

文章编号:1009-3087(2014)01-0114-07

基于EM算法的联合调制识别与参数估计

吴迪,葛临东,彭华

(信息工程大学 信息工程学院,河南 郑州 450002)

摘要:针对低信噪比情况下单节点接收调制识别率低的问题,提出了一种基于多节点接收与混合最大似然的调制识别算法。多节点同步接收后将基带信号发送到融合中心,使用混合最大似然实现全局分类判决,通过空间分集提高低信噪比下调制识别的性能。为了解决联合似然函数中多维未知参数难以直接求解的问题,将未知发送符号序列表示成隐藏变量后采用EM算法实现未知参数的最大似然估计。给出的算法在平坦衰落信道下实现了BPSK、QPSK、8PSK、16QAM信号的调制识别与参数估计。与基于矩的算法相比,基于EM迭代的最大似然估计提高了未知参数的估计精度。仿真实验结果表明,当采用4节点同步接收,在信噪比大于-2 dB时,平均正确识别率能够达到95%以上。

关键词:调制识别;混合最大似然;最大似然估计;EM算法

中图分类号:TN914

文献标志码:A

Joint Modulation Classification and Parameter Estimation Based on EM Algorithm

WU Di, GE Lin-dong, PENG Hua

(Communication Eng. College, Info. Eng. Univ., Zhengzhou 450002, China)

Abstract: The performance of modulation classification in single radio is sensitive to signal-to-noise ratio (SNR). A hybrid maximum likelihood (ML) modulation classification algorithm using multiple radios was proposed. All received baseband signals from different radios working on synchronous mode were fused at a fusion center to make the global classification decision by using the hybrid ML. Due to the spatial diversity, the performance of modulation classification in low SNR regimes was improved. The joint likelihood function contained multiple dimensional unknown parameters. In order to alleviate the computational complexity associated with the ML estimates of the unknown parameters, the expectation-maximization (EM) algorithm was adopted, in which the constellation symbols were represented unobserved data. The proposed algorithm completed the classification of BPSK, QPSK, 8PSK and 16QAM, as well as the unknown parameters estimation. Compared to the algorithm based on moments, the unknown parameters estimate based on EM estimation provided superior performance in precision. The simulation results showed that when the number of radios is four and SNR of signal is more than -2 dB, the average probability of correct classification is more than 95%.

Key words: modulation classification; hybrid maximum likelihood; maximum likelihood estimation; expectation maximization algorithm

通信信号调制方式自动识别是从多种信号集和背景噪声中确定发送信号的调制类型,从而为后续的进一步分析处理提供依据。在认知无线电通信系统中,自适应调制技术是其关键技术之一,它能够使认知用户根据信道环境的变化选择合适的发送参数和调制类型,从而达到信道容量最大化。而在接收

端如何快速准确地从含噪观测信号中识别调制类型是认知无线电的重要研究内容。

调制方式自动识别大致可以分为基于似然函数的决策理论方法和基于特征的模式识别方法^[1]。基于似然函数的决策理论方法根据不同假设下的似然函数值使用贝叶斯分类判决准则进行分类,其结果在贝叶斯估计意义下是最优的。由于发送信号经过信道后存在多个未知参数,根据对未知参数的不同处理,基于似然函数的调制识别大致分为平均似然比检测(ALRT)、广义似然比检测(GLRT)以及混合似然比检测(HLRT)^[2-4]。其中,混合似然比检测将未知发送符号看成是等概分布的随机变量,而

收稿日期:2013-06-08

基金项目:国家自然科学基金资助项目(61072046);河南省基础与前沿研究计划资助项目(102300410008; 132300410049)

作者简介:吴迪(1984—),男,博士生。研究方向:通信信号处理。E-mail:wudipaper@sina.com

用估计值代替未知参数,与其他似然比检测相比具有更低的计算复杂度和更广泛的适用性。

目前,大部分的调制识别研究都是基于单节点接收的识别方法,受信道衰落、低信噪比等因素的影响识别性能受到限制。尤其在非合作接收环境中,单节点接收信号往往信噪比较低,正确识别概率难以得到保证。随着传感器网络的广泛应用,基于多节点接收的分布式调制识别受到越来越多的重视^[5-13]。与单节点接收相比,多节点接收能够利用空间分集获得更高的接收信噪比,减轻信道衰落的影响。基于似然比检测的分布式调制识别大部分都是基于分布式判决理论的方法,这类算法在每个节点上利用似然比检测做出局部判决,然后将局部判决结果发送到融合中心后进行全局判决^[5-7],与基于特征的分布式调制识别^[8-9]相比具有更高的识别率。文献[10-13]采用空间分集的方法将多传感器或多天线观测数据集中后再使用最大似然分类器进行全局分类判决,这类算法能够适用于多信号集下的识别,与判决融合相比具有更好的识别性能。

另一方面,接收信号往往存在多个未知参数,如频率偏差、相位偏差等,对未知参数的估计精度直接影响到混合似然比检测算法的识别性能。文献[13]采用基于矩的非数据辅助方法估计信号幅度和噪声功率。文献[14]采用非线性最小二乘估计方法估计未知载波频率偏差,完成有频偏下的混合似然比检测。这些方法都是基于非数据辅助的方法,估计精度受限。最大似然估计方法具有更高的估计精度,但需要已知发送符号序列,而且在多节点接收系统中,基于数据融合的联合似然函数复杂度高,对其未知参数的最大似然估计难以直接表示。因此,需要采用未知调制类型的高精度低复杂度参数估计方法。文献[15]在单节点接收系统中,将平坦衰落信道建模成混合高斯噪声模型,使用期望-最大化(expectation-maximization, EM)算法估计未知信道状态和噪声分布参数,然后通过混合似然比检测完成调制识别,但单节点接收识别性能受限。

为了进一步提高调制识别的性能,作者针对幅相调制信号的识别问题,采用多节点同步接收实现空间分集,并在融合中心使用混合最大似然进行全局分类判决,克服了低信噪比下单节点接收识别率低的问题。然而,在多节点同步接收系统中,由于联合似然函数存在未知发送符号序列且多维未知参数相互关联,使得未知参数的最大似然估计难以直接求解。为了降低计算复杂度并提高未知参数估计精

度,将发送符号表示成隐藏变量后使用EM算法实现了未知发送符号序列下的最大似然估计,同时,多维未知参数的最大似然估计也转化成了多个低维的最大似然估计。

1 多传感器信号模型

位于空间不同位置的 L 个传感器同时、独立地接收相同的信号。假设不同传感器之间的距离足够远使其接收信号经历了相互独立的衰落信道。传感器 l 接收到的匹配滤波器输出基带信号为:

$$\mathbf{r}_l = a_l e^{j\theta_l} \mathbf{s}^{(i)} + \mathbf{w}_l \quad (1)$$

式中: $\mathbf{r}_l = [r_{l,1}, \dots, r_{l,N}]^T$ 表示第 l 个匹配滤波器输出信号向量,其中, N 为待处理的基带符号个数,符号 T 表示转置; $\mathbf{s}^{(i)} = [s_1^{(i)}, \dots, s_N^{(i)}]^T$ 表示对应于第 i 种调制的发送符号序列,假设存在 K 种可能的调制类型,则 $i \in \{1, \dots, K\}$; $\mathbf{w}_l = [w_{l,1}, \dots, w_{l,N}]^T$ 表示第 l 个传感器接收端的加性复高斯白噪声向量,服从均值为零、方差为 $2\sigma_l^2$ 的高斯分布,且假设不同传感器的噪声相互独立; a_l 和 θ_l 分别表示第 l 个传感器接收信号受信道衰落影响的幅度因子和相位因子。不同节点将接收的基带信号发送到融合中心后采用似然比检测方法对接收信号做出全局判决。在基于融合中心的网络结构中,假设网络中的所有节点工作在同步模式,即在同一时刻每个节点的接收信号来自于同一发送符号。在多传感器信号模型中, $\mathbf{a} = [a_1, \dots, a_L]^T$, $\boldsymbol{\theta} = [\theta_1, \dots, \theta_L]^T$, $\boldsymbol{\sigma} = [\sigma_1^2, \dots, \sigma_L^2]^T$ 都为未知的信号参数向量,所有未知参数向量可以表示为 $\boldsymbol{\Theta} = [\mathbf{a}, \boldsymbol{\theta}, \boldsymbol{\sigma}]^T$ 。在未知信号调制类型的条件下,融合中心需要利用接收的 $L \times N$ 个样本符号从 K 种等概率的已知信号星座中确定发送信号的调制类型,并估计未知参数向量 $\boldsymbol{\Theta}$ 。

2 基于最大似然的调制识别与参数估计

2.1 基于混合最大似然的调制识别

基于最大似然的调制识别通过比较不同假设下的接收信号似然函数或对数似然函数大小,确定发送信号的调制类型。由于噪声为高斯白噪声,则在 H_i 假设下第 l 个传感器接收信号在 k 时刻的条件概率密度函数为:

$$p_i(r_{l,n} | s_n^{(i)}, \boldsymbol{\Theta}_l) = \frac{1}{2\pi\sigma_l^2} \exp\left(-\frac{1}{2\sigma_l^2} |r_{l,n} - a_l e^{j\theta_l} s_n^{(i)}|^2\right) \quad (2)$$

式中, $\boldsymbol{\Theta}_l = [a_l, \theta_l, \sigma_l]^T$ 为第 l 个传感器上的未知参数向量, $s_n^{(i)}$ 为 n 时刻取自第 i 种假设下的未知发送

符号。在 n 时刻融合中心接收各传感器的信号组成接收信号向量 $\mathbf{r}_n = [r_{1,n}, \dots, r_{L,n}]^T$ 。由于 L 个传感器工作在同步模式,因此接收信号向量 \mathbf{r}_n 来自于同一发送符号。不同传感器信号相互独立, \mathbf{r}_n 的联合条件概率密度函数可以表示为:

$$p_i(\mathbf{r}_n | s_n^{(i)}, \boldsymbol{\theta}) = \prod_{l=1}^L p_i(r_{l,n} | s_n^{(i)}, \boldsymbol{\theta}_l) \quad (3)$$

根据对未知参数处理方法的不同,基于似然函数的调制识别有多种近似算法,其中,HLRT 算法将未知参数视为确定的常量,将未知发送符号视为概率密度已知的随机变量。因此,通过对未知发送符号求平均后得到只含有未知参数的条件概率密度函数,即:

$$p_i(\mathbf{r}_n | \boldsymbol{\theta}) = \frac{1}{M_i} \sum_{m=1}^{M_i} p_i(\mathbf{r}_n | s_{n,m}^{(i)}, \boldsymbol{\theta}) = \frac{1}{M_i} \sum_{m=1}^{M_i} \prod_{l=1}^L p_i(r_{l,n} | s_{n,m}^{(i)}, \boldsymbol{\theta}_l) \quad (4)$$

式中, M_i 表示第 i 种调制信号的星座符号点数, $s_{n,m}^{(i)}$ ($m = 1, \dots, M_i$) 表示在 n 时刻取自星座 i 的第 m 个符号。在未知发送符号的条件下,一般假设每个星座点具有相同的先验概率,即 $p(s_{n,m}^{(i)} | H_i) = 1/M_i$ 。用 $\mathbf{r} = [\mathbf{r}_1, \dots, \mathbf{r}_N]^T$ 表示所有观测信号向量,则联合条件概率密度函数为:

$$p_i(\mathbf{r} | \boldsymbol{\theta}) = \prod_{n=1}^N p_i(\mathbf{r}_n | \boldsymbol{\theta}) \quad (5)$$

式(5)表示成对数形式,并去除无关项后得到如下的对数似然函数:

$$\Lambda_i(\boldsymbol{\theta}) = \sum_{n=1}^N \ln \left[\sum_{m=1}^{M_i} \frac{\exp(-\sum_{l=1}^L (2\sigma_l^2)^{-1} |r_{l,n} - a_l e^{j\theta_l} s_n^{(i)}|^2)}{\prod_{l=1}^L \sigma_l^2} \right] - K \ln M_i \quad (6)$$

选择使对数似然函数最大的调制方式作为最终的判决结果:

$$\hat{i} = \arg \max_i \Lambda_i(\hat{\boldsymbol{\theta}}_i), i \in \{1, \dots, K\} \quad (7)$$

其中,

$$\hat{\boldsymbol{\theta}}_i = \arg \max_{\boldsymbol{\theta}} \Lambda_i(\boldsymbol{\theta}) \quad (8)$$

表示在第 i 种调制下得到的未知参数向量。将式(7)的分类判决方法称为最大似然分类。

式(6)中的对数似然函数包含 $3L$ 个未知参数,求解似然函数的全局最大值是一个多维非凸优化问题。在未知发送符号序列的情况下,式(6)中 L 个传感器的未知参数相互关联,无法直接分解成多个低维的优

化问题。为了求解似然函数全局最大,HLRT 算法采用遍历所有星座符号的方法,这造成了 HLRT 算法复杂度太高。为了降低复杂度,QLHRT(Quasi-HLRT)算法采用非数据辅助方法估计未知参数,然后将估计结果代入似然函数中,通过比较似然函数的大小进行调制识别。文献[13]利用 MoM(method of moment)估计器完成对 $\boldsymbol{\theta}_i$ 的估计。对于第 i 种调制,信号幅度和噪声方差的估计为^[13]:

$$\hat{a}_l^{(i)} = \left(\frac{\hat{M}_{42,l} - 2\hat{M}_{21,l}^2}{b^{(i)} - 2} \right)^{1/4} (E[s_m^{(i)}])^{-1/2} \quad (9)$$

$$\hat{a}_l^{2,(i)} = \frac{1}{2} \left(\hat{M}_{21,l} - \left(\frac{\hat{M}_{42,l} - \hat{M}_{21,l}^2}{b^{(i)} - 2} \right)^{1/2} \right) \quad (10)$$

式中: $b^{(i)} = E[|s_m^{(i)}|^4] / (E[|s_m^{(i)}|^2])^2$, $m = 1, \dots, M_i$; \hat{M}_{21} 和 \hat{M}_{42} 分别为接收信号的 2 阶和 4 阶矩的估计值,即 $\hat{M}_{21,l} = N^{-1} \sum_{n=1}^N |r_{l,n}|^2$, $\hat{M}_{42,l} = N^{-1} \sum_{n=1}^N |r_{l,n}|^4$ 。对 MPSK 和 MQAM 信号的相位偏差估计采用非数据辅助方法估计^[16]:

$$\hat{\theta}_l^{(i)} = \begin{cases} M_i^{-1} \arg \left(\sum_{n=1}^N r_{l,n}^{M_i} \right), & \text{MPSK;} \\ \frac{1}{4} \arg \left(\sum_{n=1}^N r_{l,n}^4 \right), & \text{MQAM} \end{cases} \quad (11)$$

将上述结果代入式(6)得到基于 MoM 的混合最大似然(HML-MoM)算法。由于 MoM 估计器采用统计方法得到未知参数的估计值,这种非数据辅助方法不是最优的,未知参数的估计精度受信噪比、数据长度等因素的影响较大,从而影响了调制识别的性能。同时,在多节点接收系统中,不同节点的未知参数相互关联,不同节点的估计误差混合后将进一步恶化 HML-MoM 算法的识别性能。

2.2 基于 EM 的混合最大似然算法

在基于似然函数的调制识别中,为了提高调制识别性能,首先需要提高未知参数的估计精度。基于最大似然的未知参数估计方法具有最优的估计性能。当发送符号序列已知时,求解式(6)中的未知参数,得到最大似然估计闭式表达式如下^[2]:

$$\hat{\theta}_l = \arg \left(\sum_{n=1}^N s_n^* r_{l,n} \right) \quad (12)$$

$$\hat{a}_l = \frac{\operatorname{Re} \left(\sum_{n=1}^N e^{-j\hat{\theta}_l} s_n^* r_{l,n} \right)}{\sum_{n=1}^N |s_n|^2} \quad (13)$$

$$\hat{\sigma}_l^2 = \frac{1}{2N} \sum_{n=1}^N |r_{l,n} - \hat{a}_l e^{j\hat{\theta}_l} s_n|^2 \quad (14)$$

式中, $\text{Re}(\cdot)$ 表示复信号的实部, 符号 $*$ 表示取共轭。由此可以看出, 当发送符号序列已知时, 未知参数的最大似然估计分解成了 L 个传感器参数的独立求解。因此, 考虑将发送符号序列作为隐藏变量, 采用 EM 算法求解最大似然估计问题。

EM 算法是一种最大似然估计的数值迭代算法, 通过联合使用观测数据和隐藏变量简化最大似然估计问题。算法的基本思想是: 在观测到的不完整数据 x 的基础上, 加入隐藏变量 y 形成“完整数据” z , 待估参数在不完整观测数据 x 下的后验概率变成在完整数据 $z = (x, y)$ 下的后验概率, 求解并得到最大似然估计值。EM 算法的求解过程包含 2 个步骤: 第 1 步是求期望 (E-Step), 对完全数据下的似然函数求条件期望; 第 2 步是求最大化 (M-Step), 最大化条件期望获得未知参数的估计值^[17-18]。

将发送符号序列表示成不可观测的隐藏变量, 定义完整数据为 $z = [r^T, s^T]$ 。通过以下 2 个步骤进行迭代求解:

1) E-step: 在第 $t-1$ 次迭代估值的基础上计算条件期望函数, 消除不可观测的隐藏变量。

$$Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) = E_s \{ \ln p_i(z | \hat{\Theta}_i^{(t)}) | r, \hat{\Theta}_i^{(t-1)} \} \quad (15)$$

式中, $\hat{\Theta}_i^{(t)}$ 和 $\hat{\Theta}_i^{(t-1)}$ 分别为第 i 种调制下第 t 和 $t-1$ 次迭代获得的参数估计值, $E_s \{ \cdot \}$ 表示对隐藏变量取期望。由于发送符号序列与未知参数相互独立, 因此完整数据 z 的对数似然函数为:

$$\ln p_i(z | \hat{\Theta}_i^{(t)}) = \ln p_i(r | s, \hat{\Theta}_i^{(t)}) + \ln p_i(s) \quad (16)$$

其中,

$$\ln p_i(r | s, \hat{\Theta}_i^{(t)}) = \sum_{n=1}^N \ln(p_i(r_n | s_n, \hat{\Theta}_i^{(t)})) \quad (17)$$

将式(16)代入式(15)得到:

$$Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) = E_s \{ \ln p_i(r | s, \hat{\Theta}_i^{(t)}) | r, \hat{\Theta}_i^{(t-1)} \} + E_s \{ \ln p_i(s) | r, \hat{\Theta}_i^{(t-1)} \} \quad (18)$$

式(18)中, 等号右边第 2 项与 $\hat{\Theta}_i^{(t)}$ 无关, 不影响其最大值的求解, 可以将其省略。对 s 求期望展开, 并将式(17)代入, 得到条件期望函数 Q 的表达式为:

$$Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) = \sum_{n=1}^N \sum_{m=1}^{M_i} \ln(p_i(r_n | s_{n,m}^{(i)}, \hat{\Theta}_i^{(t)})) b_{n,m}^{(t)} \quad (19)$$

其中,

$$b_{n,m}^{(t)} = P_i(s_{n,m}^{(i)} | r_n, \hat{\Theta}_i^{(t-1)}) \quad (20)$$

表示 n 时刻发送符号 $s_{n,m}^{(i)}$ 在给定接收信号 r_n 和第 $t-1$ 次迭代得到的估计 $\hat{\Theta}_i^{(t-1)}$ 条件下的边缘后验概率密度。利用贝叶斯准则和全概率公式, 可以得到:

$$b_{n,m}^{(t)} = P_i(s_{n,m}^{(i)} | r_n, \hat{\Theta}_i^{(t-1)}) = \frac{p_i(r_n | s_{n,m}^{(i)}, \hat{\Theta}_i^{(t-1)})}{\sum_{m=1}^{M_i} p_i(r_n | s_{n,m}^{(i)}, \hat{\Theta}_i^{(t-1)})} \quad (21)$$

定义 $\mu_n^{(t)}$ 和 $\eta_n^{(t)}$ 分别为发送符号的后验均值和后验均方值, 其表达式分别为:

$$\mu_n^{(t)} = \sum_{m=1}^{M_i} b_{n,m}^{(t)} s_{n,m}^{(i)} \quad (22)$$

$$\eta_n^{(t)} = \sum_{m=1}^{M_i} |s_{n,m}^{(i)}|^2 b_{n,m}^{(t)} \quad (23)$$

式(19)中的条件概率密度函数可由式(2)、(3)得到:

$$p_i(r_n | s_{n,m}^{(i)}, \hat{\Theta}_i^{(t)}) = \prod_{l=1}^L \frac{1}{2\pi\hat{\sigma}_l^{2,(t)}} \exp[-(2\hat{\sigma}_l^{2,(t)})^{-1} |r_{l,n} - \hat{a}_l e^{j\phi_l^{(t)}} s_{n,m}^{(i)}|] \quad (24)$$

将式(24)代入式(19)中, 展开后得到 Q 函数如下:

$$Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) = -N \sum_{l=1}^L \ln(2\pi\hat{\sigma}_l^{2,(t)}) - \sum_{l=1}^L \frac{1}{2\hat{\sigma}_l^{2,(t)}} \left\{ \sum_{n=1}^N |r_{l,n}|^2 + \hat{\sigma}_l^{2,(t)} \sum_{n=1}^N \sum_{m=1}^{M_i} |s_{n,m}^{(i)}|^2 b_{n,m}^{(t)} - 2\hat{\sigma}_l \text{Re} \left[\sum_{n=1}^N r_{l,n} e^{-j\phi_l^{(t)}} \sum_{m=1}^{M_i} s_{n,m}^{*(i)} b_{n,m}^{(t)} \right] \right\} \quad (25)$$

然后将式(22)、(23)代入式(25)中, 经化简后进一步得到 Q 函数如下:

$$Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) = -N \sum_{l=1}^L \ln(2\pi\hat{\sigma}_l^{2,(t)}) - \sum_{l=1}^L \frac{N}{2\hat{\sigma}_l^{2,(t)}} (A_{2,l} + \hat{a}_l^{2,(t)} B^{(t)} - 2\hat{a}_l^{(t)} C_l^{(t)}) \quad (26)$$

其中:

$$A_{2,l} = \frac{1}{N} \sum_{n=1}^N |r_{l,n}|^2 \quad (27)$$

$$B^{(t)} = \frac{1}{N} \sum_{n=1}^N \eta_n^{(t)} \quad (28)$$

$$C_l^{(t)} = \frac{1}{N} \sum_{n=1}^N \text{Re} [r_{l,n} e^{-j\hat{\theta}_l^{(t)}} \mu_n^{(t)*}] \quad (29)$$

2) M-step: 最大化条件期望函数, 确定第 t 次迭代的最大似然估计值 $\hat{\Theta}_i^{(t)}$ 。

$$\hat{\Theta}_i^{(t)} = \arg \max_{\hat{\Theta}_i^{(t)}} Q(\hat{\Theta}_i^{(t)} | \hat{\Theta}_i^{(t-1)}) \quad (30)$$

从式(26)可以看出,此时的 Q 函数含有多个未知参数,同时更新所有的未知参数较为困难,一般采用简化的条件最大化算法,即将 Q 函数看作某一参数的函数,而将其他参数用当前估计值固定。对 Q 函数求导获得 t 次迭代的最大似然估计值,则未知参数的估计值表示为:

$$\hat{a}_l^{(t)} = \frac{C_l^{(t)}}{B^{(t)}} \quad (31)$$

$$\hat{\sigma}_l^{2,(t)} = \frac{1}{2}(A_{2,l} - C_l^{2,(t)}/B^{(t)}) \quad (32)$$

$$\hat{\theta}_l^{(t)} = \arg\left(\sum_{n=1}^N \mu_n^{(t)*} r_{l,n}\right) \quad (33)$$

式(33)中,相偏估计可以看成是数据辅助的最大似然估计,即用星座符号的后验均值 $\mu_n^{(t)}$ 去除 $r_{l,n}$ 的调制信息。通过E-step和M-step的不断迭代直到算法收敛到平稳点,设迭代终止条件为 $|Q^{(t)} - Q^{(t-1)}| < \delta$,其中, δ 为迭代终止门限。将收敛后的估计参数代入式(6),得到当前假设下的对数似然函数值。比较不同调制方式假设下的对数似然函数值大小,从而完成调制识别。

上述EM算法在每次迭代过程中利用当前接收信号和上次未知参数估计结果获得了发送符号的后验均值和后验均方值,然后将该后验均值作为发送符号序列的估计值,从而使得未知参数的最大似然估计能够分解成 L 个传感器参数的独立求解。同时,当前未知参数的估计结果又作为下一次迭代的已知条件,当调制假设正确时,通过多次迭代能够不断提高发送符号后验概率的准确性,从而使得未知参数的估计逐步接近已知发送符号时的最大似然估计。随着未知参数估计精度的提高,对数似然函数值也将逐步增大。

2.3 算法初始化

由于EM算法只能保证算法收敛到局部最小点,当似然函数中含有多个局部最小点时,EM算法容易造成错误收敛,因此需要对EM算法进行适当初始化^[19]。在初始时刻,选取相位偏差初始值为 $\hat{\theta}_l^{(0)} = 0$,选取边缘后验概率密度为 $b_{n,m}^{(0)} = \frac{1}{M_i}$,即初始时刻认为发送符号先验等概。将 $\hat{\theta}_l^{(0)}$ 、 $b_{n,m}^{(0)}$ 代入式(31)、(32)中,得到信号幅度初值和噪声方差初值:

$$\hat{a}_l^{(0)} = \frac{\sum_{n=1}^N \sum_{m=1}^{M_i} \operatorname{Re}[r_{l,n} s_{n,m}^{*(i)}]}{\sum_{n=1}^N \sum_{m=1}^{M_i} |s_{n,m}^{(i)}|^2} \quad (34)$$

$$\hat{\sigma}_l^{2,(0)} = \frac{1}{2N} \left(\sum_{n=1}^N |r_{l,n}|^2 - \frac{\left(\sum_{n=1}^N \sum_{m=1}^{M_i} \operatorname{Re}[r_{l,n} s_{n,m}^{*(i)}] b_{n,m}^{(0)} \right)^2}{\sum_{n=1}^N \sum_{m=1}^{M_i} |s_{n,m}^{(i)}|^2 b_{n,m}^{(0)}} \right) \quad (35)$$

将 $\hat{\theta}_l^{(0)}$ 、 $\hat{a}_l^{(0)}$ 、 $\hat{\sigma}_l^{2,(0)}$ 作为EM算法的初始值。

3 仿真实验

通过仿真实验验证算法的有效性。待分类的信号集合为{BPSK, QPSK, 8PSK, 16QAM}。每个传感器接收信号经过相互独立的平坦衰落信道,信道幅度服从瑞利分布,平均衰落功率为 $E[a^2] = 1$,信道相位在 $(0, 2\pi]$ 范围内服从均匀分布。仿真中使用归一化星座符号,即 $E[s^2] = 1$,通过改变噪声功率来改变信噪比。EM算法的迭代终止门限为 10^{-4} 。为了评估算法的性能,将提出的基于EM的混合最大似然算法(HML-EM)、HML-MoM算法以及所有参数已知的理想条件ALRT算法(ALRT-UB)^[3]进行比较。

实验1:为了验证基于EM算法的混合似然比检测的迭代收敛性能,仿真其迭代过程。以单节点接收下的QPSK和8PSK信号为例,取符号个数 $N = 200$,在信噪比为10 dB下计算提出的算法每次迭代得到的对数似然函数值,并与ALRT-UB算法比较。设值未知参数为 $a_1 = 1, \sigma_1^2 = 0.05, \theta_1 = \pi/16$ 。实验结果如图1所示。

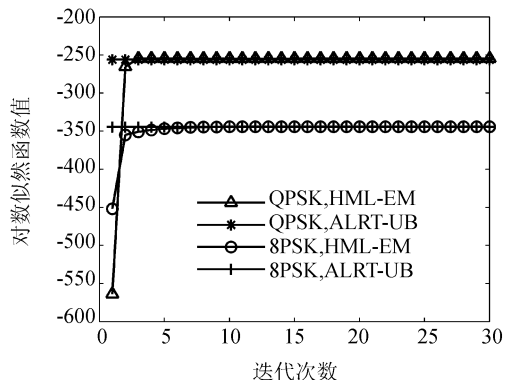


图1 HML-EM算法迭代过程

Fig. 1 Iteration of the HML-EM algorithm

从图1中可以看出,随着迭代次数的增加,2种调制方式下的对数似然函数值收敛到平衡点,并逐步接近于ALRT-UB算法的对数似然函数值。这是由于随着EM算法的迭代计算,未知参数的估计值逐步收敛到最大似然解,从而使得对数似然函数值能够接近ALRT-UB算法。

实验 2: 基于 EM 的混合最大似然对未知参数进行迭代求解, 其估计精度将直接影响到算法的分类性能。比较 HML-EM 算法与 HML-MoM 算法对未知参数的估计性能, 算法估计精度采用均方误差衡量, 以相位偏差估计精度为例, 均方误差表示为 $MSE = E[|\hat{\theta} - \theta|^2]$ 。图 2 和 3 分别给出了在 $L = 2$, $N = 200$ 条件下, 16QAM 信号的相位偏差和噪声方差在不同信噪比下的估计均方误差。从图中可以看出, 随着信噪比的增加, 未知参数的均方误差逐渐减小, 且 HML-EM 算法的参数估计与 HML-MoM 算法相比具有更低的均方误差估计性能。

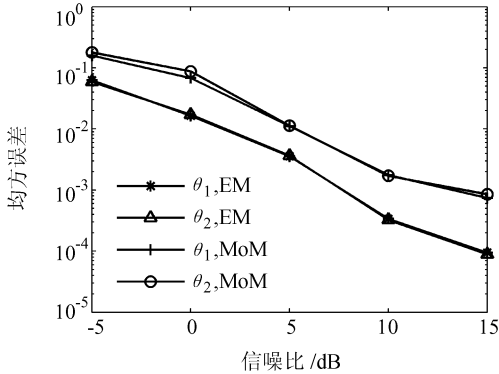


图 2 相位偏差的估计性能 ($N = 200$)

Fig. 2 Estimation performance of signal phase ($N = 200$)




图 3 噪声方差的估计性能 ($N = 200$)

Fig. 3 Estimation performance of noise variance ($N = 200$)

基于 EM 的混合最大似然的参数估计精度与符号个数的有关。图 4 比较了相同信道条件下符号个数分别为 100、200、400 时 16QAM 信号幅度的估计性能。从图 4 中可以看出, 在相同信噪比下, 符号个数越多, 算法的估计精度越高。

实验 3: 在瑞利平坦衰落信道下, 仿真比较 HML-EM、HML-MoM、ALRT-UB 3 种算法的平均正确识别率。平均正确识别率定义为 $P_{cc} = K^{-1} \sum_{i=1}^K P_c^{(i)}$, 其中, $P_c^{(i)}$ 表示第 i 种调制信号的正确




图 4 不同符号个数下信号幅度的估计性能

Fig. 4 Estimation performance of signal amplitude with different number of symbols

识别概率, K 为调制信号种类。对每个信号样本, 计算 4 种假设下的对数似然函数值, 选择使似然函数最大的调制假设作为判决结果。仿真中取符号个数 $N = 200$, 接收节点个数 L 分别取 1、2、4, 仿真结果如图 5 所示。从图 5 中可以看出, 在单接收节点条件下, HML-EM 算法与 HML-MoM 算法的平均正确识别率相近, 且都低于 ALRT-UB 算法的平均正确识别率。节点个数越多, HML-EM 算法的平均正确识别率越高, 且逐步接近于 ALRT-UB 算法, 当采用 4 节点同步接收, 在信噪比大于 -2 dB 时, 平均正确识别率能够达到 95% 以上。而 HML-MoM 算法在多节点同步接收条件下识别率反而降低。由此说明, 在多节点接收条件下, 基于 EM 算法的混合似然比检测能够获得空间分集增益, 提高了调制识别的性能, 而基于 MoM 的估计算法对未知参数的估计不是最优的, 不同节点上的估计偏差扩大了对联合似然函数估计的影响, 从而恶化了调制识别的性能。




图 5 不同节点个数下的平均正确识别率

Fig. 5 Average probability of correct classification with different number of sensors

图 6 在接收节点个数 $L = 2$ 的条件下比较了符号个数分别为 100、200、400 时 HML-EM 算法的平

均正确识别率。从图 6 中可以看出,在相同信噪比下,符号个数越多,平均正确识别率越高。




图 6 不同符号个数下的平均正确识别率

Fig. 6 Average probability of correct classification with different number of symbols

4 结 论

作者针对低信噪比条件下的联合调制识别与参数估计问题进行了研究。算法通过多节点同步接收获得空间分集增益,利用混合最大似然实现幅相调制信号的调制识别。为了提高联合似然函数中的未知参数估计,作者提出采用 EM 算法实现多维未知参数的最大似然估计。仿真结果表明,与基于矩的算法相比,提出的算法对未知参数具有更低的均方误差估计性能,并且与单节点调制识别相比,通过多节点接收在较低的信噪比下仍然具有较高的正确识别率,具有较好的实用价值。该算法适用于平坦衰落信道下的调制识别与参数估计,下一步将针对更复杂的信道模型,如多径信道、非高斯信道条件下的调制识别进行研究。

参考文献:

[1] Dobre O A, Abdi A, Bar-Ness Y, et al. Survey of automatic modulation classification techniques; classical approaches and new trends[J]. IET Communications, 2007, 1(2): 137 - 156.

[2] Dobre O A, Hameed F. Likelihood-based algorithms for linear digital modulation classification in fading channels[C]. IEEE Canadian Conference on Electrical and Computer Engineering (CCECE'06), Ottawa, 2006: 1347 - 1350.

[3] Hameed F, Dobre O A, Popescu D C. On the likelihood-based approach to modulation classification[J]. IEEE Transactions on Wireless Communication, 2009, 8(12): 5884 - 5892.

[4] Xu J L, Su W, Zhou M. Likelihood-ratio approaches to automatic modulation classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2011, 41(4): 455 - 469.

[5] Su W, Kosinski J. Framework of network centric signal sensing for automatic modulation classification[C]. 2010 IEEE

International Conference on Networking, Sensing and Control (ICNSC), Chicago, IL, 2010: 534 - 539.

- [6] Xu J L, Su W, Zhou M. Distributed automatic modulation classification with multiple sensors[J]. IEEE Sensors Journal, 2010, 10(11): 1779 - 1785.
- [7] Zhang Y, Ansari N, Su W. Optimal decision fusion based automatic modulation classification by using wireless sensor networks in multipath fading channel[C]. Global Telecommunications Conference (GLOBECOM 2011), Houston, 2011: 1 - 5.
- [8] Forero P A, Cano A, Giannakis G B. Distributed feature-based modulation classification using wireless sensor networks[C]. IEEE Military Communications Conference, San Diego, 2008: 1 - 7.
- [9] Liu Aisheng, Zhu Qi. Distributed cooperative modulation recognition with multiple sensors[J]. Signal Processing, 2011, 27(8): 1235 - 1241. [刘爱声, 朱琦. 多传感器节点分布式协作调制识别算法[J]. 信号处理, 2011, 27(8): 1235 - 1241.]
- [10] Xu J L, Su W, Zhou M. Asynchronous and high-accuracy digital modulated signal detection by sensor networks[C]. IEEE Military Communications Conference, Baltimore, 2011: 589 - 594.
- [11] Ramezani-Kebrya A. likelihood-based modulation classification for multiple-antenna receivers[J]. IEEE Transactions on Communications, 2013, 61(9): 3816 - 3829.
- [12] He Tao, Zhou Zhengou. Modulation classification using spatial diversity[J]. Journal of Electronics & Information Technology, 2008, 30(4): 872 - 875. [贺涛, 周正欧. 使用分集技术的信号调制类型识别[J]. 电子与信息学报, 2008, 30(4): 872 - 875.]
- [13] Abdi A, Dobre O A, Choudhry R, et al. Modulation classification in fading channels using antenna arrays[C]. IEEE Military Communications Conference, 2004, 1: 211 - 217.
- [14] Li H, Dobre O A, Bar-Ness Y, et al. Quasi-hybrid likelihood modulation classification with nonlinear carrier frequency offsets estimation using antenna arrays[C]. IEEE Military Communications Conference, Atlantic City, NJ, 2005: 570 - 575.
- [15] Chavali V G, da Silva C R C M. Maximum-likelihood classification of digital amplitude-phase modulated signals in flat fading non-Gaussian channels[J]. IEEE Transactions on Communications, 2011, 59(8): 2051 - 2056.
- [16] Viterbi A. Nonlinear estimation of PSK-modulated carrier phase with applications to burst digital transmission[J]. IEEE Transactions on Information Theory, 1983, 29(4): 543 - 551.
- [17] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 1977, 39(1): 1 - 38.
- [18] Wu C F. On the convergence properties of the EM algorithm[J]. The Annals of Statistics, 1983, 11(1): 95 - 103.
- [19] Biernacki C. Initializing EM using the properties of its trajectories in Gaussian mixtures[J]. Statistics and Computing, 2004, 14(3): 267 - 279.