 1998: 194-197.
- [3] Ng W and Reilly J P. Wideband array signal processing using MCMC methods [C]. *IEEE Transactions on Signal Processing*, 2005, 53(2): 411-426.
- [4] 黄有方. 带通信号的直接采样与重构[J], 信号处理, 1994, 10(1): 194-198.
Huang You-fang. Direct sampling and reconstruction of band-pass signal [J]. *Signal Processing*, 1994, 10(1): 194-198.
- [5] Green P J. Reversible jump Markov chain Monte Carlo computation and Bayesian model determination [J]. *Biometrika*, 1995, 82(4): 711-731.
- [6] Elson E C, Bassett B A, Van Der Heyden K, and Vilakazi Z Z. A new approach to the optimal target selection problem [J]. *Astronomy & Astrophysics manuscript*, 2007 50811: 1167-1175.
- [7] Laine M. Adaptive MCMC methods with applications in environmental and geophysical models [D]. [P.D. dissertation], Finnish Meteorological Institute Helsinki, 2008.
- [8] Roberts G O and Rosenthal J S. Coupling and ergodicity of adaptive MCMC. <http://probability.ca/jeff/ftpdir/adapt.pdf>, 2008. 12.

金美娜: 女, 1982 年生, 硕士生, 研究方向为阵列信号处理。

赵拥军: 男, 1964 年生, 教授, 博士生导师, 研究方向为阵列信号处理、雷达信号处理与信息处理。

盖江伟: 男, 1983 年生, 硕士生, 研究方向为阵列信号处理及高速 DSP。