

## 一种新的贝叶斯调制分类算法

柳 征 王明阳 姜文利 周一宇  
(国防科技大学电子科学与工程学院 长沙 410073)

**摘 要** 提出了一种基于马尔可夫链蒙特卡罗(MCMC)的数字调制分类方法。针对存在未知残留载波相位和频率时贝叶斯分类难以实现的问题,采用 Metropolis-Hastings(M-H)算法估计边缘似然概率密度,从而在分类性能上保持了贝叶斯分类的理论最优性和稳健性。利用对比实验验证了方法的性能。

**关键词** 马尔可夫链蒙特卡罗(MCMC), 调制分类, 贝叶斯分类器, Metropolis-Hastings (M-H) 算法, 边缘似然函数

中图分类号: TN911.3

文献标识码: A

文章编号: 1009-5896(2006)07-1233-05

## A Novel Bayesian Modulation Classification Algorithm

Liu Zheng Wang Ming-yang Jiang Wen-li Zhou Yi-yu

(School of Electronic Science & Engineering, National University of Defence Technology, Changsha 410073, China)

**Abstract** A novel method is proposed for digital modulation classification based on Markov chain Monte Carlo (MCMC). Considering the difficulty for Bayesian classifier with unknown residual carrier phase and frequency, marginal likelihood probability density is estimated by Metropolis-Hastings (M-H) algorithm, which kept the theoretical optimality and robustness of Bayesian classifier. The simulated results show that the novel classifier outperforms the one based on cumulants.

**Key words** Markov Chain Monte Carlo (MCMC), Modulation classification, Bayesian classifier, Metropolis-Hastings (M-H) algorithm, Marginal likelihood function

### 1 引言

调制分类是近年来非合作信号截获与处理的热点问题。以决策论观点看,调制分类本质上是一个二(多)元假设检验问题。对于任意幅相数字调制,文献[1]给出了理想接收条件下的平均似然比分类器(即“0-1”损失函数下的贝叶斯分类器)并证明了其渐进最优性。然而,当非合作接收信号中存在未知参数时,贝叶斯分类器因计算急剧复杂而无法实现,因此人们寻求一些低复杂度的次优算法,主要有基于贝叶斯分类器的近似实现以及基于某种变换特征的决策分类两大方向,典型方法有低信噪比条件下的准对数似然比(qLLR)<sup>[2]</sup>和 $q_M$ 算法<sup>[3]</sup>,基于瞬时幅度、频率和相位的识别算法<sup>[4]</sup>,基于高阶累积量的分类方法<sup>[5]</sup>等等。

最近,起源于统计物理学的马尔可夫链蒙特卡罗(MCMC)方法<sup>[6]</sup>引起了信号处理领域的研究热潮,并取得了多方面的成功应用。它突破了传统思维,用相对简单有效的数值方法近似求解贝叶斯估计与分类问题,保持了贝叶斯方法的理论最优性和稳健性。Metropolis-Hastings(M-H)算法<sup>[7]</sup>是在概率密度归一化常数(如后验概率中的证据因子)未知条件下的典型MCMC算法,具有适应面广的特点。本文基于

MCMC方法,研究了在加性高斯白噪声条件下,存在未知残留载波频率及相位的任意幅相数字调制分类问题。文献[8]也给出了一种基于MCMC的重要性采样估计边缘似然函数的贝叶斯分类方法,但事实上该方法存在无法确切计算重要性密度函数的缺陷,本文给出了另一种更简洁明确的基于MCMC的边缘似然函数估计方法,实现调制样式的贝叶斯分类。文章第2节简要介绍了信号模型和似然比调制分类方法,第3节提出了基于MCMC的边缘似然概率密度估计方法和贝叶斯调制分类器,第4节进行了算法的对比仿真分析。

### 2 数字调制的似然比分类

#### 2.1 信号模型

假设接收信号经过载波恢复、同步定时和码元波形恢复等处理后,得到的基带复包络采样序列形式为

$$r_n = A a_n e^{j2\pi f_0 n + j\theta_0} + w_n, \quad n = 1, \dots, N \quad (1)$$

其中 $A$ 是幅度因子, $f_0$ 是残留载波数字频率, $\theta_0$ 是残留载波相位, $N$ 是观测到的符号个数。 $w_n$ 是服从均值为零,方差为 $N_0$ 的独立同分布复高斯白噪声序列,且实部和虚部相互独立。 $\{a_n\}_{n=1}^N$ 是均匀分布在 $S_k = \{S_{k,1}, \dots, S_{k,M_k}\}$ 上的独立同分布的随机变量序列,其中 $S_k$ 代表第 $k$ 种备选数字调制的调制星座集合。文中假定所有备选调制样式的星座点已平均功率归一化,即

$$\frac{1}{M_k} \sum_{m=1}^{M_k} |S_{k,m}|^2 = 1, \quad k=1, \dots, K \quad (2)$$

在以上信号模型条件下, 调制分类问题可以定义为  $K$  元假设检验问题:

$$H_k: \quad \mathbf{r} = \mathbf{m}^{(k)} + \mathbf{w}, \quad k=1, \dots, K \quad (3)$$

其中

$$\mathbf{r} = [r_1 \ \dots \ r_N]^T$$

$$\mathbf{m}^{(k)} = [Aa_1^{(k)} e^{j2\pi f_0 1 + j\theta_0} \ \dots \ Aa_N^{(k)} e^{j2\pi f_0 N + j\theta_0}]^T$$

$$\mathbf{w} = [w_1 \ \dots \ w_N]^T$$

## 2.2 贝叶斯分类器

在“0-1”损失函数条件下, 贝叶斯分类器就是最小错误概率分类器(或最大后验概率分类器), 即选择  $K$  类备择假设中具有最大后验概率  $P(H_k | \mathbf{r})$  者为真。当所有调制样式先验等概时, 最优贝叶斯分类器简化为极大似然分类器。在理想条件下, 即信号模型中参数  $A, f_0, \theta_0, N_0$  全部已知, 观测数据在调制  $H_k$  下的似然函数为

$$p(\mathbf{r} | H_k) = \prod_{n=1}^N \frac{1}{M_k} \sum_{m=1}^{M_k} \frac{1}{\pi N_0} \exp\left(-\frac{|r_n - AS_{k,m} e^{j2\pi f_0 n + j\theta_0}|^2}{N_0}\right) \quad (4)$$

Wei<sup>[1]</sup>给出的最优分类器就是判决使得式(4)最大的调制样式为真。显然此时式(4)简单易解, 贝叶斯分类能够解析实现。

本文考虑在非合作接收中存在未知参数  $\theta = (\theta_0, f_0)$  条件下的贝叶斯调制分类问题, 这是对文献[1]理想情况下的贝叶斯分类的推广。将未知参数建模为某种先验概率分布下的随机变量, 则观测数据在调制  $H_k$  下的边缘似然函数为

$$m(\mathbf{r} | H_k) = \int p(\mathbf{r} | H_k, \theta) \pi(\theta | H_k) d\theta \quad (5)$$

其中,  $\pi(\theta | H_i)$  是未知参数  $\theta = (\theta_0, f_0)$  在调制  $H_k$  下的先验概率密度函数:

$$p(\mathbf{r} | H_k, \theta) = p(\mathbf{r} | H_k, f_0^{(k)}, \theta_0^{(k)})$$

$$= \prod_{n=1}^N \frac{1}{M_k} \sum_{m=1}^{M_k} \frac{1}{\pi N_0} \exp\left(-\frac{|r_n - AS_{k,m} e^{j2\pi f_0^{(k)} n + j\theta_0^{(k)}}|^2}{N_0}\right) \quad (6)$$

是未知参数条件下的似然函数。当所有调制样式先验等概时, 此时的最优贝叶斯分类器判决规则为使得观测数据的边缘似然概率最大的调制样式为真。然而不幸的是, 式(5)代表的边缘似然函数是很难解析实现的, 同时直接利用数值积分求解式(5)同样难以执行, 因为被积函数相当复杂而无法准确近似, 且在分布形式极不均匀。目前已有许多算法考虑在某种条件下(如信噪比)取式(5)的近似形式进行判别<sup>[2,3]</sup>, 或者考虑广义似然比分类<sup>[9]</sup>, 即不求解边缘似然函数, 而是直接以未知参数的极大似然估计值代入似然函数式(6)后判决。从统计理论而言, 贝叶斯(最大后验概率)分类利用了未知参数的全部概率信息, 而广义似然比分类未考虑未知参数的先验信息, 因此贝叶斯分类在统计意义上是最优的, 同时广义似然

比仅以未知(随机)参数在某单一取值(极大似然估计)下的似然函数进行分类判决, 易受参数取值的影响, 而贝叶斯分类将未知参数在所有可能的取值上的似然函数依先验概率加权, 因此是一种更加稳健的方法。贝叶斯分类的关键归结于式(5)求解问题, 本文采用了MCMC算法使之得以有效实现。

## 3 基于MCMC算法的边缘似然估计

### 3.1 基本原理<sup>[10]</sup>

由于估计是在各假设下独立进行, 为简洁表述, 以下推导中略去假设条件  $H_k$ 。再次考察式(5), 我们可以得到边缘似然函数的另一表达式, 称为“基本边缘似然恒等式”, 即

$$m(\mathbf{r}) = \frac{p(\mathbf{r} | \theta) \pi(\theta)}{\pi(\theta | \mathbf{r})} \quad (7)$$

其中  $\pi(\theta | \mathbf{r})$  是参数  $\theta$  的后验概率密度函数。显然式(7)对任意参数  $\theta$  成立。因此取某一合适的参数值  $\theta^*$ , 且两边取对数, 得到对数边缘似然函数为

$$\log m(\mathbf{r}) = \log p(\mathbf{r} | \theta^*) + \log \pi(\theta^*) - \log \pi(\theta^* | \mathbf{r}) \quad (8)$$

通常, 似然函数  $p(\mathbf{r} | \theta^*)$  和先验概率密度  $\pi(\theta^*)$  容易得到, 因此对边缘似然概率密度的估计归结为对后验概率  $\pi(\theta^* | \mathbf{r})$  的估计。为提高计算效率,  $\theta^*$  通常取后验概率的高密度点。

在多未知参数下, 通常将未知参数分块(block)处理, 本文中  $\theta$  分为  $(\theta_0, f_0)$  两块考虑, 则式(8)可化为

$$\log m(\mathbf{r}) = \log p(\mathbf{r} | \theta^*) + \log \pi(\theta^*)$$

$$- \log \pi(\theta_0^* | \mathbf{r}) - \log \pi(f_0^* | \mathbf{r}, \theta_0^*) \quad (9)$$

其中  $\theta^* = (\theta_0^*, f_0^*)$ 。因此若利用MCMC方法得到估计值  $\hat{\pi}(\theta_0^* | \mathbf{r}), \hat{\pi}(f_0^* | \mathbf{r}, \theta_0^*)$ , 则对数边缘似然函数估计值为

$$\log \hat{m}(\mathbf{r}) = \log p(\mathbf{r} | \theta^*) + \log \pi(\theta^*)$$

$$- \log \hat{\pi}(\theta_0^* | \mathbf{r}) - \log \hat{\pi}(f_0^* | \mathbf{r}, \theta_0^*) \quad (10)$$

### 3.2 Metropolis-Hastings(M-H)算法原理

MCMC方法近来引起了信号处理领域的极大关注, 它是一种模拟复杂概率分布的数值方法。其核心思想是产生一个以待分析概率密度函数为稳定分布的不可分的各态历经的马尔可夫链, 并以该链达到稳态的样本作为待分析分布的样本<sup>[6]</sup>。由于条件概率密度的归一化因子无法求出, 因此本文的调制分类问题采用Metropolis-Hastings(M-H)算法<sup>[10]</sup>, 并采用“随机走动”(random-walk)方法<sup>[11]</sup>生成未知参数候选值。已知后验概率密度函数  $\pi(\theta | \mathbf{r}) \propto \pi(\theta) p(\mathbf{r} | \theta)$ ,  $q(\theta, \theta')$  是候选生成(candidate-generating)概率密度, 其定义域覆盖参数  $\theta$  的全部取值区间, 代表了由参数  $\theta$  随机走动到  $\theta'$  的概率密度, 且定义  $\theta'$  被接受的概率为

$$\alpha(\theta, \theta') = \min\left\{1, \frac{p(\mathbf{r} | \theta') \pi(\theta') q(\theta', \theta)}{p(\mathbf{r} | \theta) \pi(\theta) q(\theta, \theta')}\right\} \quad (11)$$

可以证明<sup>[6]</sup>, 以转移概率  $p(\theta, \theta') = \alpha(\theta, \theta') q(\theta, \theta')$  生成的马尔可夫链, 其稳态概率就是  $\pi(\theta | \mathbf{r})$ , 并且生成的马尔可夫

链满足可逆性条件, 即对于任意参数值  $\theta^*$ , 存在

$$p(\theta, \theta^*)\pi(\theta | \mathbf{r}) = \pi(\theta^* | \mathbf{r})p(\theta^*, \theta) \quad (12)$$

式(12)两边对变量  $\theta$  在取值范围内积分, 得到  $\theta^*$  处的后验概率估计为

$$\pi(\theta^* | \mathbf{r}) = \frac{\int \alpha(\theta, \theta^*)q(\theta, \theta^*)\pi(\theta | \mathbf{r})d\theta}{\int \alpha(\theta^*, \theta)q(\theta^*, \theta)d\theta} \quad (13)$$

因此, 式(13)可进一步推导为

$$\pi(\theta^* | \mathbf{r}) = \frac{E_1[\alpha(\theta, \theta^*)q(\theta, \theta^*)]}{E_2[\alpha(\theta^*, \theta)]} \quad (14)$$

其中分子对分布  $\pi(\theta | \mathbf{r})$  取期望, 分母对分布  $q(\theta^*, \theta)$  取期望。因此得到  $\pi(\theta_0^* | \mathbf{r})$  的蒙特卡罗估计为

$$\hat{\pi}(\theta^* | \mathbf{r}) = \frac{G^{-1} \sum_{g=1}^G \alpha(\theta^{(g)}, \theta^*)q(\theta^{(g)}, \theta^*)}{J^{-1} \sum_{j=1}^J \alpha(\theta^*, \theta^{(j)})} \quad (15)$$

其中  $\{\theta^{(g)}\}_{g=1}^G$  是服从后验概率  $\pi(\theta | \mathbf{r})$  的样本,  $\{\theta^{(j)}\}_{j=1}^J$  是服从概率分布的  $q(\theta^*, \theta)$  样本。同理, 对两参数的情形且参数间相互独立, 可以得到后验概率  $\pi(\theta_1^* | \mathbf{r}, \theta_0^*)$  的蒙特卡罗估计为

$$\hat{\pi}(\theta_1^* | \mathbf{r}, \theta_0^*) = \frac{G^{-1} \sum_{g=1}^G \alpha(\theta_1^{(g)}, \theta_1^* | \theta_0^*)q(\theta_1^{(g)}, \theta_1^*)}{J^{-1} \sum_{j=1}^J \alpha(\theta_1^*, \theta_1^{(j)})} \quad (16)$$

### 3.3 基于 M-H 算法的边缘似然估计

将参数  $\theta_0, f_0$  分块考察, 即分别估计  $\hat{\pi}(\theta_0^* | \mathbf{r}), \hat{\pi}(f_0^* | \mathbf{r}, \theta_0^*)$ , 基于 M-H 算法的边缘似然估计步骤如下:

步骤 1 初始化  $\{\theta_0^{(0)}, f_0^{(0)}\}$  并利用 M-H 算法循环取样

$$\theta_0^{(g+1)} \square \pi(\theta_0 | \mathbf{r}, f_0^{(g)}), \quad f_0^{(g+1)} \square \pi(f_0 | \mathbf{r}, \theta_0^{(g+1)}) \quad (17)$$

其中在 M-H 算法中两分布的接受概率分别为

$$\alpha_\theta(\theta_0, \theta_0' | f_0) = \min \left\{ 1, \frac{p(\mathbf{r} | \theta_0', f_0)\pi(\theta_0')q_\theta(\theta_0', \theta_0)}{p(\mathbf{r} | \theta_0, f_0)\pi(\theta_0)q_\theta(\theta_0, \theta_0')} \right\} \quad (18)$$

$$\alpha_f(f_0, f_0' | \theta_0) = \min \left\{ 1, \frac{p(\mathbf{r} | f_0', \theta_0)\pi(f_0')q_f(f_0', f_0)}{p(\mathbf{r} | f_0, \theta_0)\pi(f_0)q_f(f_0, f_0')} \right\} \quad (19)$$

得到服从全条件分布密度  $\pi(\theta_0 | \mathbf{r}, f_0)$  和  $\pi(f_0 | \mathbf{r}, \theta_0)$  的样本集合  $\{\theta_0^{(g)}, f_0^{(g)}\}_{g=1}^G$ ;

步骤 2 取  $\theta_0^* = G^{-1} \sum_{g=1}^G \theta_0^{(g)}$ ;

步骤 3 提取服从概率密度  $q_\theta(\theta_0^*, \theta_0)$  和  $\pi(f_0 | \mathbf{r}, \theta_0^*)$  的样本集合  $\{\theta_0^{(j)}, f_0^{(j)}\}_{j=1}^J$ ;

步骤 4 根据步骤 1, 3 得到的采样集合, 计算后验概率:

$$\hat{\pi}(\theta_0^* | \mathbf{r}) = \frac{G^{-1} \sum_{g=1}^G \alpha_\theta(\theta_0^{(g)}, \theta_0^* | f_0^{(g)})q_\theta(\theta_0^{(g)}, \theta_0^*)}{J^{-1} \sum_{j=1}^J \alpha_f(\theta_0^*, \theta_0^{(j)} | f_0^{(j)})} \quad (20)$$

步骤 5 根据步骤 3, 取  $f_0^* = J^{-1} \sum_{j=1}^J f_0^{(j)}$ ;

步骤 6 提取服从概率密度  $q_f(f_0^*, f_0)$  的样本集合

$\{f_0^{(j)}\}_{j=1}^J$ ;

步骤 7 根据步骤 3, 6 得到的样本集合, 计算后验概率

$$\hat{\pi}(f_0^* | \mathbf{r}, \theta_0^*) = \frac{J^{-1} \sum_{j=1}^J \alpha_f(f_0^{(j)}, f_0^* | \theta_0^*)q_f(f_0^{(j)}, f_0^*)}{T^{-1} \sum_{t=1}^T \alpha_f(f_0^*, f_0^{(t)} | \theta_0^*)} \quad (21)$$

步骤 8 根据步骤 4, 7 依式(10)估计对数边缘似然函数值。

算法中似然概率依式(6)计算。值得说明的是, 在无先验知识时,  $\pi(\theta_0), \pi(f_0)$  可取无信息先验(即取值范围内的平均分布), 且当候选生成概率密度只与转移前后样本差有关并对称分布, 即有如下形式

$$q_\theta(\theta_0, \theta_0') = g_\theta(|\theta_0 - \theta_0'|), \quad q_f(f_0, f_0') = g_f(|f_0 - f_0'|) \quad (22)$$

则式(18), 式(19)可以进一步化简为

$$\begin{aligned} \alpha_\theta(\theta_0, \theta_0' | f_0) &= \min \left\{ 1, \frac{p(\mathbf{r} | \theta_0', f_0)}{p(\mathbf{r} | \theta_0, f_0)} \right\} \\ \alpha_f(f_0, f_0' | \theta_0) &= \min \left\{ 1, \frac{p(\mathbf{r} | f_0', \theta_0)}{p(\mathbf{r} | f_0, \theta_0)} \right\} \end{aligned} \quad (23)$$

有关候选生成概率密度函数的选取的详细说明可参见文献[11]。另外, 对于单未知参数和多未知参数的情形, 可以适当地减少或扩充运行步骤, 依相同原理估计边缘似然函数。在仿真分析中就分别对  $\theta_0$  和  $f_0$  单未知参数情形进行了分析。

## 4 仿真分析

本文通过仿真分析验证了基于 MCMC 的数字调制分类性能。由于马尔可夫链需要在一定取样次数后达到稳态, 实验中取过渡采样次数为  $N_b = 200$ , 稳态后的马尔可夫链取样长度为  $N = 1000$ 。

未知参数的先验概率均取无信息先验, 即对于载波相位而言,

$$\pi(\theta_0) = \begin{cases} U \left[ -\frac{\pi}{M}, \frac{\pi}{M} \right], & \text{MPSK} \\ U \left[ -\frac{\pi}{2}, \frac{\pi}{2} \right], & \text{MPAM} \\ U \left[ -\frac{\pi}{4}, \frac{\pi}{4} \right], & \text{MQAM} \end{cases} \quad (24)$$

对于残留载频先验概率而言, 假定由其引起的最大相移不超过  $\pi/2$ , 故先验概率:

$$\pi(f_0) = U \left[ -\frac{1}{4N_s}, \frac{1}{4N_s} \right] \quad (25)$$

其中  $U[·, ·]$  表示某区间上的均匀分布。候选生成概率分布函数取正态分布, 分别为

$$\begin{cases} q_\theta(\theta, \theta') = g_\theta(\theta - \theta') \square N(0, \sigma_\theta^2) \\ q_f(f, f') = g_f(f - f') \square N(0, \sigma_f^2) \end{cases} \quad (26)$$

其中  $\sigma_\theta, \sigma_f$  的选择应当根据实际的样本接受概率而定, 通常最佳选择是使得接收概率在 0.23 附近<sup>[11]</sup>。

实验 1 收敛性分析 在输入信噪比为 5dB, 符号数

$N_s = 100$  时, 以 16QAM 调制为例, 分别在  $\theta_0 = \pi/16, f_0 = 0$  和  $\theta_0 = 0, f_0 = 0.2/N_s$  条件下, 利用 M-H 算法得到的服从后验概率  $\pi(\theta_0 | r, f_0 = 0)$  和  $\pi(f_0 | r, \theta_0 = 0)$  的样本序列和直方图分别如图 1 和图 2 所示。候选生成概率分布标准差取  $\sigma_\theta = \pi/8, \sigma_f = 0.083/N_s$  以保证样本接受率在 0.23 附近,  $\theta_0$  和  $f_0$  的起始取值均为零。从图中可以看出, 马尔可夫链生成的载波相位样本序列在起始后就迅速达到了稳态, 残留载波频率样本序列在约 100 次取样后达到稳态。且从样本直方图也可以看出, 后验概率密度接近于一个在参数真值附近的单峰函数, 且参数真值接近于概率密度峰值和样点分布均值。因此也说明了 M-H 算法中步骤 2, 5 以样本均值作为后验概率高密度点的合理性。




图 1 残留载波相位的 MCMC 采样序列(a) 及其直方图 (b)  
Fig.1 The MCMC samples sequence (a) and histogram (b) of the residual carrier phase




图 2 残留载波频率的 MCMC 采样序列(a) 及其直方图 (b)  
Fig.2 The MCMC sample sequence (a) and histogram (b) of the residual carrier frequency

实验 2 比较分析 以文献[5]仿真实验中的 4 类调制 {8PSK,16QAM,4PAM,BPSK} 分类问题为例, 比较本文和基于四阶累积量的调制分类方法。文献[5]中的判决规则为

$$\left. \begin{aligned} |\hat{C}_{40}| < 0.34 & \quad 8\text{PSK} \\ 0.34 \leq |\hat{C}_{40}| < 1.02 & \quad 16\text{QAM} \\ 1.02 \leq |\hat{C}_{40}| < 1.68 & \quad 4\text{PAM} \\ |\hat{C}_{40}| \geq 1.68 & \quad \text{BPSK} \end{aligned} \right\} \quad (27)$$

其中  $C_{40} = E[x^4(n)] - 3E^2[x^2(n)]$ ,  $\hat{C}_{40}$  是四阶累积量  $C_{40}$  的估计值。

表 1 给出了在  $N_s = 100, \text{SNR} = 5\text{dB}$  条件下, 分别对应于未知参数  $f_0 = 0.2/N_s$  和  $\theta_0 \sim U(0, 2\pi)$  时, 基于累积量分类方法和 MCMC 分类方法的结果。可以看出, 基于 MCMC 的调制分类的性能明显优于累积量方法。图 3 给出了  $N_s = 100, \text{SNR} = 5\text{dB}$ , 载波相位随机分布时, 调制分类性能随未知残留载波频率的变化规律。可以看出, MCMC 调制分类方法具有相对更好的稳健性和分类有效性。




图 3 载波相位随机分布时, MCMC 方法和累积量方法分类性能随残留载波频率的变化曲线,  
Fig.3 Performanc of modulation classifiers vs. residual frequency based on HOS and MCMC, with residual carrier phase uniformly distributed

表 1 在给定条件下, 累积量方法和 MCMC 方法的调制分类性能比较

Tab.1 Confusion matrices for the modulation classifier based on HOS and MCMC with the given conditions

		$N_s = 100, \text{SNR} = 5\text{dB}, f_0 = 0.2/N_s, \theta_0 = 0$				$N_s = 100, \text{SNR} = 5\text{dB}, f_0 = 0, \theta_0 \sim U(0, 2\pi)$				
		输出		输入		输出		输入		
		16QAM	8PSK	4PAM	BPSK	16QAM	8PSK	4PAM	BPSK	
累 积 量 方 法	16QAM	64	32	3	0	16QAM	69	10	21	0
	8PSK	48	52	0	0	8PSK	51	48	1	0
	4PAM	11	0	76	13	4PAM	10	0	79	11
	BPSK	3	0	75	22	BPSK	0	0	4	96
MC 法	16QAM	83	17	0	0	16QAM	98	2	0	0
	8PSK	15	85	0	0	8PSK	3	97	0	0
	4PAM	1	2	97	0	4PAM	0	0	100	0

	BPSK	0	1	0	99	BPSK	0	0	0	100
--	------	---	---	---	----	------	---	---	---	-----

## 5 结束语

本文研究了存在未知载波相位和频率条件下的数字调制分类问题, 提出了一种基于马尔可夫链蒙特卡罗(MCMC)的分类方法, 针对贝叶斯分类极为复杂的困难, 采用Metropolis-Hastings (M-H)算法完成了在未知参数条件下的边缘似然函数的数值估计, 从而在分类性能上保持了贝叶斯分类的理论最优性和稳健性。通过对比实验验证了方法的性能。本文方法在以后研究中还可以扩展到更多参数情况, 并且对于未知参数估计问题也具有实际意义。

## 参 考 文 献

- [1] Wei W, Mendel J M. Maximum-likelihood classification for digital amplitude-phase modulation. *IEEE Trans. on Comm.*, 2000, 48(2): 189 – 193.
  - [2] Polydoros A, Kim K. On the detection and classification of quadrature digital modulations in broad-band noise. *IEEE Trans. on Comm.*, 1990, 38(8): 1199 – 1211.
  - [3] Huang C Y, Polydoros A. Likelihood methods for MPSK modulation classification. *IEEE Trans. on Comm.*, 1995, 43(2/3/4): 1493 – 1504.
  - [4] Azzouz E E, Nandi A K. Automatic identification of digital modulation types. *Signal Processing*, 1995, 47(1): 55 – 69.
  - [5] Swami A, Sadler B M. Hierarchical digital modulation classification using cumulants. *IEEE Trans. on Comm.*, 2000, 48(3): 416 – 429.
  - [6] Andrieu C, De Freitas N, Doucet A, Jordan M I. An introduction to MCMC for machine learning. *Machine Learning*, 2003, 50(1/2): 5 – 43.
  - [7] Chib S, Greenberg E. Understanding the Metropolis-Hastings algorithm. *American Statistician*, 1995, 49(4): 327 – 335.
  - [8] Lesage S, Tourneret J Y, Djuric P M. Classification of digital modulations by MCMC sampling, IEEE ICASSP, Salt Lake City, Utah, May 2001, vol.4: 2553 – 2556.
  - [9] Sills J A. Maximum-likelihood modulation classification for PSK/QAM, IEEE MILCOM, Atlantic City, NJ, Oct.31-Nov.3, 1999: 217 – 220.
  - [10] Chib S, Jeliazkov I. Marginal likelihood from the Metropolis-Hastings output. *Journal of the American Statistical Association*, 2001, 96(453): 270 – 281.
  - [11] Spall J C. Estimation via Markov chain Monte Carlo. *IEEE Control Systems Magazine*, 2003, 23(2): 34 – 45.
- 柳 征: 男, 1978年生, 博士生, 研究方向为数字调制识别, 辐射源识别等。
- 王明阳: 男, 1977年生, 博士生, 研究方向为超宽带通信及其截获技术等。
- 姜文利: 男, 1967年生, 博士, 教授, 研究方向为综合电子战技术、空间信息处理等。
- 周一宇: 男, 1948年生, 博士, 教授, 博士生导师, 研究方向为综合电子战技术、空间信息处理等。