

混沌信号在无线传感器网络中的盲分离*

黄锦旺 冯久超[†] 吕善翔

(华南理工大学电子与信息学院, 广州 510641)

(2013年9月16日收到; 2013年10月21日收到修改稿)

混沌信号在本质上属于非线性非高斯信号, 它在无线传感器网络下的应用还涉及到信号量化问题, 这使得混沌信号在此应用环境下的信号盲分离更为棘手。针对此问题, 本文在容积卡尔曼粒子滤波的框架下提出一种解决方法。文中首先推导出观测信号的概率密度函数, 在量化比特有限的情况下, 采用最优量化器, 获得最优的量化结果。在此基础上, 使用容积卡尔曼滤波器产生粒子滤波中的重要性概率密度函数, 融入最新的观测值, 提高粒子对系统状态后验概率的逼近, 提高信号盲分离的精度。仿真结果表明算法能够有效地分离混合混沌信号, 参数估计的精度及其运算量均优于已有的无先导卡尔曼粒子滤波算法, 其运行时间为无先导卡尔曼粒子滤波算法的88.77%。

关键词: 混沌信号, 盲分离, 无线传感器网络, 粒子滤波器

PACS: 05.45.-a, 05.45.Vx, 84.40.Ua

DOI: 10.7498/aps.63.050502

1 引言

无线传感器网络是当前的一个热点研究方向, 在工业、农业和航天等众多领域有巨大的应用价值^[1,2]。传感器网络由大量的节点通过无线通信组合而成, 通过节点之间的协作完成复杂的任务, 节点的通信能力、计算能力和能量有限, 我们在设计传感器网络应用的时候需要考虑节点资源受限的问题。

信号盲分离技术是20世纪末发展起来的信号处理技术, 在语音处理、图像处理和无线通信等领域有重要的应用。目前已经提出了很多盲分离的算法^[3,4], 这些算法是基于PC的, 没有考虑传感器节点的资源受限和信号分离的实时性。文献[5, 6]根据混沌的产生方程和卡尔曼滤波器来构造目标函数, 用卡尔曼滤波器估计分离向量, 通过分离向量和混合信号的乘积来实现混沌信号的分离。卡尔曼滤波器对于高斯信号的估计是最优的, 但针对非线性和非高斯信号的估计, 一般采用粒子滤波器。

混沌信号本质上不属于高斯信号, 因此分离混合的混沌信号, 更适合采用粒子滤波器来实现。本文在此基础上, 结合容积卡尔曼滤波算法和粒子滤波器^[7–9], 提出一种新的混沌信号盲分离算法, 能有效地实现混合混沌信号的盲分离。新算法用容积卡尔曼滤波器来产生粒子滤波器中粒子的重要性概率密度函数, 融入最新的观测值, 提高算法的参数估计精度。同时算法相比已有的无先导卡曼粒子滤波算法^[10,11]有较少的运算量和较高的参数估计精度。另外, 和目前算法简单使用均匀量化不同, 我们推导出观测信号的概率密度函数, 使用最优量化器^[12,13]量化观测信号, 在节点量化比特数有限的情况下, 获得最优的信号量化结果, 提高算法性能。

2 盲源模型

考虑一个有N个节点和J个信号源的无线传感器网络系统, 节点n的观测信号为各个信号源的加权和

* 国家自然科学基金(批准号: 60872123, 61101014)、国家-广东省自然科学基金联合基金(批准号: U0835001)、广东省高层次人才项目基金(批准号: N9101070)和中央高校基本业务费(批准号: 2012ZM0025)资助的课题。

† 通讯作者。E-mail: fengjc@scut.edu.cn

$$y_n(k) = \sum_{j=1}^J a_{nj} x_j(k) + v_n(k), \quad (1)$$

$x_j(k)$ 为第 j 个源信号, $v_n(k)$ 是节点 n 的观测噪声, a_{nj} 为混合系数, k 为离散时间点.

由于传感器网络无线通信带宽有限, 节点收集的信号在传输到融合中心之前需要经过量化处理, 减少通信的数据量. 量化信号过程引入量化噪声, 对于无簇结构的传感器网络, 节点把采集数据直接发给融合中心, 融合中心收到的信号为

$$z_n(k) = \sum_{j=1}^J a_{nj} x_j(k) + v_n(k) - q_n(k), \quad (2)$$

$q_n(k)$ 为量化噪声. (2) 式写成向量形式

$$\mathbf{Z} = \mathbf{AX} + \mathbf{U}. \quad (3)$$

观测信号 $\mathbf{Z} = [z_1, z_2, \dots, z_N]^T$, 混合矩阵 $\mathbf{A} = [a_{nj}]$ 和噪声向量 $\mathbf{U} = [v_1 - q_1, v_2 - q_2, \dots, v_N - q_N]^T$.

3 信号的最优量化

节点的观测数据经过量化后发送到融合中心, 融合中心收集观测数据并做信号盲分离处理. 和其他文章简单使用均匀量化不同, 本文在推导出信号概率密度函数的情况下, 使用最优量化器对信号进行量化处理, 在量化比特有限的条件下, 实现信号的最优量化.

最优量化需要知道观测信号的概率密度函数, 在推导观测信号概率密度函数之前, 先证明两个引理.

引理 1 假设信号 x 的概率密度函数为 $p_x(x)$, 则信号 $y = ax + b$ 的概率密度函数为 $p_y(y) = p_x\left(\frac{y-b}{a}\right)\frac{1}{a}$, a, b 为常系数, 且 $a > 0$.

证明 由于 $a > 0$, y 是 x 的单调递增函数, 其分布函数

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(ax + b \leq y) \\ &= P\left(X \leq \frac{y-b}{a}\right) = F_X\left(\frac{y-b}{a}\right). \end{aligned} \quad (4)$$

将上式两边对 y 求导得

$$\begin{aligned} p_y(y) &= p_x\left(\frac{y-b}{a}\right) \frac{d}{dy}\left(\frac{y-b}{a}\right) \\ &= p_x\left(\frac{y-b}{a}\right) \frac{1}{a}. \end{aligned} \quad (5)$$

证毕.

引理 2 两个独立信号 x_1 和 x_2 , 其概率密度函数分别为 $p_{x_1}(x)$ 和 $p_{x_2}(x)$, 则信号 $y = x_1 + x_2$ 的概率密度函数为 $p_y(y) = \int_{-\infty}^{\infty} p_{x_1}(u)p_{x_2}(y-u)du$.

证明 引入另外一个变量 $y' = x_1 - x_2$, 求解出 x_1 和 x_2 ,

$$\begin{aligned} x_1 &= \frac{1}{2}(y + y'), \\ x_2 &= \frac{1}{2}(y - y'). \end{aligned} \quad (6)$$

向量 (x_1, x_2) 对向量 (y, y') 的雅可比多项式

$$J = \begin{vmatrix} \frac{\partial x_1}{\partial y} & \frac{\partial x_1}{\partial y'} \\ \frac{\partial x_2}{\partial y} & \frac{\partial x_2}{\partial y'} \end{vmatrix} = \begin{vmatrix} \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & -\frac{1}{2} \end{vmatrix} = -\frac{1}{2}. \quad (7)$$

二维变量 (y, y') 的概率密度函数为

$$\begin{aligned} p_{yy'}(y, y') &= p_{x_1 x_2}(x_1, x_2) |J| \\ &= \frac{1}{2} p_{x_1 x_2}\left(\frac{1}{2}(y+y'), \frac{1}{2}(y-y')\right), \end{aligned} \quad (8)$$

变量 y 的概率密度函数为

$$\begin{aligned} p_y(y) &= \int_{-\infty}^{\infty} p_{yy'}(y, y') dy' \\ &= \frac{1}{2} \int_{-\infty}^{\infty} p_{x_1 x_2}\left(\frac{1}{2}(y+y'), \frac{1}{2}(y-y')\right) dy', \end{aligned} \quad (9)$$

令 $u = \frac{1}{2}(y+y')$, 将 (9) 式做变量替换

$$p_y(y) = \int_{-\infty}^{\infty} p_{x_1 x_2}(u, y-u) du. \quad (10)$$

信号 x_1 和 x_2 相互独立, (10) 式可写成 [14]

$$p_y(y) = \int_{-\infty}^{\infty} p_{x_1}(u)p_{x_2}(y-u) du, \quad (11)$$

即信号 y 的概率密度函数是信号 x_1 和 x_2 概率密度函数的卷积, 证毕.

由于节点 n 的观测信号 y_n 为各个源信号的加权和, 求其概率密度函数的过程如下: 根据信号 x_j 的概率密度函数 p_{x_j} 和 (5) 式求出 $a_{nj}x_j$ 的概率密度函数 $p_{a_{nj}x_j}$, 再根据 (11) 式对这些求和信号逐一求概率密度函数, 其求解过程如图 1 所示.

噪声 v_n 为加性高斯噪声, 其均值和方差分别记为 0 和 σ_{v_n} , 其概率密度函数如下 [15]:

$$p_{v_n}(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{x^2}{2\sigma^2}\right\}. \quad (12)$$

根据所有加权信号和的概率密度函数 $p_{a_{n1}x_1 a_{n2}x_2 \dots a_{nJ}x_J}$ 、噪声信号的概率密度函数 p_{v_n}

和(11)式, 计算出节点 n 的观测信号的概率密度函数 $p_{a_1x_1a_2x_2\cdots a_nx_nv}$.

$$\begin{array}{c}
 ((\cdots(a_{n1}x_1+a_{n2}x_2+a_{n3}x_3)+\cdots+a_{nj}x_j) \\
 \overline{p_{a_{n1}x_1} \quad p_{a_{n2}x_2}} \\
 \downarrow \qquad \qquad \qquad \downarrow \\
 p_{a_{n1}x_1a_{n2}x_2} \quad p_{a_{n3}x_3} \\
 \downarrow \\
 p_{a_{n1}x_1a_{n2}x_2a_{n3}x_3} \\
 \cdots \\
 \overline{p_{a_{n1}x_1a_{n2}x_2\cdots a_{n(J-1)}x_{(J-1)}} \quad p_{a_jx_J}} \\
 \downarrow \\
 p_{a_{n1}x_1a_{n2}x_2\cdots a_{nj}x_J}
 \end{array}$$

图1 概率密度函数求解过程

有了观测信号的概率密度函数后, 下面给出最优量化器的设计:

设第 n 个节点观测信号的概率密度函数为 $p_n(y)$, 量化电平数 M_{ny} , 有 $M_{ny} = 2M_i$, M_i 为量化的比特位数. 最佳的分层电平和最佳的量化电平分别为 $\{y_l\}$ 和 $\{\bar{y}_l\}$, 为使量化噪声的功率 N_q 最小, 其必要条件^[12,13]为

$$\frac{\partial N_q}{\partial y_l} = 0, \quad l = 1, 2, \dots, M_{nq}, \quad (13)$$

$$\frac{\partial N_q}{\partial \bar{y}_l} = 0, \quad l = 1, 2, \dots, M_{nq}. \quad (14)$$

量化噪声的功率定义为

$$\begin{aligned}
 N_q &= E[e_q^2] = \int_{-\infty}^{\infty} (y - \bar{y}_l)^2 p_n(y) dy \\
 &= \sum_{l=1}^{M_{nq}} \int_{y_{l-1}}^{y_l} (y - \bar{y}_l)^2 p_n(y) dy. \quad (15)
 \end{aligned}$$

将(15)式代入(13)式得

$$\begin{aligned}
 &\frac{\partial}{\partial y_l} \left[\int_{y_{l-1}}^{y_l} (y - \bar{y}_l)^2 p_n(y) dy \right. \\
 &\left. + \int_{y_l}^{y_{l+1}} (y - \bar{y}_{l+1})^2 p_n(y) dy \right] = 0, \quad (16)
 \end{aligned}$$

$$(y_l - \bar{y}_l)^2 p_n(y_l) - (y_{l+1} - \bar{y}_{l+1})^2 p_n(y_{l+1}) = 0. \quad (17)$$

所以最优的分层电平为

$$\begin{aligned}
 y_{l,\text{opt}} &= \frac{1}{2}(\bar{y}_{l,\text{opt}} + \bar{y}_{l+1,\text{opt}}), \\
 l &= 1, 2, \dots, M_{nq} - 1. \quad (18)
 \end{aligned}$$

将(15)式代入(14)式, 同理可求出最优的量化电

平为

$$\bar{y}_{l,\text{opt}} = \frac{\int_{y_{l-1,\text{opt}}}^{y_{l,\text{opt}}} y p_n(y) dy}{\int_{y_{l-1,\text{opt}}}^{y_{l,\text{opt}}} p_n(y) dy}. \quad (19)$$

上述量化过程为: 先设定一组最优量化电平 $\{\bar{y}_l\}^0$, 代入(18)式得到一组最优的分层电平 $\{y_l\}^0$, 将得到的最优分层电平代入(19)式得到一组最优量化电平 $\{\bar{y}_l\}^1$, 如此反复迭代, 当前后两组最优量化电平 $\{\bar{y}_l\}^r$ 和 $\{\bar{y}_l\}^{r+1}$ 之差小于某个预置值, 则迭代结束.

利用方程(18)和(19)的计算结果, 可以进一步求得量化噪声的方差为

$$\begin{aligned}
 \sigma_q^2 &= \sum_{l=1}^{M_{nq}} \int_{y_l}^{y_{l+1}} (x - \bar{y}_l)^2 p_l(x) dx \\
 &\approx \sum_{l=1}^{M_{nq}} \frac{P_l}{\Delta_l} \int_{y_l}^{y_{l+1}} (x - \bar{y}_l)^2 dx \\
 &= \sum_{l=1}^{M_{nq}} \frac{P_l}{\Delta_l} \left[\frac{(y_{l+1} - \bar{y}_l)^3}{3} - \frac{(y_l - \bar{y}_l)^3}{3} \right] \\
 &= \sum_{l=1}^{M_{nq}} \frac{P_l}{\Delta_l} \frac{\Delta_l^3}{12} = \frac{1}{12} \sum_{l=1}^{M_{nq}} P_l \Delta_l^2 \\
 &= \frac{1}{12} \sum_{l=1}^{M_{nq}} p_x(\bar{y}_l) \Delta_l^3, \quad (20)
 \end{aligned}$$

其中, P_l 为输入电平落在第 l 个量化区间的概率, 且

$$\begin{aligned}
 P_l &= P(y_l < x \leq y_{l+1}) \\
 &= p_x(\bar{y}_l)(y_{l+1} - y_l) = p_x(\bar{y}_l) \Delta_l. \quad (21)
 \end{aligned}$$

4 盲分离算法

4.1 状态方程和观测方程

融合中心收集信号并进行盲分离处理, 使用自适应滤波器估计出提取向量 \mathbf{W} , 用提取向量和混合信号的乘积实现源信号的提取.

$$\hat{\mathbf{X}} = \mathbf{WZ}. \quad (22)$$

下面推导分离向量的状态转移方程和测量方程.

混合矩阵 \mathbf{A} 是时不变的, 所以分离向量 \mathbf{w} 也是线性时不变的, 其状态方程为

$$\mathbf{w}_k = \mathbf{w}_{k-1}. \quad (23)$$

假设源信号的产生方程已知, 第 j 个源信号 $x_{j,k}$ 由以下的混沌方程产生

$$x_{j,k} = f(x_{j,k-1}), \quad j = 1, 2, \dots, J, \quad (24)$$

J 是源信号的个数, $f(\cdot)$ 是非线性混沌方程. 提取信号 $\hat{x}_{j,k}$ 是源信号 $x_{j,k}$ 的估计, 满足上面的混沌方程

$$\hat{x}_{j,k} = f(\hat{x}_{j,k-1}), \quad (25)$$

$\hat{x}_{j,k}$ 由分离向量和混合信号相乘得到

$$\hat{x}_{j,k} = \mathbf{w}_{j,k}^T \mathbf{Z}. \quad (26)$$

将 (26) 式代入 (25) 式

$$\mathbf{w}^T \mathbf{Z}(k) = f(\mathbf{w}^T \mathbf{Z}(k-1)), \quad (27)$$

则分离向量的测量方程为

$$\mathbf{w}_k^T \mathbf{Z}(k) - f(\mathbf{w}_k^T \mathbf{Z}(k-1)) + u(k) = 0. \quad (28)$$

4.2 容积卡尔曼粒子滤波盲分离算法

假设第 j 个信号的分离向量为 \mathbf{w}_j , 下面算法流程给出分离向量 \mathbf{w}_j 的迭代求解过程, 为方便书写, 以下对分离向量 \mathbf{w}_j 的书写省略下标 j . 基于分离向量的状态转移方程 (23) 和测量方程 (28), 结合容积卡尔曼粒子滤波的信号盲提取算法流程如下:

4.2.1 初始化

从分离向量的先验分布中选取 N 个粒子 \mathbf{w}_0^i 和粒子对应的误差协方差矩阵的平方根矩阵 \mathbf{S}_0^i ($1 \leq i \leq N$),

$$\bar{\mathbf{w}}_0^i = E[\mathbf{w}_0^i], \quad (29)$$

$$\begin{aligned} \mathbf{S}_0^i &= \text{sqrt}\{\mathbf{P}_0^i\} \\ &= \text{sqrt}\left\{E\left[(\mathbf{w}_0^i - \bar{\mathbf{w}}_0^i)(\mathbf{w}_0^i - \bar{\mathbf{w}}_0^i)^T\right]\right\}, \end{aligned} \quad (30)$$

$E[\cdot]$ 是期望运算, $\text{sqrt}\{\cdot\}$ 平方根运算, \mathbf{P}_0^i 是粒子的协方差, 粒子初始权值为 $\omega_0^i = \frac{1}{N}$.

4.2.2 重要性采样

根据测量值 \mathbf{Z}_k 和容积卡尔曼滤波算法分别更新 N 个分离向量的粒子, 对于粒子 \mathbf{w}_k^i 的更新过程如下:

1) 计算积分点和传播积分点

$$\mathbf{W}_{j,k-1|k-1}^i = \mathbf{S}_{k-1|k-1}^i \zeta_j + \bar{\mathbf{w}}_{k-1|k-1}^i, \quad (31)$$

$$\mathbf{W}_{j,k|k-1}^{i*} = \mathbf{W}_{j,k-1|k-1}^i, \quad (32)$$

其中, $j = 1, 2, \dots, m$, $m = 2n_w$, n_w 是状态向量的维度. $\zeta_j = \sqrt{m/2}[1]_j$.

2) 状态向量及其误差协方差平方根的更新

$$\bar{\mathbf{w}}_{k|k-1}^i = \frac{1}{m} \sum_{j=1}^m \mathbf{W}_{j,k|k-1}^{i*}, \quad (33)$$

$$\begin{aligned} \boldsymbol{\chi}_{k|k-1}^{i*} &= \frac{1}{\sqrt{m}} \left[\mathbf{W}_{1,k|k-1}^{i*} - \bar{\mathbf{w}}_{k|k-1}^i \cdots \mathbf{W}_{m,k|k-1}^{i*} \right. \\ &\quad \left. - \bar{\mathbf{w}}_{k|k-1}^i \right], \end{aligned} \quad (34)$$

$$\mathbf{S}_{k|k-1}^i = \text{qr}\left\{\left[\boldsymbol{\chi}_{k|k-1}^{i*} \sqrt{Q_{k-1}}\right]\right\}, \quad (35)$$

Q_k 为状态转移的协方差矩阵. $\text{qr}\{\cdot\}$ 是 qr 分解运算.

3) 测量积分点, 测量传播积分点和更新测量值

$$\mathbf{W}_{j,k|k-1}^i = \mathbf{S}_{k|k-1}^i \zeta_j + \bar{\mathbf{w}}_{k|k-1}^i, \quad (36)$$

$$\begin{aligned} \mathbf{Y}_{j,k|k-1}^i &= \mathbf{W}_{j,k|k-1}^i \mathbf{Z}(k) \\ &\quad - f\left(\mathbf{W}_{j,k|k-1}^i \mathbf{Z}(k-1)\right), \end{aligned} \quad (37)$$

$$\bar{\mathbf{y}}_{k|k-1}^i = \frac{1}{m} \sum_{j=1}^m \mathbf{Y}_{j,k|k-1}^i. \quad (38)$$

4) 误差协方差矩阵的平方根矩阵和互协方差矩阵

$$\begin{aligned} \boldsymbol{\Psi}_{k|k-1}^i &= \frac{1}{\sqrt{m}} \left[\mathbf{Y}_{1,k|k-1}^i - \bar{\mathbf{y}}_{k|k-1}^i \cdots \right. \\ &\quad \left. - \mathbf{Y}_{m,k|k-1}^i - \bar{\mathbf{y}}_{k|k-1}^i \right], \end{aligned} \quad (39)$$

$$\mathbf{S}_{z,k|k-1}^i = \text{qr}\left\{\left[\boldsymbol{\Psi}_{k|k-1}^i \sqrt{\mathbf{R}_k}\right]\right\}, \quad (40)$$

$$\begin{aligned} \boldsymbol{\chi}_{k|k-1}^i &= \frac{1}{\sqrt{m}} \left[\mathbf{W}_{1,k|k-1}^i - \bar{\mathbf{w}}_{k|k-1}^i \cdots \mathbf{W}_{m,k|k-1}^i \right. \\ &\quad \left. - \bar{\mathbf{w}}_{k|k-1}^i \right], \end{aligned} \quad (41)$$

$$\mathbf{P}_{xz,k|k-1}^i = \boldsymbol{\chi}_{k|k-1}^i \boldsymbol{\Psi}_{k|k-1}^{iT}, \quad (42)$$

\mathbf{R}_k 是测量误差协方差矩阵.

5) 卡尔曼增益, 状态向量预测更新, 协方差更新和粒子的转移概率

$$\mathbf{K}_k^i = \left(\mathbf{P}_{xz,k|k-1}^i / \mathbf{S}_{z,k|k-1}^{iT} \right) / \mathbf{S}_{z,k|k-1}^i, \quad (43)$$

$$\bar{\mathbf{w}}_{k|k}^i = \bar{\mathbf{w}}_{k|k-1}^i + \mathbf{K}_k^i \left(\mathbf{y}_k^i - \bar{\mathbf{y}}_{k|k-1}^i \right), \quad (44)$$

$$\mathbf{S}_{k|k}^i = \text{qr}\left\{\left[\boldsymbol{\chi}_{k|k-1}^i - \mathbf{K}_k^i \boldsymbol{\Psi}_{k|k-1}^{iT} \mathbf{K}_k^i \sqrt{\mathbf{R}_k}\right]\right\}, \quad (45)$$

$$\mathbf{P}(\mathbf{w}_{k+1}^i | \mathbf{w}_k^i) = N\left(\mathbf{w}_{k+1}^i, \bar{\mathbf{w}}_{k|k}^i, \mathbf{P}_{k|k}^i\right), \quad (46)$$

这里 $\mathbf{P}_{k|k}^i = \mathbf{S}_{k|k}^i \mathbf{S}_{k|k}^{iT}$.

4.2.3 权值计算和归一化处理

求粒子 \bar{w}_k^i 的权值 ω_k^i 并做归一化处理.

$$\omega_k^i = \omega_{k-1}^i \frac{p(\mathbf{y}_k | \mathbf{w}_k^i) p(\mathbf{w}_k^i | \mathbf{w}_{k-1}^i)}{q(\mathbf{w}_k^i | \mathbf{w}_{0:k-1}^i, \mathbf{y}_{1:k})}, \quad (47)$$

$$\tilde{\omega}_k^i = \omega_k^i \left[\sum_{j=1}^N \omega_k^j \right]^{-1}. \quad (48)$$

4.2.4 重采样

根据粒子的权重对粒子进行重采样, 舍去权重小的粒子, 复制权重大的粒子, 重新得到 N 个粒子. 对粒子的权重重新设置, $\omega_{k+1}^i = \frac{1}{N}$.

4.2.5 更新状态向量

$$\bar{w}_{k+1} = \sum_{i=1}^N \omega_{k+1}^i \bar{w}_k^{*i}, \quad (49)$$

\bar{w}_j 是估计出来的分离向量, $\bar{s}_j(k) = \bar{w}_j^T \mathbf{Z}(k)$ 是恢复的第 j 个源信号.

4.3 算法分析

容积卡尔曼粒子滤波器在粒子滤波器的框架下, 采用容积卡尔曼滤波算法获得重要性概率密度函数, 每次采样后的粒子由容积卡尔曼滤波算法更新, 更新时融入最新的观察值, 特别是测量值发生突变的时候, 算法能够追踪到最新的观测值, 在一定程度上解决粒子退化问题. 算法获得的重要性概率密度函数更接近状态的后验概率分布, 性能相对基本粒子滤波器有较大的提高.

同时算法相对已有的无先导卡尔曼粒子滤波算法有较少的积分点, 算法的计算量较少. 设信号长度为 N_s , 粒子数量为 N_p , 节点数量为 N , 则根据算法中循环次数估计出算法的计算复杂度, CPF 算法复杂度为

$$\begin{aligned} & O(N_s \times N_p \times (N + 2N + N + 2N)) \\ & = O(N_s \times N_p \times (6N)). \end{aligned} \quad (50)$$

UPF 算法的复杂度为

$$\begin{aligned} & O(N_s \times N_p \times (N + (2N + 1) + N + (2N + 1))) \\ & = O(N_s \times N_p \times (6N + 2)). \end{aligned} \quad (51)$$

两种算法复杂度之比为

$$\rho = \frac{O(N_s \times N_p \times (6N))}{O(N_s \times N_p \times (6N + 2))} = \frac{3N}{3N + 1}. \quad (52)$$

UPF 算法中变量的长度较长, 计算的时候也会增加运算量, 所以实际的算法复杂度比例应该比上面估计的偏小. 在 $N = 3$ 时, $\rho = \frac{3 \times 3}{3 \times 3 + 1} = 90\%$, 下面的仿真测试结果为 88.77%, 和理论分析的结果一致.

5 仿真结果

不失一般性, 我们采用两组混沌信号作为源信号 [16,17], 对混合后的信号做信号盲分离, 信号的产生方程为

$$\begin{aligned} s_1(k) &= 1 - 2s_1^2(k-1), \\ s_2(k) &= \cos(4a \cos(s_2(k-1))), \\ s_3(k) &= s_3^2(k-1) - 2, \\ s_4(k) &= 1 + \sin(\pi s_4(k-1)). \end{aligned} \quad (53)$$

混合系数矩阵随机产生并且满足标准正态分布, 假设网络中所有节点的信噪比和量化位数相同, 粒子数量为 200 个.

为了评价分离算法的性能, 本文采用分离信号和源信号的相关系数 [18] 作为评价指标. 其定义为

$$\zeta = \frac{\left| \sum_{k=1}^{N_s} \hat{s}(k) s(k) \right|}{\sqrt{\sum_{k=1}^{N_s} \hat{s}^2(k) \sum_{k=1}^{N_s} s^2(k)}}, \quad (54)$$

其中 N_s 为信号长度. 由于每次仿真的混合系数矩阵 A 和信号源随机产生, 在同样条件下, 每次的相关系数都会有一些差异, 这里采用同样条件下运行 500 次后取平均值.

图 2 是在节点数 $N = 3$, 量化比特 $M_i = 4$, 信噪比 $\text{SNR} = 15 \text{ dB}$ 条件下, 信号在混合前和分离后的相图比较. 从图 2 可以看出, 分离信号和源信号波形接近, 表明算法能够有效的分离混合的信号.

图 3 是在节点数 $N = 3$, 量化比特 $M_i = 4$, 信噪比 $\text{SNR} = 15 \text{ dB}$ 条件下, 三种分离算法的分离信号和源信号的对比图. 从图 3 可以看到, 在信号变化大的时候, CPF 算法和 UPF 算法都能够有效的跟踪信号, PF(粒子滤波) 算法则不能, 这是因为在重要性采样的时候, 前面两种算法均融入最新的观测信号, 更好的追踪信号的变化. 在相同条件下, CPF 算法比 UPF 算法更贴近源信号.

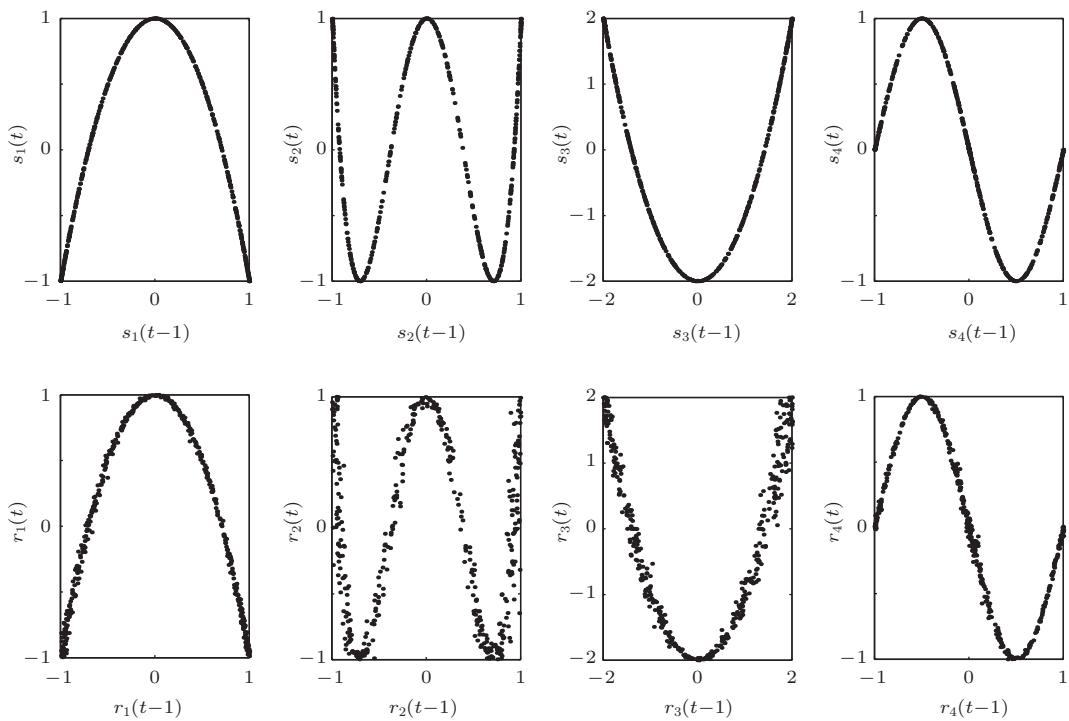


图2 源信号和分离信号的相图

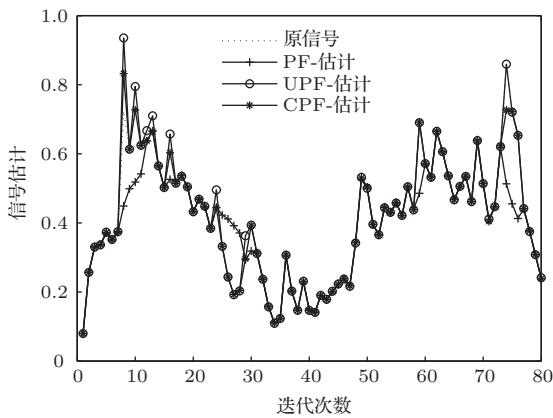


图3 源信号和分离信号局部放大

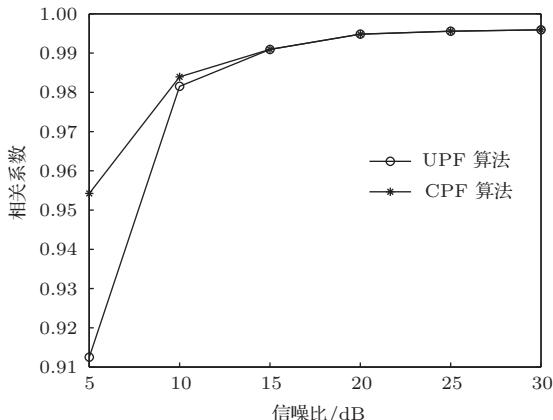


图4 相关系数和信噪比关系

图4是在节点数 $N = 3$ 和量化比特 $M_i = 4$ 条件下, 相关系数和信噪比的关系图. 在图中看到, 两种算法的性能随着信噪比的增大而提高. 在信噪比超过 15 dB 时, 算法性能随着信噪比的增加没有明显提升, 这是因为在信噪比高的时候, 混叠过程对算法性能的影响超过了噪声的影响. 在信噪比较低的条件下, CPF 算法的性能明显优于 UPF 算法.

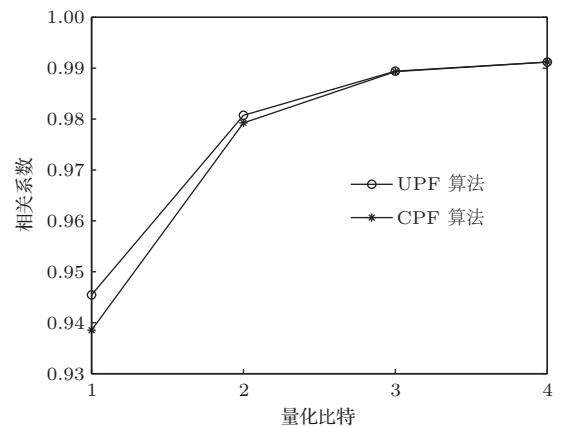


图5 相关系数和量化位数关系

图5是在节点数 $N = 3$ 和信噪比 $\text{SNR} = 15$ dB 条件下, 相关系数和量化比特的关系. 两种算法的性能都随着量化比特的增加而提高. 量化比特的增加可以提高算法的性能, 但同时也增加了节点的

通信量、存储量和计算量, 实际应用中需要折中考虑. 从图 5 看到, 在量化比特较少的情况下, CPF 算法性能较 UPF 算法有明显优势.

图 6 是在量化比特 $M_i = 4$ 和信噪比 $\text{SNR} = 15 \text{ dB}$ 条件下, 相关系数和节点数量的关系. 两种算法性能随着节点数量增加而提高, 但是在节点数量超过 20 时, 算法性能随着节点数量的增加没有明显提升. 节点数量的增加可以提供更多源信号的后验信息, 但是过量的这种后验信息对性能提升没有太多作用. 在节点数量相同情况下, CPF 算法性能优于 UPF 算法.

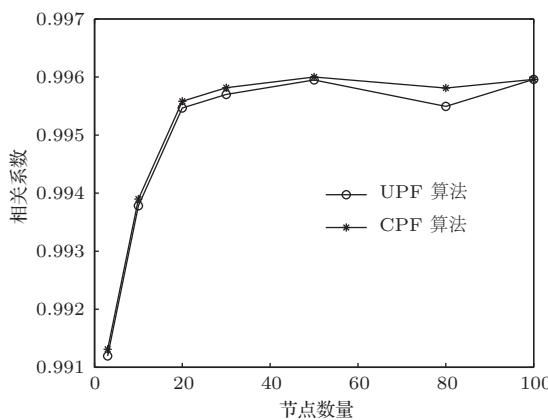


图 6 相关系数和节点数量关系

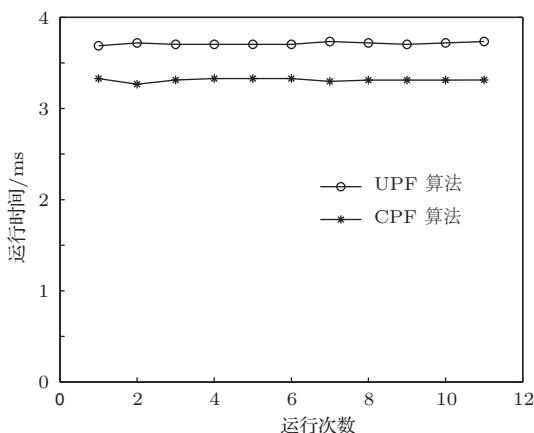


图 7 算法运行时间

图 7 是在节点数 $N = 3$, 量化比特 $M_i = 4$ 和信噪比 $\text{SNR} = 15 \text{ dB}$ 条件下, UPF 算法和 CPF 算法的运行时间为 3.7449 ms 和 3.3242 ms, 由于 CPF 算法做粒子的重要性概率密度函数时, 使用的积分点比 UPF 算法少, 计算量也少, 运行时间为 UPF 算法的 88.77%, 结果和前面的运算复杂度分析一致.

6 结 论

本文针对非线性和非高斯的信号盲分离系统, 结合容积卡尔曼滤波器和粒子滤波器, 提出一个新的基于容积卡尔曼粒子滤波的信号盲分离算法. 本文在推导出观测信号的概率密度函数基础上, 使用最优量化器量化观测信号, 在量化比特数有限的条件下获取最优的量化结果. 算法的优点在于使用容积卡尔曼滤波器来计算粒子滤波器中的重要性概率密度函数, 通过融入最新的测量值, 提高了粒子对状态后验概率的逼近程度, 特别是测量值发生较大变化的情况下, 有效提升算法的估计精度. 仿真结果表明算法能够实时有效的分离混合混沌信号, 在估计精度上优于无先导粒子滤波器, 同时算法使用较少的积分点, 降低了算法的运算量, 算法运行时间为无先导粒子滤波器的 88.77%.

参考文献

- Pantazis N A, Nikolidakis S A, Vergados D D 2013 *IEEE Communications Surveys and Tutorials* **15** 551
- Qi H, Wang F B, Deng H 2013 *Acta Phys. Sin.* **62** 104301 (in Chinese)[祁浩, 王福豹, 邓宏 2013 物理学报 **62** 104301]
- Li X X, Feng J C 2007 *Acta Phys. Sin.* **56** 701 (in Chinese)[李雪霞, 冯久超 2007 物理学报 **56** 701]
- Malouche Z, Macchi O 1998 *IEEE Transactions on Neural Networks* **9** 123
- Wang S Y, Feng J C 2012 *Acta Phys. Sin.* **61** 170508 (in Chinese)[王世元, 冯久超 2012 物理学报 **61** 170508]
- Hu Z H, Feng J C 2010 *Journal of Southwest University (Natural Science)* **32** 146 (in Chinese) [胡志辉, 冯久超 2010 西南大学学报(自然科学版) **32** 146]
- Lee S H, West M 2013 *IEEE Transactions on Signal Processing* **61** 801
- Arasaratnam I, Haykin S 2009 *IEEE Transactions on Automatic Control* **54** 1254
- Jia B, Xin M, Cheng Y 2012 *Proceedings of the IEEE Conference on Decision and Control* Maui, HI, December 10–13, 2012 p4095
- Mohammadi A, Asif A 2011 *IEEE Workshop on Statistical Signal Processing Proceedings* Nice, France, June 28–30, 2011 p237
- Cong L, Qin H L 2011 *Chinese Journal of Electronics* **20** 755
- Yu X, Wang H Q, Yang E H 2010 *IEEE Transactions on Information Theory* **56** 5796
- Bianchi P, Jakubowicz J 2013 *IEEE Transactions on Signal Processing* **61** 3119
- Falsone G, Settimeri D 2013 *Probabilistic Engineering Mechanics* **33** 79

- [15] Maaref A, Aïssa S 2009 *IEEE Transactions on Communications* **57** 214
- [16] Wang J H 2012 *Chaos, Solitons and Fractals* **45** 1140
- [17] Persohn K J, Povinelli R J 2012 *Chaos, Solitons and Fractals* **45** 238
- [18] Farina D, Févotte C, Doncarli C, Merletti R 2004 *IEEE Transactions on Biomedical Engineering* **51** 1555

Blind source separation of chaotic signals in wireless sensor networks*

Huang Jin-Wang Feng Jiu-Chao[†] Lü Shan-Xiang

(School of Electronic and Information engineering, South China University of Technology, Guangzhou 510641, China)

(Received 16 September 2013; revised manuscript received 21 October 2013)

Abstract

Chaotic signal is essentially a nonlinear and non-Gaussian signal, which involves signal quantization when used in wireless sensor networks (WSNs). It makes the blind source separation of chaotic signal in WSNs more difficult to address. To solve the problem, we propose a new source separation algorithm based on cubature Kalman particle filter (CPF) in this paper. First the probability density function of the observed signal is derived and the optimal quantization is used; this can achieve the optimal quantization of signal under the limited budget of quantization bits. After that, the algorithm uses cubature Kalman filter (CKF) to generate the important proposal distribution of the particle filter (PF), integrating the latest observation and improving the approximation to the system posterior distribution, which will improve the performance of the signal separation. Simulation results show that the algorithm can separate mixed chaotic signal effectively, it is superior over the unscented Kalman particle filter (UPF) counterpart in accuracy and computation overhead. The running time is 88.77% compared to the UPF counterpart.

Keywords: chaotic signal, blind source separation, WSNs, particle filter

PACS: 05.45.-a, 05.45.Vx, 84.40.Ua

DOI: 10.7498/aps.63.050502

* Project supported by the National Natural Science Foundation of China (Grant Nos. 60872123, 61101014), the Joint Fund of the National Natural Science Foundation and the Natural Science Foundation of Guangdong Provincial, China (Grant No. U0835001), the Fund for Higher-level Talent in Guangdong Province (Grant No. N9101070), and the Fundamental Research Funds for the Central Universities of China (Grant No. 2012ZM0025).

† Corresponding author. E-mail: fengjc@scut.edu.cn