

超宽带系统的 HDP-HMM-MTCS 稀疏信道估计算法^①

李晓飞

(武夷学院 数学与计算机学院, 武夷山 354300)
(武夷学院 认知计算与智能信息处理福建省高校重点实验室, 武夷山 354300)
(华东师范大学 上海可信研究重点实验室, 上海 200062)
通讯作者: 李晓飞, E-mail: lixiaofei_73@163.com

摘 要: 给定超宽带 (Ultra Wide-Band, UWB) 信道的稀疏结构, 利用压缩感知 (Compressive Sensing, CS) 进行 UWB 信道估计. 作为 CS 实现的多任务 CS (Muti-Task Compressive Sensing, MTCS) 算法进行信号重建. 信号参数和数据共享可以使用伽马-高斯先验来求解. 在本文中, 层次结构 Dirichle 进程 (Hierarchy Dirichle Processing, HDP) 提供了 HDP 的树结构, 用于解决跨多个任务的数据共享问题. 我们研究 UWB 通信的隐马尔可夫模型 (Hidden Markov Model, HMM) HDP 多任务 CS (Hierarchy Dirichlet Processing Hidden Markov Model based Muti-Task Compressive Sensing, HDP-HMM-MTCS) 的信道估计性能. 首先, 在视距 (Line-Of-Sight, LOS) 和非视距 (Non-Line-Of-Sight, NLOS) 环境下的标准化 IEEE 802.15.4a 信道的稀疏信道结构估计. 其次, CS 比率 (CS Rate, CSR) 对 HDP-HMM-MTCS 信道估计性能的影响. 最后, 利用 SNR (Signal-to-Noise Ratio), 并将其与 MTCS, STCS (Simple-Task Compressive sensing), OMP (Orthogonal Matching Pursuit), L1magic 算法以及新的算法如改进的贝叶斯压缩感知 (Bayesian Compressive Sensing, BCS) 算法, 多经字典自适应算法 BCS 和特征字典自适应算法 BCS 的信道估计比较时间复杂性. 仿真结果表明, 无论 LOS 和 NLOS 环境如何, HDP-HMM-MTCS 具有最小可执行时间, 其信道估计性能优于 MTCS 和其他算法. 因此, HDP-HMM-MTCS 是用于稀疏信道模式的有效且高效的 UWB 信道估计方法.

关键词: 层次结构 Dirichle 进程; 多任务压缩感知; IEEE 802.15.4a 信道模式; 稀疏信道估计; HDP-HMM-MTCS

引用格式: 李晓飞. 超宽带系统的 HDP-HMM-MTCS 稀疏信道估计算法. 计算机系统应用, 2018, 27(3): 191–197. <http://www.c-s-a.org.cn/1003-3254/6290.html>

HDP-HMM-MTCS for Sparse Channel Estimation Algorithm in UWB Systems

LI Xiao-Fei

(Mathematics and Computer Science Department, Wuyi University, Wuyishan 354300, China)
(The Key Laboratory of Cognitive Computing and Intelligent Information Processing of Fujian Education Institutions, Wuyi University, Wuyishan 354300, China)
(Shanghai Key Laboratory of Trustworthy Computing, East China Normal University, Shanghai 200062, China)

Abstract: Given the sparse structure of Ultra Wide-Band (UWB) channels, Compressive Sensing (CS) is exploited for UWB channel estimation. Muti-Task Compressive Sensing (MTCS), as a CS implementation, has exhibited a potential for promoting signal reconstruction. The signal parameters and data sharing can be solved using the Gamma-Gaussian prior. In this paper, the Hierarchy Dirichle processing (HDP) provides the tree structure of the HDP prior for data sharing across multiple tasks. We research the channel estimation performance of HDP Hidden Markov Model based Muti-Task Compressive Sensing (HDP-HMM-MTCS) for UWB communication systems. In particular, investigate the effects of three factors. Firstly, the sparse structure of a standardized IEEE 802.15.4a channel under Line-Of-Sight (LOS) and Non-Line-Of-Sight (NLOS) environments is estimated. Secondly, the CS Rate (CSR) regions' effect on the HDP-HMM-

① 基金项目: 福建省教育厅科技 A 类项目 (JA15515); 福建省科技厅引导性项目 (2016N0030); 武夷学院校级项目 (XL201012)

收稿时间: 2017-07-13; 修改时间: 2017-08-09; 采用时间: 2017-08-14; csa 在线出版时间: 2018-02-09

MTCS channel estimation performance is calculated. Thirdly, the SNR regions are compared with the results of the MTCS, Simple-Task Compressive Sensing (STCS), Orthogonal Matching Pursuit (OMP), and the L1 magic estimations. The simulation results demonstrate that the HDP-HMM-MTCS has the minimum executable time and its channel estimation performances exceed those of the MTCS and the other algorithms, regardless of the LOS and NLOS environments. Therefore, the HDP-HMM-MTCS is an effective and efficient UWB channel estimation method for a sparse channel mode.

Key words: hierarchy dirichle processing; muti-task compressive sensing; IEEE 802.15.4a channel mode; sparse channel estimation; HDP-HMM-MTCS

超宽带 (Ultra Wide-Band, UWB) 脉冲无线电 (Impulse Response, IR) 系统引起了学术界和行业的兴趣. UWB-IR 实现的主要挑战之一是信道估计^[1]. 压缩感知 (Compressive Sensing, CS)^[2,3]可以应用于 UWB 信道估计, 以克服常规最大似然 (Maximum Likelihood, ML) 信道估计器的高速率采样问题^[4]. 在文献[5]中, 采用贝叶斯压缩感知, 提出了两种有效的算法, 以减少主动传感器节点的数量, 同时保持高性能. 在文献[6]中, 采用基于贝叶斯压缩感知 (Bayesian Compressive Sensing, BCS) 的策略来解决入射到天线阵列上的电磁窄带信号 (Direction of Arrivals, DoAs) 估计问题. 在文献[7]中, 主要贡献是利用噪声方差学习在性能改进和适用性增强方面的能力. 在文献[8]中, 压缩感测技术应用于数据恢复, 模拟通信系统期间对采样率降低进行了分析. 文献[9]提出无线网络通信的实现方法以及对无线各模块具体的实现过程进行探讨.

在文献[10,11]中, BCS 框架已被应用于各种 UWB 信道模式和噪声条件下的信道估计. 多任务 CS (Muti-Task Compressive Sensing, MTCS)^[12]应用于 UWB 信道估计中的多个任务. MTCS 和隐马尔可夫模型 (Hidden Markov Model, HMM) 层次 Dirichlet 过程 (Hierarchy Dirichle Processing, HDP) 多任务 CS (HDP-HMM-MTCS) 具有共享相似机制, 可以利用共享机制执行多任务压缩感知信号. 然而, 主要区别在于 MTCS 使用伽马-高斯先验, 而 HDP-HMM-MTCS 使用层次 Dirichlet 过程 HDP. 在本文中, HDP-HMM-MTCS 用于解决多个集群之间的数据共享问题, 用于 UWB 通信中的信道估计和降低计算复杂度. 本文的贡献如下:

(1) 提出了一种新颖的 CS 框架, 表示为 HDP-HMM-MTCS, 用于 UWB 信道估计. HDP-HMM-MTCS 的优点是利用隐马尔可夫模型采用树形结构来

解决多个任务中的数据共享问题, 采用 HDP^[8]以前的方法, 减少了数据传输过程中的数据丢失; 而 MTCS 算法可以使用伽马-高斯先验在多个群集之间共享数据.

(2) 对于 CS 测量, 比较 HDP-HMM-MTCS 和 MTCS^[12], 单任务 CS (Simple-Task Compressive Sensing, STCS)^[12], 正交匹配追踪 (Orthogonal Matching Pursuit, OMP)^[10], L1 magic^[1]和新的算法如改进的 BCS 算法^[13], 多经字典自适应算法 BCS^[14]和特征字典自适应算法 BCS^[14]的信道估计性能, $K=200$, 相对于 CS 比率 (CSR) 和信噪比 (SNR) 值. 图 3 和图 4 分别显示视距 (LOS) 和非视距 (NLOS) 环境几种算法比较情况. 仿真结果表明, HDP-HMM-MTCS 的信道估计性能 (如均方误差 (Mean Square Error, MSE), 误码率 (Bit Error Ratio, BER), 归一化均方误差 (Normalized Mean Square Error, NMSE) 和峰值 SNR (Peak Signal Noise Ratio, PSNR)) 优于那些 MTCS 和其他算法. 此外, 从表 1 可以看出, HDP-HMM-MTCS 的计算时间小于 MTCS 和其他算法的计算时间.

降低信号传输误差和信号数据共享是 UWB 信道估计的挑战之一. MTCS 算法^[11]采用高斯先验方法的共享机制执行多任务压缩感知信号. 本文采用 HDP-HMM-MTCS 算法即采用隐马尔可夫模型层次 Dirichlet 过程解决多信号集群之间的共享问题. 同时, 算法仿真结果显示虽然 HDP-HMM-MTCS 算法的计算复杂度和 MTCS 算法的计算复杂度相等, HDP-HMM-MTCS 算法的时间复杂度却要低于 MTCS 算法的时间复杂度, 同时和最新算法比较时间复杂度, 仿真结果同样显示 HDP-HMM-MTCS 算法的时间复杂度要比最新算法复杂度低.

本文的其余部分安排如下. 在第 1 节中, 建立了 HDP-MTCS 框架. 在第 2 节中, 描述了 HDP-HMM-

MTCS 基本框架, 并提供了在 UWB 系统中用于信道估计的详细 HDP-HMM-MTCS 框架. 在第 3 节中, 介绍和讨论了仿真结果, 并在第 4 节中得出结论.

1 HDP-MTCS 框架应用于 UWB 信道估计

在本节中, 我们提出了一个离散时间等效的 UWB 信道模型. 在任何信号的稀疏域 (时域, 频域等) 中, 随机较小的测量降低采样率.

1.1 UWB 的 MTCS 框架

首先, 为了实现离散时间信道模型, 将通用连续时间信道脉冲响应 (CIR) $h(t)$:

$$h(t) = \sum_{m=1}^M h_m \xi(t - \gamma_m) \quad (1)$$

其中 $\xi(\cdot)$ 是 Dirac 函数, M 表示多路径的数量, γ_m 是第 m 个多径分量的延迟, h_m 是第 m 个多径信道增益系数. 假设 (1) 中连续时间 CIR 的多路径可以根据 Ω 空间信道模型^[10]随时发送脉冲宽度为 ΔT 秒. 等效的 T 间隔信道模型可以表示为:

$$h(t) = \sum_{p=1}^P \omega_p \xi(t - p\Delta T) \quad (2)$$

其中, P 为信道离散时间间隔数. $T_\omega = p\Delta T$ 是信道长度. $\{\omega_p\}$ 是所得到的信道系数集. 因此, 离散时间等效信道响应 h 可以表示为:

$$h = [\omega_1, \omega_2, \dots, \omega_P]^T \quad (3)$$

考虑到 h 具有 K 个非零系数, 假定测量值 $K \ll P$, 则信道的稀疏假设是有效的.

假设由 K 个测量值接受信号表示为 $\{\tilde{g}_i\}_{i=1, \dots, K}$, 接收信号的离散时间方程表示为:

$$\tilde{g}_i = \sum_{j=1}^K \tilde{E}_j h_j + \tilde{\eta}_j \quad (4)$$

其中, 标量矩阵 $E = [\tilde{E}_1, \tilde{E}_2, \dots, \tilde{E}_K] \subseteq \Omega^{K \times K}$ 为时间跳变脉冲, $\tilde{\eta}$ 是加性白高斯噪声 (AWGN), 具有 K 个非零系数. 接收信号 $\tilde{g}_i$ 映射到随机测量矩阵 $\Theta \subseteq \Omega^{K \times P}$, 接受信号 $\tilde{g}_i \subseteq \Omega^{K \times P}$ 为:

$$\begin{aligned} \tilde{g}_i &= \sum_{j=1}^K \Theta_j \tilde{E}_j h_j + \Theta_j \tilde{\eta}_j \\ &= \sum_{j=1}^K \Theta_j \tilde{H}_j + \tilde{\rho}_j \end{aligned} \quad (5)$$

白噪声 (Additive White Gaussian Noise, AWGN)

$\tilde{\rho}_j \subseteq \Omega^{K \times P}$. 由噪声向量 $\tilde{\rho}_j$ 表示为具有精度 $\tilde{\beta}_0$ 的零均值高斯随机分布 i.i.d. $\tilde{H}_i$ 是信道脉冲响应 $h(t)$ 的估计近似值.

$$\tilde{H}_i = \max \|\tilde{H}_i\|_1 \text{ 且 } \|\Theta \tilde{H}_i - \tilde{g}_i\| \geq \varsigma \quad (6)$$

ς 是任意小的数, 且 $\varsigma \leq \tilde{\rho}_i$. 利用 log-barrier 算法来解决 L1 范数, 并且接收信号 $\tilde{g}_i$ 估计为:

$$\tilde{g}_i = \sum_{j=1}^K \Theta_j \tilde{H}_j + \tilde{\rho}_j \quad (7)$$

$\tilde{H}$ 是 $h(t)$ 的估计近似矢量值. Θ_j 为第 j 维测量矩阵, $\tilde{\rho}_j$ 是白高斯噪声. 随机权重 $\tilde{\beta}_0$ 和测量矩阵 Θ_j , 信道脉冲信号近似值 $\tilde{H}$ 和接受信号 $\tilde{g}_i$ 的估计通过方程 (7) 的似然函数来表示为:

$$p(\tilde{g}_i | \tilde{H}_i, \tilde{\beta}_0) = 2\pi \tilde{\beta}_0^{-K/2} \exp \left\{ -\frac{\tilde{\beta}_0}{2} \left\| \Theta_i \tilde{H}_i - \tilde{g}_i \right\|_2^2 \right\} \quad (8)$$

在可压缩条件下, 信道估计问题变为线性回归. 对于关于上述超先验的 MTCS 模型^[7], 参数 β 是 Gamma-Gaussian 先验参数和数据共享多个群集, 服从 $\beta = \{\tilde{\beta}_i\}_{i=1, \dots, K}$ 和 $\beta \sim \prod_{j=1}^K Ga(a, b)$, 其中 a, b 是未知超参数. 在 MTCS 模型里, 使用来自所有 K 个任务的 CS 数据推到超参数, 提出 HDP-MTCS 利用群集适当从 K 个任务共享所有 CS 数据.

1.2 HDP 群集共享

为了解决分组数据共享问题, HDP 在先前的分布中被应用于分组数据因子^[12]. 假设 CS 测量对于接受信号 $\tilde{g}_i$, 第 n_i 簇和初始接受信号 $\tilde{g}_0 \in \Omega^{K \times P}$ 是全局变量. 观测数据 $(s_{1i}, s_{2i}, \dots, s_{ni})$ 是 UWB 通信的发送信号. T 表示基本概率测试周期. 考虑 $\tilde{g}_i$ 是独立的, 并用分布表示 $\tilde{g}_i, \tilde{g}_i \sim DP(\xi, T)$ 和 $F(\varpi_{ii})$ 被定义为观察值 S_{ij} 的分布, 其中每个信号因子 ϖ_{ii} 表示信号观测值 $F(\varpi_{ii})$ 分布相匹配的因子. 图 1 给出了四组 HDP 混合模型的图形表示, 其中矩形表示每个组内模型的重复, 重复的数量在矩形的右下角给出. 模型和条件分布如下:

$$\begin{aligned} \tilde{g}_0 | \beta, \tilde{g}_0 &\sim DP(\tilde{\beta}_0, \tilde{g}_0) \\ \varpi_{ij} | \tilde{g}_i &\sim \tilde{g}_i \\ S_{ij} | \varpi_{ij} &\sim F(\varpi_{ij}) \end{aligned} \quad (9)$$

其中, $\tilde{g}_0$ 初始接受信号矢量, ξ 是初始化 Gamma-Gaussian 先验群集, $\tilde{\beta}_0$ 表示随机权重, 采用棍棒方法描述 $DP(\xi, T)$ 的 $\tilde{g}_0$ 性质, 其中 $\tilde{g}_0$ 定义为 $\tilde{g}_0 = \sum_{n=1}^{\infty} \alpha_q \xi_q$,

其中 $\xi_q \sim \vec{g}_0$, $\alpha_q \sim \text{Beta}(1, \xi)$, $\alpha_q \sim \alpha'_q \prod_{i=1}^{q-1} (1 - \alpha_q)$. 这里, ξ 是初始信号权重, α_q 为第 q 层缩放参数, 服从 Beta 分布, 假设 $\vec{g}_0$ 在成员 $\xi = (\xi_q)_{q=1}^m$ 放置非零块, 并且是接受信号 $\vec{g}_i$ 的基础分布:

$$\vec{g}_i = \sum_{i=1}^{\infty} \chi_{11} \xi_q \quad (10)$$

基于公式 (9), 每子模型对应不同组, χ 是混合权重 $\chi_i = (\chi_{il})_{l=1}^{\infty}$. 由于给定 $\vec{g}_0$, $\vec{g}_i$ 成员都是独立的. 因此给定 α_j 权重 χ_i 是独立的.




图1 四组 HDP 混合模型的图形表示

1.3 UWB 系统的 HDP-MTCS 信道估计算法

为了便于后验计算, 采用指标变量 ℓ_j 表示第 i 次循环, 其中 $\ell_j = i$, 如第 i 层权重等于第 j 层权重, 即 $\xi_j = \xi_i$.

HDP-MTCS 模式表示为:

$$\begin{aligned} \vec{g}_i | h_i, \xi_0 &\sim DP(\vec{E} h_i, \xi_0^{-1}) \\ h_{ij} | l_j, \{\xi_i\}_{i=1}^P, P &\sim DP(0, \xi_{i-1}^{-1}) \\ l_j | \{\alpha_q\} &\sim \text{Multinomial}(\{\alpha_q\}_{k=1, \dots, P}) \\ \alpha_q &\sim \text{Beta}(1, \xi_0) \\ \xi_i | e, f &\sim \prod_{j=1}^m Ga(e, f) \\ \xi_0 &\sim Ga(c, d) \end{aligned} \quad (11)$$

其中 $i = 1, \dots, K$; $j = 1, \dots, P$; $k = 1, \dots, P$; K 为多任务 CS 测量的数量, 变量 j 和 i 测试矩阵行变量和列变量. 为了信道估计系数稀疏, 超参数 c, d, e 和 f 都被设置为一个较小的值. l_j 表示第 j 簇信号的单元帧. E 为信号能量. 假设选择参数值与稀疏改善层次结构一致, c 和 d 接近于零, e 和 f 赋值为 ξ 和 ξ_0 , 第 j 信道冲击响应 $\vec{h}_j$ 先验分布表示如下:

$$P(\vec{h}_i | e, f) = \prod_{j=1}^K DP(h_{i,j} | 0, \xi_q^{-1}) Ga(\xi_q | e, f) d\xi_q \quad (12)$$

$Ga(\cdot)$ 表示 Gamma 分布函数, 从贝叶斯的规则来看, 边界似然函数如下:

$$P(Q | U, V) = \frac{P(U | Q) P(Q | V)}{\int P(U | Q) P(Q | V) dQ} \quad (13)$$

其中, $U = \{\vec{g}_i\}_{i=1, \dots, K}$ 表示来自“K”CS 任务的 CS 测量.

$$Q = \{\beta_0, \alpha_i, \{\tilde{h}_i\}_{i=1, \dots, M}, \{\ell_j\}_{j=1, \dots, M}, \{\xi_i\}_{i=1, \dots, M}\}$$

表示信道估计测量参数矩阵集合. $V = \{a, b, c, d\}$ 是超参数集. 由于边际似然函数的难以计算, 考虑边界似然度的对数来确定对数分布函数 $\lambda(Q)$, $P(Q | U, V)$ 是逼近实际后验分布.

$$\log P(U | V) = \Gamma(\lambda(Q)) + \Psi_{KL}(\lambda(Q) \| \rho(Q | U, V)) \quad (14)$$

其中,

$$\Gamma(\lambda(Q)) = \int \lambda(Q) \log \frac{P(U | Q) P(Q | V)}{\lambda(Q)} dQ \quad (15)$$

同时, $\Psi_{KL}(\lambda(Q) \| \rho(Q | U, V))$ 是 $\lambda(Q)$ 和 $P(Q | U, V)$ 之间的 Kullback-Leibler (KL) 发散. 通过最大化, $\Gamma(\lambda(Q))$ 是 $\rho(Q | U, V)$ 近似逼近, 同时 $\log P(U | V)$ 上形成刚性下界, $\lambda(Q)$ 以分解形式表示为:

$$\lambda(Q) = \lambda(\xi_0) \lambda(\xi) \lambda(\alpha) \prod_{j=1}^K \lambda(\ell_j) \prod_{j=1}^K \lambda(g_j) \prod_{q=1}^K \lambda(\xi_q) \quad (16)$$

根据文献[11], 式 (15) 中, $\lambda(Q)$ 和 $P(Q | U, V)$ 用式 (16) 和式 (12) 替代, 实现了下界 $\Gamma(\lambda(Q))$. 为了确定 $\lambda(\cdot)$ 分布, 设置 $\partial \Gamma(\lambda) / (\partial \lambda(\cdot)) = 0$. 通过考虑每个 $\lambda(\cdot)$ 分布的函数导数来实现下界 $\Gamma(\lambda(Q))$ 的优化. 算法的收敛由下界 Γ 的增加控制. 其中,

$$\begin{aligned} \lambda(\xi_0) &\sim Ga(c, d) \\ \lambda(\xi) &\sim Ga(e, f) \\ \lambda(\ell_j) &\sim \text{Multinomial}(\{\alpha_q\}_{k=1, \dots, N}) \\ \lambda(\vec{g}) &\sim DP(\Theta \vec{H}_i \xi_{0,1}^{-1}) \\ \lambda(\xi_q) &\sim \prod_{j=1}^m Ga(\xi_q | c_{q,j} d_{q,j}) \end{aligned}$$

$\text{Multinomial}(\cdot)$ 表示 $\{\alpha_q\}_{k=1, \dots, N}$ 的最小值函数.

2 HDP-HMM-MTCS 应用 UWB 信道估计

2.1 HDP-HMM-MTCS 的棍棒模型

HDP 应用开发多任务压缩感知 MTCS 信号空间的隐马尔可夫模型. HMM 模型涉及系列混合模型, 其中涉及到当前状态的每个值. 当前状态 δ_i 表示转置矩阵

特定行, 其概率作为下个状态 δ_{i+1} 的混合比例. 给定下个状态 δ_{i+1} , 当前状态 δ_i 由 g_{i+1} 索引的混合组件. 考虑 HMM 无参数变量允许状态无界集, 当前状态每个值都是 Dirichle 过程的一个集合, 而且为了从当前状态能够到达下个状态, 这些 Dirichle 过程集合必须都有相互连接. 这就等同于关联到状态条件的 Dirichle 过程的元素必须是共享的, 即 HDP 的框架.




图2 分层 Dirichle 隐马尔科夫模型过程模型 (HDP-HMM-MTCS)

因此, 通过经典 HMM 的 HDP 混合模型替换传统的有限混合模型集来定义非参数变量 HMM, 就是 HDP-HMM. 利用棍棒公式描述 HDP-HMM 模型 (如图 2):

$$\begin{aligned} \beta|T &\sim GEM(T) \\ \pi|\gamma_0, \beta &\sim DP(\gamma_0, \beta) \\ \varphi_k|h, h &\sim H(h) \\ \delta_i|\{\pi\}_{j=1}^{\infty}, \delta_{i-1} &\sim \pi_{\chi_{i-1}} \\ g_i|\{\varphi\}_{j=1}^{\infty}, \delta_i &\sim f(\varphi_{\chi_i}) \end{aligned} \quad (17)$$

其中, 可变序列 δ 表示隐藏状态序列和 φ 代表从 f 分布观察序列. φ 是状态特定参数分布集. 参数化 H 后在参数化 h . GEM 表示棍棒模型过程, π 是 DP 过程并在 k 状态的转型分布, 通过 DP 过程和参数化相同离散测量矩阵 β 连接, 在状态集周围有大量的数据, 能再次进入并使用状态集. 当时间 $k=1, 2, \dots, K$ 时, $i=1, 2, \dots, N$ 状态分布为:

$$\begin{aligned} \delta_k|\delta_{k-1}(\pi_i)_{i=1}^{\infty} &\sim \pi_{\delta_{k-1}} \\ g_k|\delta_k, (\varphi_i)_{i=1}^{\infty} &\sim G(\varphi_{\delta_k}) \end{aligned} \quad (18)$$

采用棍棒模型描述 g_0 的属性, $\vec{g}_0$ 定义为:

$$\vec{g}_0 = \sum_{q=1}^{\infty} \alpha_q \xi_q$$

同时,

$$\xi_q \sim \vec{g}_0, \alpha \sim Beta(1, \varepsilon), \alpha_q = \alpha'_q \prod_{i=1}^{\infty} \chi_{il} \xi_i$$

假设 $\vec{g}_0$ 是 $\vec{g}_i$ 的基础分布, 而且是非零质量的元素

$\vec{g}_i$ 的分布为: $\vec{g}_i = \prod_{l=1}^{\infty} \chi_{il} \xi_i$, 每个子模型对应不同混合比例变化的组 $\chi_i = (\chi_{il})_{l=1}^{\infty}$. 给定 $\vec{g}_0$, 每个权重 χ_{il} 是独立的. HDP-HMM-MTCS 算法的复杂性与“K”任务相关, 称为“K”簇. 详细分析表明, HDP-HMM-MTCS 算法具有与 MTCS 相当的计算复杂度 $O(PK^2)$, 并且比传统的 ML 方法 $O(iP^3)$ 更小, 其中“ i ”是迭代次数并且 $K \ll P$, 以满足稀疏信号.

下一节, 我们研究了 CS 比率, 表示为 CSR, 定义为 K/P , SNR 区域和 IEEE 802.15.4a 信道模型对 HDP-HMM-MTCS 信道估计性能的影响, 并将结果与 STCS^[12], MTCS^[12], OMP^[10]和 l1 magic^[1]比较.

3 仿真结果

假设 CS 测量的性能 $K=200$, 我们评估估计信道向量的 NMSE 和 PSNR 性能, 通道系数为 $\sum_{i=1}^P \omega_i^2 = 1$. 对于模拟, 我们假设传输的参数为 5 s , $T = 200 \text{ ns}$. 采用 2-PPM 调制方案. 在模拟中使用采样率 $f_c = 4 \text{ GHz}$ 来传送这样的 UWB 信号. $SNR = \sum_{i=1}^P g_i^2 / (f_c * \sigma^2)$, 其中 σ^2 是 AWGN 的方差和 $NMSE = \sum_{i=1}^P (g_i - \tilde{g}_i) / g_i$. 如图 3 和图 4 所示, 对于 CS 测量, $K=200$, 比较 HDP-HMM-MTCS 框架和 STCS^[12], MTCS^[12], OMP^[10]和 l1 magic^[1]的信道估计性能; OMP 和 l1 magic 的 MATLAB 代码可在 <http://sparselab.stanford.edu/>和 <http://users.ece.gatech.edu/justin/l1magic/>分别获得. 并且 MTCS 的代码可以在 <http://people.ee.duke.edu/lihan/cs/>获得.

图 3(a) 和 (b) 绘制了重建 NMSE 和 PSNR 与 UWB 通信的 CSR; 可以看出, 在稀疏信道与 CSR 中, HDP-HMM-MTCS 框架的 NMSE 和 PSNR 性能优于 MTCS 和其他算法的 NMSE 和 PSNR 性能. 因此, (1) 提出的 HDP-HMM-MTCS 框架达到最佳效果, (2) 具有树结构的模型 (HDP-HMM-MTCS) 优于没有结构的模型. 这可能是因为 HDP-HMM-MTCS 算法可以使用先前的 HDP 从群集中的“K”任务共享所有 CS 数据, 而 MTCS 算法仅使用 Gamma-Gaussian 先验共享数据. 因此, HDP-HMM-MTCS 算法提高了 NMSE 和 PSNR 性能, 超越了 MTCS 和其他算法的性能.

图 4 分别描述了 LOS 和 NLOS 情况下的 MSE 和 BER 曲线. 图 4(a) 和 (c) 分别描述了 LOS 和 NLOS 环境下的 BER 性能曲线; 比较确定了 HDP-HMM-MTCS 算法的 BER 性能优于 MTCS 和其他算法, 不

管 LOS 和 NLOS 环境如何. 图 4(b) 和 (d) 分别显示 LOS 和 NLOS 环境下的 MSE 性能曲线, 确定与 MTCS 和其他算法相比, HDP-HMM-MTCS 具有最低

的 MSE, 因为 HDP-HMM-MTCS 解决了数据共享问题. 在使用 HDP 先验的 K 任务中, MTCS 使用 Gamma-Gaussian 先验解决问题, 而另一种算法无法解决数据共享问题. 因此, HDP-HMM-MTCS 可以是稀疏信道模式的有效信道估计方法.




图3 比较 STCS (CS measure $k=200$), MTCS, HDP-MTCS, OMP, and the L1 MAGIC 算法的 MSE 和 PSNR 性能




图4 比较 LOS 和 NLOS 情况下的 MSE 和 BER 性能

最后, 在表 1 中, 提出了 HDP-HMM-MTCS, MTCS-MTCS, STCS, OMP, l1 magic 以及最新的算法如改进的贝叶斯压缩感知 (BCS) 算法^[13], 多字典自适应算法 BCS^[14]和特征字典自适应算法 BCS^[14]的计算时间; 其主

要信道模型适用于 IEEE 802.15.4a 信道估计. 模拟在具有 2.4 GHz, Intel Core i34000M CPU 和 12 GB RAM 的计算机上实现. 在 LOS 环境下, 我们假设传输的参数时间为 5 s, $T=200$ ns, 采用 2-PPM 调制方案. 在表 1 中, 作

为 STCS, OMP 和 l1 magic 只处理简单的 CS 任务, 对于四个 CS 任务 ($K=200, 300, 400$ 和 500), STCS 的计算时间 {1.3711 s, 3.0223 s, 5.2044 s} 分别低于其他两种算法. 然而, MTCS 和 HDP-HMM-MTCS 算法可以同

步 4 项任务 ($K=200, 300, 400$ 和 500) 的实现, 仿真结果表明, HDP-HMM-MTCS (1.92145 s) 的计算时间明显小于 MTCS, {6.4797 s} 和其他算法. 从仿真结果可以看出, HDP-HMM-MTCS 算法比 MTCS 和其他算法更有效.

表 1 K 不同测量数据时 STCS, MTCS, HDP-MTCS, OMP 和 L1 MAGIC 的执行时间比较

K	STCS	MTCS	HDP-HM M-MTCS	OMP	L1MAGIC	改进的贝叶斯 压缩感知(BCS)算法 ^[13]	多经字典自 适应算法BCS ^[14]	特征字典自 适应算法BCS ^[14]
200	1.37			77.31	4.20	4.35	3.90	2.78
300	3.02			75.94	5.29	4.68	3.20	3.23
400	2.51	6.47	1.92	19.26	4.28	5.76	2.90	2.64
500	5.20			55.05	5.35	5.32	3.47	3.41

5 结论

在本文中, 我们研究了 HDP-HMM-MTCS 在 LOS 和 NLOS 环境下的 UWB 通信的信道估计性能. 使用标准化 IEEE 802.15.4a 信道模式的稀疏结构, 我们研究 HDP-HMM-MTCS 信道估计性能, 并将其与 MTCS, STCS, OMP, l1 magic 以及最新的估计结果进行比较. 仿真结果表明, 由于 HDP-HMM-MTCS 采用树形结构解决了多个任务间的数据共享问题, 所以在信道估计中使用 HDP, 在 LOS 和 NLOS 下, 优于 MTCS 和其他具有稀疏信道结构的算法环境; 因此, 它是一种有效的信道估计方法. 此外 HDP-HMM-MTCS 的计算时间在 MTCS 和其他算法中是最小的, 其计算复杂度为 $O(PK^2)$, 其比常规 ML 解决方案更有效. 本文研究的 UWB 通信中的 HDP-HMM-MTCS 应用只是一个开始; HDP-HMM-MTCS 将来会在其他各个领域得到应用.

参考文献

- Cheng XT, Wang MY, Guan YL. Ultrawideband channel estimation: A Bayesian compressive sensing strategy based on statistical sparsity. *IEEE Transactions on Vehicular Technology*, 2015, 64(5): 1819–1832. [doi: 10.1109/TVT.2014.2340894]
- Donoho DL. Compressed sensing. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289–1306. [doi: 10.1109/TIT.2006.871582]
- Candes EJ, Romberg J, Tao T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, 2006, 52(2): 489–509. [doi: 10.1109/TIT.2005.862083]
- Paredes J, Arce GR, Wang ZM. Ultra-wideband compressed sensing: Channel estimation. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(3): 383–395. [doi: 10.1109/JSTSP.2007.906657]
- Ji SH, Xue Y, Carin L. Bayesian compressive sensing. *IEEE Transactions on Signal Processing*, 2008, 56(6): 2346–2356. [doi: 10.1109/TSP.2007.914345]
- Özgör M, Erkucuk S, Cirpan HA. Bayesian compressive sensing for ultra-wideband channel models. *Proceedings of the 35th International Conference on Telecommunications and Signal Processing (TSP)*. Prague, Czech Republic. 2012. 320–324.
- Ji SH, Dunson D, Carin L. Multitask compressive sensing. *IEEE Transactions on Signal Processing*, 2009, 57(1): 92–106. [doi: 10.1109/TSP.2008.2005866]
- Teh YW, Jordan MI, Beal MJ, et al. Hierarchical dirichlet processes. *Journal of the American Statistical Association*, 2006, 101(476): 1566–1581. [doi: 10.1198/016214506000000302]
- 邢彦廷, 吕立, 廉东本. 视频会议中的网络通信控制系统. *计算机系统应用*, 2015, 24(4): 249–252.
- Jhang JW, Huang WH. A high-SNR projection-based atom selection OMP processor for compressive sensing. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 2016, 24(12): 3477–3488. [doi: 10.1109/TVLSI.2016.2554401]
- Cadavid AN, Ramos M. Simulation and analysis of compressed sensing technique as sampling and data compression and reconstruction of signals using convex programming. *Proceedings of the 21st Symposium on Signal Processing, Images and Artificial Vision (STSIVA)*. Bucaramanga, Columbia. 2016. 1–7.
- Qi YT, Liu DH, Dunson D, et al. Multi-task compressive sensing with dirichlet process priors. *Proceedings of the 25th International Conference on Machine Learning*. Helsinki, Finland. 2008. 768–775.
- 常苗苗, 周金和. 基于改进贝叶斯压缩感知的正交频分复用系统信道估计. *计算机应用与软件*, 2016, 33(2): 98–101.
- 王玲玲, 齐丽娜. 特征字典与自适应联合的 BCS-UWB 信道估计. *计算机技术与发展*, 2015, 25(12): 195–200.