

OFDM 时变信道的粒子流滤波估计算法

赵知劲^{1,2} 吴 斌¹

(1. 杭州电子科技大学通信工程学院, 浙江杭州 310018;

2. 中国电子科技集团第 36 研究所通信系统信息控制技术国家级重点实验室, 浙江嘉兴 314001)

摘 要: 粒子滤波是一种基于序贯重要性采样原理的蒙特卡罗方法, 其重采样步骤将导致“粒子贫化”, 传统的基于粒子滤波的 OFDM 时变信道估计算法精度较低、计算复杂度较高。本文从消除“粒子贫化”角度出发, 用粒子流的方法取代了重采样。通过建立微分方程实现贝叶斯估计, 采用粒子流将粒子平滑移动到状态空间中的后验分布上, 实现从先验粒子到后验粒子的更新, 提出了一种基于粒子流滤波的 OFDM 时变信道估计算法。与基于粒子滤波的信道估计方法相比, 本方法计算复杂度低, 估计精度高, 对环境噪声具有较好鲁棒性。

关键词: 信道估计; 正交频分复用; 粒子贫化; 粒子流滤波

中图分类号: TN911.72 文献标识码: A DOI: 10.16798/j.issn.1003-0530.2016.02.016

The Estimation Algorithm of OFDM Time-varying Channel Using Particle Flow Filtering

ZHAO Zhi-jin^{1,2} WU Yu¹

(1. School of Telecommunication Engineering of Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

2. State Key Lab of Information Control Technology in Communication System of No. 36 Research Institute, China Electronic Technology Corporation, Jiaxing, Zhejiang 314001, China)

Abstract: Particle filtering is a Monte Carlo method which is based on the sequential importance sampling, its re-sampling step results in the particle impoverishment, the traditional OFDM time-varying channel estimation algorithm based on particle filtering suffered several problems, such as low accuracy and high computation complexity. In view of eliminating particle impoverishment, the method of particle flow is used to replace re-sampling. Through constructing the differential equation to achieve Bayesian estimation and using particle flow to smoothly migrates the particles to the posterior distribution in state space, then updates from prior particles to posterior particles, an OFDM time-varying channel algorithm based particle flow filtering is proposed. Compared with the channel estimation algorithm based particle filtering, the algorithm has lower computation complexity, higher estimation accuracy and more robust to the environmental noise.

Key words: channel estimation; orthogonal frequency division multiplexing; particle impoverishment; particle flow filtering

1 引言

时变信道(TVC)估计影响着无线通信系统性能,已引起国内外研究者的关注。卡尔曼滤波(Kalman Filtering, KF)算法、递推最小二乘(RLS)算法和最小均方(LMS)算法是主要的经典时变信道估计方法, KF 算法和其他两种算法相比具有更好的

性能^[1]。

然而, KF 算法对噪声干扰鲁棒性较差, 在非高斯环境噪声下难以适用。基于贝叶斯估计的粒子滤波^[2](Particle Filtering, PF)算法克服了 KF 算法的缺陷, 在非高斯环境噪声下也能表现出良好的鲁棒性。文献[3-5]将 PF 算法应用于非高斯环境噪声下 TVC 的估计, 但是传统粒子滤波中的重采样步

骤将会导致粒子丧失多样性,即“粒子贫化”^[6],从而降低算法的估计精度。随着估计状态向量维数的增加,粒子滤波的“粒子贫化”问题将愈加严重。增加粒子数目可以缓解“粒子贫化”问题,但增加了计算复杂度。

为了解决上述 PF 中存在的“粒子贫化”问题,本文给出了一种基于粒子流滤波的(Particle Flow Filtering, PFF) OFDM 信道估计算法。该算法通过将更新粒子的方式由 PF 算法中的重采样方法改变为粒子流方法,从而避免了重采样方法带来的“粒子贫化”问题和计算量增加问题,改善了对噪声的鲁棒性,降低了计算复杂度,提高了估计精度。

本文内容安排如下:第2节将详细介绍 OFDM 的 TVC 频域状态空间模型和粒子流滤波理论;第3节将描述本文提出的信道估计(PFF)算法的具体步骤;第4节将给出算法的计算机仿真实验结果,并且将对本文算法和其他算法的性能进行分析比较。

2 基础知识

本节中将对 OFDM 的 TVC 频域的状态空间模型和粒子流滤波理论进行详细阐述。

2.1 OFDM 无线通信系统模型

OFDM 系统接收端的频域观测方程如式(1)所示,可以用 AR 模型(即状态方程)来建模时变信道,如式(2)所示^[7]

$$\mathbf{Y}_m = \mathbf{X}_m \mathbf{C}_m + \mathbf{W}_m \quad (1)$$

$$\mathbf{C}_m = \alpha \mathbf{C}_{m-1} + \mathbf{V}_m \quad (2)$$

其中, \mathbf{Y}_m 、 \mathbf{X}_m 和 \mathbf{W}_m 分别是 m 时刻(发送第 m 个信号时)的接收信号、发送信号和环境噪声, $\mathbf{Y}_m = [Y_m(0), \dots, Y_m(N-1)]^T$, $\mathbf{W}_m = [W_m(0), \dots, W_m(N-1)]^T$, \mathbf{W}_m 是环境噪声,

$$\mathbf{X}_m = \begin{bmatrix} X_m(0) & 0 & \dots & 0 \\ 0 & X_m(1) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & X_m(N-1) \end{bmatrix} \quad (3)$$

$X_m(i)$ 是子信道 i 上发送的信息符号, N 为子载波数; $\mathbf{C}_m = [C_m(0), \dots, C_m(N-1)]^T$ 为 m 时刻的信道频率响应; $\mathbf{V}_m = [V_m(0), \dots, V_m(N-1)]^T$ 为 m 时刻的状态噪声,该状态噪声服从均值为 0、方差为 σ_v^2

的高斯分布;参数 α 反映了时变信道变化的快慢。设最大多普勒扩展频率为 f_d ,系统采样周期为 T_s ,理想条件下,可以使用下面两式来确定系数 α 和噪声方差 σ_v^2 ^[8]

$$\alpha^2 + \sigma_v^2 = 1 \quad (4)$$

$$\alpha = J_0(2\pi f_d T_s) \quad (5)$$

其中 $J_0(\cdot)$ 为零阶 Bessel 函数。

估计信道就是利用接收信号 \mathbf{Y} 以及式(1)和式(2)来求解状态向量 \mathbf{C}_m 。

2.2 粒子流滤波

N 维状态向量 \mathbf{C} 的非归一化条件概率密度可以用下式表示

$$p(\mathbf{C}, t_k | \mathbf{Z}_k) = p(\mathbf{C}, t_k | \mathbf{Z}_{k-1}) p(\mathbf{Y}_k | \mathbf{C}, t_k) \quad (6)$$

其中, \mathbf{Y}_k 为第 k 时刻测量值; \mathbf{Z}_k 为包括所有测量值的矩阵, $\mathbf{Z}_k = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_k]^T$; $p(\mathbf{Y}_k | \mathbf{C}, t_k)$ 为似然函数。贝叶斯估计即为基于式(6)估计状态向量 \mathbf{C} 。

粒子滤波就是通过直接计算式(6)两个函数的点乘实现贝叶斯估计,而粒子流滤波^[9]则是通过将粒子平滑移动到状态空间的后验分布上实现贝叶斯估计,图1是该过程的形象化描述。

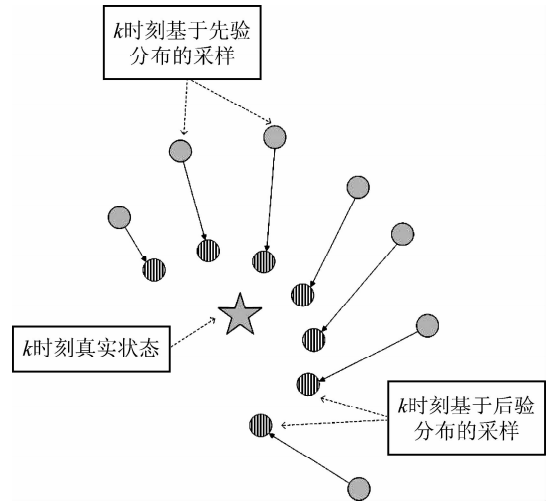


图1 粒子流滤波示意图

Fig. 1 Schematic diagram of particle flow filtering

其基本思想是建立一个微分方程来平滑移动粒子从而实现式(6)的贝叶斯估计,得到类似于由系统动力学方程推导出的时间自然流的粒子流。由于利用离散时间点的样本,不能建立一个时间流,因此引入标量参数 λ , 它扮演类似时间的作用,其在 $[0, 1]$ 内取值。为了便于书写和讨论,将式(6)

中的各函数表示如下: $q(\mathbf{C}) = p(\mathbf{C}, t_k | \mathbf{Z}_k)$, $g(\mathbf{C}) = p(\mathbf{C}, t_k | \mathbf{Z}_{k-1})$, $l(\mathbf{C}) = p(\mathbf{Y}_k | \mathbf{C}, t_k)$, 则式(6)可以表示为

$$q(\mathbf{C}) = g(\mathbf{C})l(\mathbf{C}) \quad (7)$$

利用拓扑学中同伦的概念, 首先定义一个针对变量 λ 的条件概率密度对数流如下

$$\log q(\mathbf{C}, \lambda) = \log g(\mathbf{C}) + \lambda \log l(\mathbf{C}) + K(\lambda) \quad (8)$$

其中, $q(\mathbf{C}, \lambda)$ 是 \mathbf{C} 的条件概率密度, \mathbf{C} 是关于 λ 的函数; $K(\lambda)$ 是用于平衡等式的条件概率密度归一化常数。当 $\lambda=1$ 时, 式(8)就是归一化后验分布, 这正是所要的结果; 当 $\lambda=0$ 时, 式(8)就是归一化先验分布。称满足式(8)关系的 \mathbf{C} 为粒子流, 其密度函数为密度流。

假设服从贝叶斯规律的粒子流满足以下的 Ito 随机微分方程^[10]

$$d\mathbf{C} = f(\mathbf{C}, \lambda) d\lambda + d\mathbf{w} \quad (9)$$

其中, $f(\mathbf{C}, \lambda)$ 是满足 Fokker-Planck 方程^[11]的函数, \mathbf{w} 为过程噪声。利用 Fokker-Planck 方程和式(8)、式(9)可计算得到函数 $f(\mathbf{C}, \lambda)$, 然后得到如下表达式^[12]

$$\frac{\partial q}{\partial \lambda} = -\text{Tr} \left(\frac{\partial(fq)}{\partial \mathbf{C}} \right) + \frac{1}{2} \text{Tr} \left(\mathbf{Q} \frac{\partial^2 q}{\partial \mathbf{C}^2} \right) \quad (10)$$

其中, $\text{Tr}(\cdot)$ 表示 (\cdot) 的迹, \mathbf{Q} 为 Ito 随机微分方程过程噪声 \mathbf{w} 的协方差矩阵。为了简化讨论过程, 这里令 $\mathbf{Q}=0$, 式(9)和式(10)可以分别简化为

$$\frac{d\mathbf{C}}{d\lambda} = f(\mathbf{C}, \lambda) \quad (11)$$

$$\frac{\partial q}{\partial \lambda} = -\text{Tr} \left(\frac{\partial(fq)}{\partial \mathbf{C}} \right) = -\frac{\partial q}{\partial \mathbf{C}} f - q \text{Tr} \left(\frac{\partial f}{\partial \mathbf{C}} \right) \quad (12)$$

因为 q 关于 λ 是光滑和连续的, 式(8)两端同时对 λ 求导得到

$$\frac{\partial \log q(\mathbf{C}, \lambda)}{\partial \lambda} = \frac{\partial q(\mathbf{C}, \lambda)}{\partial \lambda} / q(\mathbf{C}, \lambda) = \log l(\mathbf{C}) + \frac{\partial K(\lambda)}{\partial \lambda} \quad (13)$$

结合式(12)和式(13)可以得到以下等式

$$\log l(\mathbf{C}) + m(\lambda) = -\frac{\partial \log q}{\partial \mathbf{C}} f - \text{Tr} \left(\frac{\partial f}{\partial \mathbf{C}} \right) \quad (14)$$

其中 $m(\lambda) = \partial K(\lambda) / \partial \lambda$, 式(14)就是式(6)贝叶斯

估计所应满足的常微分方程。求解式(14)得到 f , 然后由式(11)就能得到所要估计的 \mathbf{C} , 这就是粒子流滤波。由此可知, 利用式(11)实现了从先验粒子到后验粒子的更新, 用粒子流的方法取代了重采样实现粒子更新, 从而有效避免了粒子滤波中的“粒子贫化”问题, 并且降低了计算复杂度。上述思想可以用图2直观表示之。

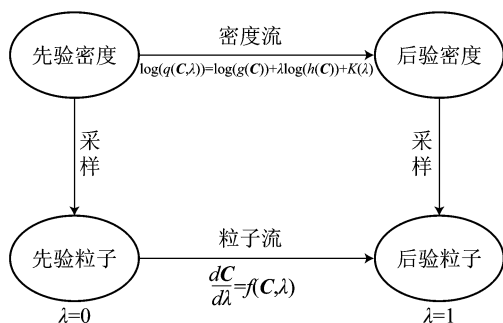


图2 推导贝叶斯估计的粒子流

Fig. 2 Derivation of the Bayesian estimation particle flow

在图2中利用粒子流的微分方程将先验粒子平滑移动到后验分布, 在避免使用重采样的情况下实现了贝叶斯估计。

3 基于粒子流滤波的信道估计

根据式(1)和式(2)的观测方程和状态方程求解式(14)得到 f , 然后由式(11)积分得到所要估计的 \mathbf{C} , 这就是本文提出的基于粒子流滤波 (Particle Flow Filtering, PFF) 的 OFDM 系统信道估计方法。因此关键是对方程(14)的求解。

方程(14)有多种求解方法^[13,14], 下面介绍其中一种容易实现的方法。假设方程(14)存在某种特定的解如下

$$f(\mathbf{C}, \lambda) = \mathbf{A}(\lambda)\mathbf{C} + \mathbf{b}(\lambda) \quad (15)$$

其中, $\mathbf{A}(\lambda)$ 和 $\mathbf{b}(\lambda)$ 是待定项。由此可得

$$\frac{df}{d\mathbf{C}} = \mathbf{A}(\lambda) \quad (16)$$

假设不含噪声的观测值为 $\hat{\mathbf{Y}}$, 观测方程为 h (线性或非线性), 即有 $\hat{\mathbf{Y}} = h(\mathbf{C})$ 。实际中由于无法直接得到无噪声的观测值 $\hat{\mathbf{Y}}$, 其可近似表示为

$$\hat{\mathbf{Y}} = h(\mathbf{C}) \approx h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}}) \quad (17)$$

其中, $\hat{\mathbf{C}}$ 为 \mathbf{C} 的估计值, \mathbf{H} 为基于实际观测方程得到的雅克比矩阵, 其表达式为 $\mathbf{H} = \partial h(\mathbf{C}) / \partial \mathbf{C}$ 。根据文献[11], 假设先验概率 $g(\mathbf{C})$ 和似然函数 $l(\mathbf{C})$ 都

服从高斯分布, 可以表示为

$$\log(g) = -\frac{1}{2}(\mathbf{C} - \bar{\mathbf{C}})^T \mathbf{P}^{-1}(\mathbf{C} - \bar{\mathbf{C}}) \quad (18)$$

$$\begin{aligned} \log(l) = & -\frac{1}{2}(\mathbf{Y} - \hat{\mathbf{Y}})^T \mathbf{R}^{-1}(\mathbf{Y} - \hat{\mathbf{Y}}) = \\ & -\frac{1}{2}\{\mathbf{Y} - [h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}})]\}^T \mathbf{R}^{-1} \\ & \{\mathbf{Y} - [h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}})]\} \quad (19) \end{aligned}$$

式中, $\bar{\mathbf{C}}$ 为 \mathbf{C} 的先验均值; \mathbf{P} 为 \mathbf{C} 的预测误差协方差矩阵, 给定 \mathbf{P} 的初始值, 利用扩展卡尔曼滤波 (EKF) 或者无迹卡尔曼滤波 (UKF) 迭代更新获得 \mathbf{P} ; \mathbf{R} 为观测方程的噪声协方差矩阵。将式 (18) 和式 (19) 代入式 (8) 可得 $\log q(\mathbf{C}, \lambda)$, 并利用式 (16) 和 (19) 计算方程 (14) 可得

$$\begin{aligned} & -\frac{1}{2}\{\mathbf{Y} - [h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}})]\}^T \mathbf{R}^{-1} \\ & \{\mathbf{Y} - [h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}})]\} + m(\lambda) = \\ & \{(\mathbf{C} - \bar{\mathbf{C}})^T \mathbf{P}^{-1} - \lambda\{\mathbf{Y} - [h(\hat{\mathbf{C}}) + \mathbf{H}(\mathbf{C} - \hat{\mathbf{C}})]\}^T \\ & \mathbf{R}^{-1} \mathbf{H}\}(\mathbf{A}\mathbf{C} + \mathbf{b}) - \text{Tr}(\mathbf{A}) \quad (20) \end{aligned}$$

由式 (20) 两边含有 \mathbf{C}^2 项相等可得

$$\begin{aligned} -\frac{1}{2}(\mathbf{H}\mathbf{C})^T \mathbf{R}^{-1}(\mathbf{H}\mathbf{C}) = & \mathbf{C}^T \mathbf{P}^{-1} \mathbf{A}\mathbf{C} + \lambda(\mathbf{H}\mathbf{C})^T \mathbf{R}^{-1} \mathbf{H}\mathbf{A}\mathbf{C} \\ & -\frac{1}{2}\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} = \mathbf{P}^{-1} \mathbf{A} + \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}\mathbf{A} \quad (21) \end{aligned}$$

因此我们可以得到 \mathbf{A} 的表达式为

$$\mathbf{A} = -\frac{1}{2}(\mathbf{P}^{-1} + \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} \quad (22)$$

同理利用式 (20) 两边含 \mathbf{C} 项相等可得

$$\begin{aligned} \mathbf{C}^T \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}] = & \mathbf{C}^T \mathbf{P}^{-1} \mathbf{b} - \mathbf{C}^T \mathbf{A}^T \mathbf{P}^{-1} \bar{\mathbf{C}} + \\ & \lambda(\mathbf{H}\mathbf{C})^T \mathbf{R}^{-1} \mathbf{H}\mathbf{b} - \lambda \mathbf{C}^T \mathbf{A}^T \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}] \\ \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}] = & \mathbf{P}^{-1} \mathbf{b} - \mathbf{A}^T \mathbf{P}^{-1} \bar{\mathbf{C}} + \\ & \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}\mathbf{b} - \lambda \mathbf{A}^T \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}] \quad (23) \end{aligned}$$

我们可以得到 \mathbf{b} 的表达式

$$\begin{aligned} \mathbf{b} = & (\mathbf{P}^{-1} + \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \{\mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \\ & \mathbf{H}\hat{\mathbf{C}}] + \mathbf{A}^T \{\mathbf{P}^{-1} \bar{\mathbf{C}} + \lambda \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}]\}\} \quad (24) \end{aligned}$$

由于我们无法知晓 $\bar{\mathbf{C}}$ 值, 用估计值 $\hat{\mathbf{C}}$ 代替 $\bar{\mathbf{C}}$, 可得

$$\begin{aligned} \mathbf{b} = & (\mathbf{P}^{-1} + \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \{\mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \\ & \mathbf{H}\hat{\mathbf{C}}] + \mathbf{A}^T \{\mathbf{P}^{-1} \hat{\mathbf{C}} + \lambda \mathbf{H}^T \mathbf{R}^{-1}[\mathbf{Y} - h(\hat{\mathbf{C}}) + \mathbf{H}\hat{\mathbf{C}}]\}\} \quad (25) \end{aligned}$$

利用矩阵求逆定理可得

$$(\mathbf{P}^{-1} + \lambda \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} = \mathbf{P} - \lambda \mathbf{P}\mathbf{H}^T(\mathbf{R} + \lambda \mathbf{H}\mathbf{P}\mathbf{H}^T)^{-1} \mathbf{H}\mathbf{P} \quad (26)$$

将式 (26) 代入式 (22) 化简可得

$$\mathbf{A} = -\frac{1}{2}\mathbf{P}\mathbf{H}^T(\mathbf{R} + \lambda \mathbf{H}\mathbf{P}\mathbf{H}^T)^{-1} \mathbf{H} \quad (27)$$

将式 (26) 代入式 (25), 并利用式 (27) 化简, 最后可得

$$\mathbf{b} = (\mathbf{I} + 2\lambda \mathbf{C})[(\mathbf{I} + \lambda \mathbf{A})\mathbf{P}\mathbf{H}^T \mathbf{R}^{-1}(\mathbf{Y} - \mathbf{e}) + \mathbf{A}\hat{\mathbf{C}}] \quad (28)$$

其中, \mathbf{I} 为单位矩阵, $\mathbf{e} = h(\hat{\mathbf{C}}) - \mathbf{H}\hat{\mathbf{C}}$ 是将测量方程线性化的误差, 当测量方程 h 为线性时 \mathbf{e} 恒等于 0。将式 (27) 和式 (28) 代入式 (15) 即可得函数 $f(\mathbf{C}, \lambda)$ 。

因此, 本文提出的 OFDM 的 TVC 估计 (PFF) 算法共有两个阶段, 即训练阶段和估计阶段, 其主要步骤如下:

(1) 首先系统发送端发送一串接收端已知的 OFDM 训练序列 \mathbf{X}_m , 接收端利用已知的训练序列 \mathbf{X}_m 和接收信号 \mathbf{Y}_m 使用 LMS 估计算法获得 TVC 的初始估计 $\hat{\mathbf{C}}_{t-1}$, 利用 $\hat{\mathbf{C}}_{t-1}$ 生成初始粒子集合, 表示为 $\tilde{\mathbf{c}}_{t-1,i} (1 \leq i \leq N_p)$, 其中 N_p 为粒子个数。

(2) 利用当前实时观测得到的 \mathbf{Y}_t 和前一时刻得到的 $\hat{\mathbf{C}}_{t-1}$, 采用式 (29) 所示的最大似然解码算法对符号 \mathbf{X}_t 粗估计 (解码), 得到其估计值 $\tilde{\mathbf{X}}_t$ 。

$$\tilde{\mathbf{X}}_t = \arg \min_{\mathbf{X}_t \in \mathcal{S}^{N_t}} \|\mathbf{Y}_t - \hat{\mathbf{C}}_{t-1} \mathbf{X}_t\|^2 \quad (29)$$

其中, \mathcal{S} 为发射字符集 (包括所有可能的发射字符), N_t 为发射字符集中字符个数。

(3) 根据当前观测值的 \mathbf{Y}_t 和前一时刻信道估计值 $\hat{\mathbf{C}}_{t-1}$ 以及发射信号粗估计值 $\tilde{\mathbf{X}}_t$, 使用粒子流滤波算法按如下步骤估计现时信道 $\hat{\mathbf{C}}_t$:

(a) 根据状态方程 (2), 对粒子集 $\tilde{\mathbf{c}}_{t-1,i} (1 \leq i \leq N_p)$ 进行先验更新, 此处 α 与式 (2) 中 α 的值相同

$$\tilde{\mathbf{c}}_{t,i} = \alpha \tilde{\mathbf{c}}_{t-1,i} + \mathbf{V}_m \quad (1 \leq i \leq N_p) \quad (30)$$

(b) 利用当前时刻测量值 \mathbf{Y}_t 和式 (15)、式 (27) 和式 (28) 对 $\tilde{\mathbf{c}}_{t,i}$ 进行更新, 得到服从 $p(\mathbf{C}, t_k | \mathbf{Z}_k)$ 概率分布的粒子 $\tilde{\mathbf{c}}_{t,i}$ 。

(c) 计算粒子 $\tilde{\mathbf{c}}_{t,i}$ 的均值获得估计量

$$\hat{\mathbf{C}}_t = \frac{1}{N_p} \sum_{i=1}^{N_p} \tilde{\mathbf{c}}_{t,i} \quad (31)$$

(4) 根据当前时刻的观测信号 \mathbf{Y}_t 和估计信道 $\hat{\mathbf{C}}_t$ 再次利用式 (29) 进行最大似然解码, 得到发送序

列 \mathbf{X}_t 的估计值 $\hat{\mathbf{X}}_t$ 。

步骤(1)为训练阶段,步骤(2)~(4)为估计阶段,步骤(1)~(4)对一帧 OFDM 信号的信道完成了估计,在下一帧 OFDM 信号到来时,重复上述过程。在训练阶段需要训练序列以完成对初始信道的估计,在后续信道实时估计中不需要发送任何训练序列信息。完整 PFF 算法如表 1 所示。

表 1 基于粒子流滤波的时变信道估计算法

Tab.1 OFDM channel estimation algorithm
based on particle flow filtering

训练阶段:

估计初始信道得到信道初始值 $\hat{\mathbf{C}}_{t-1}$ 并生成初始粒子集 $\tilde{\mathbf{c}}_{t-1}^i (1 \leq i \leq N_p)$ 。

估计阶段:

对 $k=t, t+1, \dots, t+N_d-1$,

1) 利用 $\hat{\mathbf{C}}_{k-1}$ 和当前测量值 \mathbf{Y}_k 通过式(29)得到粗估计值 $\tilde{\mathbf{X}}_k$;

2) 利用式(30)对粒子集 $\tilde{\mathbf{c}}_{k-1}^i$ 进行先验更新得到 $\tilde{\mathbf{c}}_k^i$;

3) 计算样本均值 $\bar{\mathbf{c}} = \frac{1}{N_p} \sum_{i=1}^{N_p} \tilde{\mathbf{c}}_k^i$;

4) 对 $j=1, 2, \dots, N_\lambda$, 设 $\lambda=j\Delta\lambda$:

① 在 $\bar{\mathbf{c}}$ 值处线性化测量方程 h , 得到 $\mathbf{H} = \left. \frac{\partial h(\mathbf{c})}{\partial \mathbf{c}} \right|_{\mathbf{c}=\bar{\mathbf{c}}}, \mathbf{e} = h(\bar{\mathbf{c}}) - \mathbf{H}\bar{\mathbf{c}}$;

② 利用式(27)和式(28)计算出 \mathbf{A} 和 \mathbf{b} ;

③ 对 $i=1, 2, \dots, N_p$, 利用式(15)计算出每个粒子对应的 $f(\tilde{\mathbf{c}}_k^i, \lambda)$ 值, 并平滑移动每一个粒子 $\tilde{\mathbf{c}}_k^i = \tilde{\mathbf{c}}_k^i + \Delta\lambda f(\tilde{\mathbf{c}}_k^i, \lambda)$;

④ 利用样本集 $\tilde{\mathbf{c}}_k^i$ 更新样本均值 $\bar{\mathbf{c}} = \frac{1}{N_p} \sum_{i=1}^{N_p} \tilde{\mathbf{c}}_k^i$;

5) 利用式(31)计算 $\hat{\mathbf{C}}_k$, 结合当前测量值 \mathbf{Y}_k , 由式(29)得到发送序列 \mathbf{X}_k 的估计值 $\hat{\mathbf{X}}_k$ 。

表 1 中 N_d 表示一帧 OFDM 信号中不包括训练序列的 OFDM 符号长度, N_d 的值通常为 10; $N_\lambda = 1/\Delta\lambda$, $\Delta\lambda$ 为数值积分步长。表 1 中采用的是欧拉积分法, 也可采用其他数值积分方法。

4 算法仿真与性能分析

本节仿真实验中将分析比较基于 EKF、标准粒

子滤波(SPF)、扩展卡尔曼粒子滤波^[15](EKPF)和本文算法(PFF)的四种信道估计算法性能。以 MATLAB 2010b 作为工具, 在 Intel 酷睿双核处理器(2.13 GHz)、2 GB 内存的 PC 机上实现仿真实验。假设在一个 OFDM 符号中的信道不变, 设 OFDM 系统的载频为 2 GHz, 带宽为 10 MHz, 系统的子载波数目为 64 个, 信号调制方式为 QPSK; 系统采用瑞利多径衰落信道; 式(2)中参数 α 即归一化多普勒衰减率 $f_d T_s$ 的值分别设为 0.01 和 0.03, 分别对应于慢时变信道和快时变信道; 由式(5)确定噪声方差 σ_v^2 的值; 每一次初始信道估计发送一帧 OFDM 符号序列, 其中第一个 OFDM 符号为训练序列, 后面紧跟着 10 个未知的 OFDM 符号即 $N_d = 10$; 粒子流滤波的数值积分步长 $\Delta\lambda = 0.1$; 仿真实验的次数为 1000 次, 三种不同粒子型滤波器的粒子数 $N_p = 50$ 。

环境噪声 \mathbf{W}_m 分别为高斯噪声和非高斯噪声, 仿真中采用的非高斯噪声为 Middleton-A 类^[16]非高斯噪声, 可以用混合高斯模型来近似表示 Middleton-A 类非高斯噪声, 其概率密度表示为 $p(\mathbf{W}_m) = (1 - \varepsilon)N(0, \sigma_g^2) + \varepsilon N(0, \kappa\sigma_g^2)$, $N(0, \sigma_g^2)$ 为服从均值为 0, 方差为 σ_g^2 的复高斯分布, 仿真中取 $\varepsilon = 0.3$, $\kappa = 100$ 。


用传输的误比特率(BER)和式(32)所定义的归一化均方误差(NMSE)分析比较四种信道估计算法性能。

$$\text{NMSE} = \frac{\sum_{m=0}^{N_d-1} \sum_{k=0}^{N-1} E \left\{ \frac{\|C_m(k) - \hat{C}_m(k)\|^2}{\|C_m(k)\|^2} \right\}}{N_d N} \quad (32)$$


其中 $\hat{C}_m(k)$ 和 $C_m(k)$ 分别是估计值 $\hat{\mathbf{C}}_m$ 和 \mathbf{C}_m 的第 k 维分量, N 为信道维数。

高斯噪声和非高斯噪声下 4 种信道估计方法对慢时变信道和快时变信道估计的归一化均方误差和误码率分别如图 3 和图 4 所示。


由图可见, 在环境噪声为高斯和非高斯噪声时, 4 种方法对慢时变信道的估计性能都优于快时变信道; 本文算法在高信噪比情况下的信道估计的 NMSE 和 BER 都要显著低于其他三种算法; 在两种环境噪声情况下本文算法的估计性能变化较小, 这说明本文方法对噪声的鲁棒性较好。




(a) 慢时变信道($f_a T_s=0.01$)
(a) Slow time-varying channel($f_a T_s=0.01$)



(b) 快时变信道($f_a T_s=0.03$)
(b) Fast time-varying channel($f_a T_s=0.03$)




(c) 慢时变信道($f_a T_s=0.01$)
(c) Slow time-varying channel($f_a T_s=0.01$)




(d) 快时变信道($f_a T_s=0.03$)
(d) Fast time-varying channel($f_a T_s=0.03$)

图 3 高斯环境噪声下时变信道估计性能


Fig. 3 Time-varying channel estimation performance under Gaussian noise environment




(a) 慢时变信道($f_a T_s=0.01$)
(a) Slow time-varying channel($f_a T_s=0.01$)



(b) 快时变信道($f_a T_s=0.03$)
(b) Fast time-varying channel($f_a T_s=0.03$)



(c) 慢时变信道($f_a T_s=0.01$)
(c) Slow time-varying channel($f_a T_s=0.01$)



(d) 快时变信道($f_a T_s=0.03$)
(d) Fast time-varying channel($f_a T_s=0.03$)

图4 非高斯环境噪声下时变信道估计性能

Fig.4 Time-varying channel estimation performance under Non-Gaussian noise environment

表2 4种滤波算法的平均运行时间

Tab.2 The average running time of four kinds filtering algorithm

滤波算法名称	运行时间/s
EKF	0.0468
SPF	0.3852
EKPF	2.9204
PFF	0.2661

为了比较不同信道估计算法的计算复杂度,对每种滤波算法分别进行了1000次仿真实验,4种算法的运行时间平均值如表2所示。由表可见:EKF算法运行速度最快;在其余三种粒子型算法中,PFF运行速度最快,SPF次之,EKPF最慢。

5 结论

本文提出了一种基于粒子流滤波的OFDM时变信道估计方法,采用粒子流形式更新粒子,能够有效避免粒子滤波方法中重采样引起的“粒子贫化”问题,和基于粒子滤波的信道估计算法相比,本文算法估计精度高,对噪声鲁棒性强,计算复杂度低。

参考文献

[1] Haykin S, Sayed A H, Zeidler J R, et al. Adaptive tracking of linear time-variant systems by extended RLS algorithms [J]. IEEE Transactions on Signal Processing, 1997, 45(5): 1118-1128.

[2] Dong Hui-ying, Cao Bin, Yang Yue-ping. Application of particle filter for target tracking in wireless sensor networks[C] // International Conference on Communications and Mobile Computing (CMC). Shenzhen: IEEE, 2010: 12-14.

[3] Cai hua, Zhao Xiao-hui. Variable step-size semi-blind channel estimation for MIMO-OFDM based on particle filtering[C] // International Conference on Wireless Communications, Networking and Mobile Computing. Beijing: IEEE, 2009: 24-26.

[4] 景源, 殷福亮, 曾硕. 基于粒子滤波的MIMO-OFDM时变信道半盲估计[J]. 通信学报, 2007, 28(8): 67-75.
Jing Yuan, Yin Fuliang, Zeng Shuo. Particle filtering based semi-blind estimation for MIMO-OFDM time-varying channel[J]. Journal on Communications, 2007, 28(8): 67-75. (in Chinese)

[5] 顾晨阳, 李丁山, 李含辉. 单载波频域均衡系统信道估计的粒子滤波方法[J]. 信号处理, 2014, 30(4): 483-488.
Gu Chenyang, Li Dingshan, Li Hanhui. Channel Estimation of Single Carrier Frequency Domain Equalization System Using Particle Filter Method[J]. Journal of Signal Processing, 2014, 30(4): 483-488. (in Chinese)

[6] Daum F, Huang J. Particle degeneracy: root cause and solution[C] // SPIE Defense, Security and Sensing. 2011: 80500W-80500W-11.

[7] Wang H S, Chang P C. On verifying the first-order Mark-

- ovian assumption for a Rayleigh fading channel model [J]. IEEE Transactions on Vehicular Technology, 1996, 45(2): 353-357.
- [8] Bello P. Characterization of randomly time-variant linear channels[J]. IEEE Transactions on Communications Systems, 1963, 11(4): 360-393.
- [9] Daum F, Huang J. Particle flow for nonlinear filters, Bayesian decisions and transport[C]//16th International Conference on Information Fusion (FUSION). Istanbul; IEEE, 2013:1072-1079.
- [10] Itô K. Differential equations determining Markov processes[J]. Zenkoku Shijo Sugaku Danwakai, 1942, 244(1077): 1352-1400.
- [11] Risken H. Fokker-planck equation[M]. Springer Berlin Heidelberg, 1984.
- [12] Daum F, Huang J. Proof that particle flow corresponds to Bayes' rule: necessary and sufficient conditions [C] // SPIE Defense Security International Society for Optics and Photonics, 2015: 94740I-94740I-10.
- [13] Daum F, Huang J. Particle flow with non-zero diffusion for nonlinear filters, Bayesian decisions and transport [J]. Signal and Data Processing of Small Targets, 2013, 9(12): 1117-1123.
- [14] Daum F E. Exact finite-dimensional nonlinear filters[J]. IEEE Transactions on Automatic Control, 1986, 31(7): 616-622.
- [15] Ning Zhou, Da Meng, Shuai Lu. Estimation of the dynamic states of synchronous machines using an extended particle filter[C]. IEEE Transactions on Power Systems. 2013:4152-4161.
- [16] Wang X, Poor H V. Robust multiuser detection in non-Gaussian channels [J]. IEEE Transactions on Signal Processing, 1999, 47(2): 289-305.

作者简介



赵知劲 女, 1959年生, 浙江宁波人。杭州电子科技大学教授, 博士, 博士生导师, 主要研究方向为认知无线电、通信信号处理、自适应信号处理等。
E-mail: zhaozj03@hdu.edu.cn.



吴 棫 男, 1991年生, 浙江温州人, 杭州电子科技大学硕士研究生, 研究方向为信号处理。
E-mail: waynegeek@yeah.net