

## 一种基于概率密度传播的目标跟踪算法

高庆华 金明录 王洁 王洪玉  
(大连理工大学电子与信息工程学院 大连 116023)

**摘要:** 该文提出一种解决非线性、非高斯条件下目标跟踪问题的新方法,在贝叶斯框架下通过连续概率密度传播实现目标跟踪。采用高斯混合模型表征目标先验分布、后验分布及观察似然函数,利用无迹变换实现目标位置的非线性预测,通过拟合方法获得后验分布,同时,将后验分布各模式的加权质心作为目标的位置估计。仿真结果表明,该算法可以很好地解决大噪声环境下基于无线传感器网络的目标跟踪问题。

**关键词:** 无线传感器网络;跟踪;概率密度传播;贝叶斯估计

**中图分类号:** TP393; TP391

**文献标识码:** A

**文章编号:** 1009-5896(2010)10-2410-05

**DOI:** 10.3724/SP.J.1146.2009.01404

## A Tracking Algorithm Based on Probability Density Propagation

Gao Qing-hua Jin Ming-lu Wang Jie Wang Hong-yu

(School of Electronics and Information Engineering, Dalian University of Technology, Dalian 116023, China)

**Abstract:** A tracking algorithm based on probability density propagation which can deal with non-linear and non-Gaussian issues is proposed. The Gaussian mixture model is adopted to represent the prior density distribution, posterior density distribution and likelihood distribution. The unscented transformation is used to deal with the non-linear prediction and approximation method is used to achieve the posterior density distribution. Finally, the weighted centroid point of the posterior density distribution's different modes is calculated and set as the current position of the target. Simulation results indicate that the proposed algorithm can deal with the tracking task in wireless sensor network under strong noise.

**Key words:** Wireless sensor network; Tracking; Probability density propagation; Bayesian estimation

### 1 引言

目标跟踪问题是 WSN(Wireless Sensor Network)领域的研究热点。有效的目标跟踪是无线传感器网络在战场信息监测、生活习性监测、室内定位等众多领域得以应用的基础。目标跟踪算法整体上分为两大类:一类是概率方法,将跟踪问题转化为状态估计问题,采用贝叶斯估计、极大似然估计等方法处理问题;另一类是数值方法,将跟踪问题看作优化问题,采用求极值的方法处理问题。在目标运动轨迹没有规律、系统噪声和观测噪声较复杂的情况下,基于概率的方法通常具有较强的鲁棒性和较优的跟踪精度。

近年来,PF(Particle Filter)算法被提出并用来解决非线性、非高斯环境下的目标跟踪问题。PF 算法理论上基于后验分布进行采样,实际应用中很难实现对后验分布直接采样,因此通常基于先验分布

采样,然后利用似然函数进行加权,这样处理造成当前时刻的观测信息在采样中没有发挥作用,当先验分布与似然函数偏差较大时,会造成绝大多数粒子权值趋近于零的退化现象发生,文献[1]证明随着时间的推移这种退化必然发生。一种直观的克服该问题的方法是增加粒子数目,但这样势必造成计算量的增加。重采样可以在一定程度上缓解该问题,但会造成粒子多样性降低,易发生粒子耗尽、贫化问题。Doucet 提出采用扩展卡尔曼滤波算法对每个粒子进行预测;文献[2-4]等人提出基于无迹卡尔曼滤波算法对每个粒子进行预测;文献[5,6]提出采用高斯函数对粒子进行平滑处理;文献[7]等提出利用观测到的参考节点信息对预测粒子进行 mean-shift 偏移;文献[8]提出利用参考节点信息构建目标可能出现区域的方法对粒子采样区域进行限制;上述算法优化了提议分布,使先验分布与似然函数的交集变大,一定程度上克服了粒子退化问题,但是,这类算法本质上仍然需要对概率密度分布进行采样,不能彻底摆脱粒子退化、贫化的问题。文献[9]提出一种采用连续函数表征目标分布的算法实现人脸跟

2009-10-29 收到, 2010-05-25 改回

国家自然科学基金(60871046)资助课题

通信作者: 高庆华 qhgao@dlut.edu.cn

踪,有效地克服了 PF 算法采样困难的问题,但是该算法通过多次采样、拟合获得似然函数,需要计算大量 Hessian 矩阵、求逆矩阵等复杂操作,不适用于 WSN。

针对上述问题,本文提出一种贝叶斯框架下的概率密度传播跟踪算法 PDPA(Probability Density Propagation Algorithm),采用高斯混合模型来表征目标概率分布,通过对连续函数的一系列操作实现目标跟踪,解决了大噪声、非线性、非高斯环境下基于 WSN 的目标跟踪问题。

## 2 系统模型

PDPA 算法基于贝叶斯框架,采用状态空间模型来表述 WSN 跟踪问题,令目标的状态变量序列为  $\{x_t, t=1, \dots, N\}$ , 观测变量序列为  $\{z_t, t=1, \dots, N\}$ , 则有

$$x_t = F(x_{t-1}) + w_t \quad (1)$$

$$z_t = H(x_t) + v_t \quad (2)$$

这里  $F$  为状态预测函数,  $H$  为状态观测函数,  $w_t$  为过程噪声,  $v_t$  为观测噪声。

在预测方程和观测方程的作用下,状态分布先验概率密度函数  $p(x_t | z_{1, \dots, t-1})$  和后验概率密度函数  $p(x_t | z_{1, \dots, t})$  按式(3), 式(4)进行状态预测和更新:

$$p(x_t | z_{1, \dots, t-1}) = \int p(x_{t-1} | z_{1, \dots, t-1}) p(x_t | x_{t-1}) dx_{t-1} \quad (3)$$

$$p(x_t | z_{1, \dots, t}) = \frac{p(z_t | x_t) p(x_t | z_{1, \dots, t-1})}{\int p(z_t | x_t) p(x_t | z_{1, \dots, t-1}) dx_t} \quad (4)$$

状态转移概率函数  $p(x_t | x_{t-1})$  由式(1)确定, 观察似然概率函数  $p(z_t | x_t)$  由式(2)确定。

GMM(Gaussian Mixture Model)具有近似表示任意概率分布的能力,文献[10, 11]对此作了详细研究,本文亦采用 GMM 来表示概率分布函数  $p(x_t | z_{1, \dots, t-1})$ ,  $p(x_t | z_{1, \dots, t})$  及  $p(z_t | x_t)$ , 如式(5)所示。

$$p(x) = \sum_{m=1}^c \lambda^m N(x | \mu^m, \Sigma^m) \quad (5)$$

这里  $c$  为高斯核个数,  $\lambda^m$  为第  $m$  个核的权值,  $\mu^m$  为其均值,  $\Sigma^m$  为其方差, 高斯函数  $N(x | \mu, \Sigma)$  定义为

$$N(x | \mu, \Sigma) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \cdot \exp\left[-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right] \quad (6)$$

这里  $d$  为变量  $x$  的维数, 文中 T 代表转置。

## 3 概率密度传播跟踪算法

PDPA 算法采用 GMM 表征先验分布、似然函数、后验分布,有效地克服了 PF 算法退化、贫化、采样效率低的问题,同时,具有处理非线性、非高

斯问题的能力。整个算法基于贝叶斯框架,分为预测、似然函数构建、后验分布计算、目标位置确定 4 部分。

### 3.1 预测

算法基于上一时刻的后验分布  $p(x_{t-1} | z_{1, \dots, t-1})$  进行预测,通过 UT(Unscented Transform)变换<sup>[2]</sup>对 GMM 中每个高斯函数  $N(x | \mu^m, \Sigma^m)$  进行采样,如式(7)所示。

$$\left. \begin{aligned} \chi_{t-1}^{m,0} &= \mu^m, & W_{t-1}^{m,0} &= \beta/(d + \beta), \\ \chi_{t-1}^{m,i} &= \mu^m + ((d + \beta)\Sigma^m)_i^{1/2}, & W_{t-1}^{m,i} &= 1/2(d + \beta), \\ & & & i = 1, \dots, d \\ \chi_{t-1}^{m,i} &= \mu^m - ((d + \beta)\Sigma^m)_{i-d}^{1/2}, & W_{t-1}^{m,i} &= 1/2(d + \beta), \\ & & & i = d + 1, \dots, 2d \end{aligned} \right\} \quad (7)$$

这里  $\chi_{t-1}^{m,i}$  为采样样本位置,  $W_{t-1}^{m,i}$  为其权值,  $\beta$  为尺度调节变量,  $((d + \beta)\Sigma^m)_i^{1/2}$  为矩阵  $(d + \beta)\Sigma^m$  第  $i$  行或列的开平方。将这些样本代入运动方程实现状态预测,如式(8)所示。

$$\chi_t^{m,i} = F(\chi_{t-1}^{m,i}) \quad (8)$$

更新后的均值  $\bar{\mu}^m$  和方差  $\bar{\Sigma}^m$  为

$$\left. \begin{aligned} \bar{\mu}^m &= \sum_{i=0}^{2d} W_{t-1}^{m,i} \chi_t^{m,i} \\ \bar{\Sigma}^m &= \sum_{i=0}^{2d} W_{t-1}^{m,i} (\chi_t^{m,i} - \bar{\mu}^m)(\chi_t^{m,i} - \bar{\mu}^m)^T + \Sigma_w \end{aligned} \right\} \quad (9)$$

这里  $\Sigma_w$  用于补偿运动噪声。对 GMM 中每个高斯函数均进行 UT 变换,获得的先验分布如式(10)所示

$$\bar{p}(x) = \sum_{m=1}^{c1} \lambda^m N(x | \bar{\mu}^m, \bar{\Sigma}^m) \quad (10)$$

### 3.2 似然函数构建

目标可以通过 RSSI(Received Signal Strength Indicator), TDOA(Time Difference of Arrival), TOF(Time of Flight)等多种技术手段获取自身与参考节点的距离估计;然后,根据几何约束关系估算目标可能出现的区域;最后,结合观测噪声,建立 GMM 模型用来表征似然函数。由物理信号获取距离信息时可采取中值滤波措施减小噪声的影响。

当目标探测到的参考节点个数  $k \geq 2$  时,假设获得的参考节点位置、距离信息集合为  $\{(x_1, y_1, d_1), (x_2, y_2, d_2), \dots, (x_k, y_k, d_k)\}$ ,  $(x_i, y_i)$  为参考节点  $i$  的位置,  $d_i$  为其与目标的距离,任意两个参考节点  $\{i, j | i \in (1, \dots, k), j \in (1, \dots, k), i \neq j\}$  之间的距离  $d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$ , 如果满足约束条件  $(d_i + d_j > d_{ij}) \cup (d_i + d_j > d_j) \cup (d_j + d_j > d_i)$ , 则求解以  $(x_i, y_i)$  为圆心  $d_i$  为半径的圆与以  $(x_j, y_j)$  为圆心  $d_j$  为半径的圆的交点,将求得的交点作为 GMM 模型的

均值, 观测噪声的方差作为 GMM 模型的方差, 权值为交点总个数的倒数。

当目标探测到的参考节点个数  $k=1$  时, 则以  $(x_1 + d_1, y_1)$ ,  $(x_1 - d_1, y_1)$ ,  $(x_1, y_1 + d_1)$ ,  $(x_1, y_1 - d_1)$ ,  $(x_1 + 0.7d_1, y_1 + 0.7d_1)$ ,  $(x_1 + 0.7d_1, y_1 - 0.7d_1)$ ,  $(x_1 - 0.7d_1, y_1 + 0.7d_1)$ ,  $(x_1 - 0.7d_1, y_1 - 0.7d_1)$  作为 GMM 模型的均值, 观测噪声的方差作为 GMM 模型的方差, 权值为  $1/8$ 。

当未收到参考节点信息时, 令似然函数为常数 1。

### 3.3 后验分布计算

后验分布函数为先验分布函数与似然函数的乘积, 如式(11)所示

$$\left( \sum_{m=1}^{c1} \lambda^m N(\bar{\mu}^m, \bar{\Sigma}^m) \right) \left( \sum_{n=1}^{c2} \lambda^n N(\mu^n, \Sigma^n) \right) = \sum_{m=1}^{c1} \sum_{n=1}^{c2} \lambda^{mn} N(\mu^{mn}, \Sigma^{mn}) \quad (11)$$

这里  $c1$  为先验分布核个数,  $c2$  为似然函数核个数, 相乘得到核个数为  $c1 \times c2$  的 GMM 函数, 新 GMM 参数如下

$$\lambda^{mn} =$$

$$\frac{\lambda^m \lambda^n \exp\left(-\frac{1}{2}(\bar{\mu}^m - \mu^n)^T (\bar{\Sigma}^m + \Sigma^n)^{-1} (\bar{\mu}^m - \mu^n)\right)}{(2\pi)^{d/2} |\bar{\Sigma}^m + \Sigma^n|^{1/2}} \quad (12)$$

$$\Sigma^{mn} = \left( (\bar{\Sigma}^m)^{-1} + (\Sigma^n)^{-1} \right)^{-1} \quad (13)$$

$$\mu^{mn} = \Sigma^{mn} \left( (\bar{\Sigma}^m)^{-1} \bar{\mu}^m + (\Sigma^n)^{-1} \mu^n \right) \quad (14)$$

新的 GMM 函数综合了先验信息以及当前时刻的观测信息, 代表了目标的后验分布信息。但是, 直接将该函数作为后验分布势必造成 GMM 函数中核个数随时间不断增加, 导致算法计算量灾难性增长。本文采用以下 3 种方法对新 GMM 函数进行拟合处理, 以确保后验分布核个数的恒定。

**方法 1** 基于核系数选择 直接选择模型中系数最大的  $c1$  个核构成新的 GMM 函数。

**方法 2** EM 拟合 首先, 对  $c1 \times c2$  个样本点  $\mu^{mn}$  进行重采样, 各样本点被选择的概率正比于  $\lambda^{mn} |\Sigma^{mn}|^{-1}$ , 重采样获得样本集  $\{s_i, i=1, \dots, N\}$ , 通常令样本个数  $N=10 \times c1 \times c2$ 。然后, 采用 EM 算法对这些样本点的分布进行拟合处理, 转化为具有  $c1$  个核的 GMM 函数, EM 算法分为 E-step 和 M-step 两个步骤。

E-step:

$$r_k^{ij} = \frac{\lambda_{k-1}^j N(s_i | \mu_{k-1}^j, \Sigma_{k-1}^j)}{\sum_{j=1}^{c1} \lambda_{k-1}^j N(s_i | \mu_{k-1}^j, \Sigma_{k-1}^j)} \quad (15)$$

M-step:

$$\lambda_k^j = \frac{1}{N} \sum_{i=1}^N r_k^{ij}, \quad \mu_k^j = \frac{\sum_{i=1}^N r_k^{ij} s_i}{\sum_{i=1}^N r_k^{ij}}, \quad (16)$$

$$\Sigma_k^j = \frac{\sum_{i=1}^N r_k^{ij} (s_i - \mu_k^j)(s_i - \mu_k^j)^T}{\sum_{i=1}^N r_k^{ij}}$$

EM 算法初始条件为  $\lambda_0^j = 1/c1$ ,  $\mu_0^j$  从样本中随机选取,  $\Sigma_0^j$  为单位矩阵。EM 算法循环执行几次后收敛, 此时的参数即可作为后验分布 GMM 函数的参数。

**方法 3** K-mean 拟合 与 EM 算法相比, K-mean 算法具有简单、计算量小的优点。算法首先从  $c1 \times c2$  个权值为  $\lambda^{mn} |\Sigma^{mn}|^{-1}$  的样本点  $\mu^{mn}$  中随机选取  $c1$  个点作为聚类中心, 然后, 根据各样本点与各聚类中心的欧式空间距离对样本点分类, 计算各类样本点的加权质心作为新的聚类中心。此过程进行多次后收敛, 此时聚类样本的聚类中心、方差、样本个数占总样本个数的比例即为 GMM 模型中的均值、方差与权值。

拟合处理后的后验分布 GMM 函数为

$$\hat{p}(x) = \sum_{m=1}^{c1} \hat{\lambda}^m N(x | \hat{\mu}^m, \hat{\Sigma}^m) \quad (17)$$

### 3.4 目标位置确定

PDPA 算法将后验分布  $\hat{p}(x)$  各高斯核均值的加权质心作为当前时刻的目标位置, 如式(18)所示

$$(\hat{x}, \hat{y}) = \frac{\sum_{m=1}^{c1} \omega_m \hat{\mu}^m}{\sum_{n=1}^{c1} \omega_n} \quad (18)$$

其中  $\omega_m = \hat{\lambda}^m |\hat{\Sigma}^m|^{-1}$ 。

整个 PDPA 算法遵循贝叶斯框架, 基于上一时刻的后验分布进行预测, 获取当前时刻的似然函数, 然后求解当前时刻的后验分布, 同时, 计算后验分布中各模式的加权质心并将其作为当前时刻的位置。算法初始时刻直接将似然函数确定的位置作为其估计位置。

## 4 性能仿真与分析

### 4.1 仿真模型与环境

实验中目标基于 CV/CT 混合模型运动, 具体模型参见文献[12]。运动噪声与观察噪声均为对称双

峰非高斯噪声，运动噪声模型为  $w_1N(\mu_1, \Sigma_1) + (1 - w_1)N(-\mu_1, \Sigma_1)$ ，运动噪声均值默认为  $\mu_1 = 1$ ，方差  $\Sigma_1 = 1$ ，系数  $w_1 \in [0.2, 0.8]$ ；观察噪声模型为  $w_2N(\mu_2, \Sigma_2) + (1 - w_2)N(-\mu_2, \Sigma_2)$ ，观察噪声均值默认为  $\mu_2 = 20$ ，方差  $\Sigma_2 = 20$ ，系数  $w_2 \in [0.2, 0.8]$ 。其它默认仿真参数如表 1 所示。

表 1 仿真参数

仿真参数	参数描述
观测噪声均值及方差	$\pm 20, 20$
运动噪声均值及方差	$\pm 1, 1$
运动速率	50 m/s
角速度	$30^\circ / s$
理想观测范围	100 m
PF 算法粒子规模	500
参考节点布置及密度	均匀分布，间距 200 m
拟合方法	基于核系数选择
GMM 核个数	8
采样时间间隔	1 s

将 PDPA 算法分别与经典 PF 算法，ML (Maximum Likelihood)算法进行对比分析。误差定义为估计位置与真实位置的均方误差，实验结果均为 100 次实验的均值。

### 4.2 跟踪效果分析

3 种算法跟踪效果如图 1 所示，理想轨迹为椭圆形，右下角处受噪声影响轨迹发生突变，PF 算法在轨迹突变处跟踪误差加大，而 PDPA 算法表现出较好的跟踪能力，证明其克服了 PF 算法在先验分布与似然分布差别较大时产生的退化现象，同时，PDPA 算法克服了 ML 算法跟踪轨迹跳变、不稳定的问题。

### 4.3 环境适应能力分析

3 种算法随运动噪声均值变化效果如图 2 所示，随着运动噪声的加大，真实轨迹与理想轨迹偏差加大，致使先验分布与似然函数交集变小，造成 PF




图 1 跟踪效果图

算法出现退化现象；ML 算法最大误差较大，定位性能变化严重。PDPA 算法在均值误差、最大误差方面均表现出良好性能。

从图 3 可以看出，随着观测噪声的增加，ML 算法误差显著增加，PDPA 算法误差缓慢增加，在观测噪声方差小于 60 时 PDPA 性能优于 PF 算法，表明 PDPA 算法对观测噪声具有较好的适应能力。

参考节点间距的变化造成目标可获得的有效观测信息量发生变化，从而影响跟踪精度。图 4 显示出 ML 算法性能随间距变化较剧烈，而 PDPA 算法与 PF 算法对间距变化不是很敏感，表现出较好的密度适应性。

### 4.4 性能分析

PDPA 算法与 PF 算法、ML 算法性能对比如表 2 所示，总体来说 PDPA 算法适合在运动噪声与观察噪声均较大、参考节点分布不均匀的条件下工作，且算法跟踪效果波动较小。

表 2 算法性能比较

算法	运动噪声	观察噪声	参考节点密度	性能波动
PDPA	优	中	优	小
PF	差	优	优	小
ML	优	差	差	大

3.3 节中 3 种拟合方法性能对比如表 3 所示。通常情况下，在 WSN 应用中核系数最大的几个核函数基本上代表了后验分布的特征，基于核系数选择的方法即可满足性能要求。


表 3 拟合方法性能比较

方法	平均误差(m)	最大误差(m)	计算量
基于核系数选择	40.3	89.8	小
EM 算法	35.5	77.2	大
K-mean 算法	37.6	85.5	适中


用于表征概率分布的 GMM 函数核个数通常根据具体的应用环境采用实验的方法来确定，Ding 在文献[11]中介绍了 AIC 与 BIC 两种核个数确定准则，亦可采用这些准则确定核个数。核个数过少会造成有用信息的丢失，同时，过多的核个数也会使一些虚假信息得到传播，GMM 核个数要与噪声的多峰值特征相匹配。

## 5 结束语

PDPA 算法本质上是一种基于 GMM 模型表征的连续函数实现贝叶斯估计的跟踪算法，解决了 PF




(a) 平均误差




(b) 最大误差

图 2 误差随运动噪声均值变化




(a) 平均误差




(b) 最大误差

图 3 误差随观测噪声均值变化



(a) 平均误差



(b) 最大误差

图 4 误差随参考节点间距离变化

算法采样困难的问题, 实现了大噪声、非线性、非高斯环境下的目标跟踪。实验结果表明, PDPA 算法适用于不同参考节点密度场合, 且能在运动与观测模型噪声较大的恶劣条件下工作, 是一种适用于 WSN 的健壮跟踪算法。进一步的研究方向为 PDPA 算法收敛性的证明及将该算法应用到复杂参数估计等问题中。

**致谢** 感谢罗海勇博士和 Ding Min 博士在相关算法方面的探讨。

### 参考文献

- [1] Doucet A, Godsill S, and Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. *Statistics and Computing*, 2000, 10(3): 197-208.
- [2] Merwe R, Doucet A, and Freitas N, *et al.* The unscented particle filter[C]. 14th Annual Neural Information Processing Systems Conference, Denver, Colorado, USA, Nov.27-Dec.2, 2000: 584-590.
- [3] Rui Yong and Chen Yun-qiang. Better proposal distributions: object tracking using unscented particle filter[C]. *Proceeding of the Conference on Computer Vision and Pattern Recognition*, Hawaii, USA, Dec.9-14, 2001: 786-793.
- [4] Cheng Qi and Bondon P. A new unscented particle filter[C]. *International Conference on Acoustics, Speech and Signal Processing*, Las Vegas, Nevada, USA, March 30-April 4, 2008: 3417-3420.
- [5] Kotecha J H and Djuric P M. Gaussian sum particle filtering[J]. *IEEE Transactions on Signal Processing*, 2003, 51(10): 2602-2612.
- [6] Kotecha J H and Djuric P M. Gaussian particle filtering[J]. *IEEE Transactions on Signal Processing*, 2003, 51(10): 2592-2601.
- [7] Luo Hai-yong, Li Jin-tao, and Zhao Fang, *et al.* Mobile target

localization based on mean shift in wireless sensor networks[C]. *Third International Conference on Pervasive Computing and Applications*, Alexandria, Egypt, October 6-8, 2008: 248-253.

- [8] Baggio A and Langendoen K. Monte Carlo localization for mobile wireless sensor networks[J]. *Ad hoc Networks*, 2008, 6(5): 718-733.
- [9] Han Bohyung, Zhu Ying, and Comaniciu D, *et al.* Visual tracking by continuous density propagation in sequential Bayesian filtering framework[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(5): 919-930.
- [10] Sheng Xiao-hong, Hu Yu-hen, and Ramanathan P. Distributed particle filter with GMM approximation for multiple targets localization and tracking in wireless sensor network[C]. *Fourth International Symposium on Information Processing in Sensor Networks*, Los Angeles, California, USA, April 25-27, 2005: 181-188.
- [11] Ding Min and Cheng Xiu-zhen. Fault tolerant target tracking in sensor networks[C]. *Proceedings of the 10th ACM International Symposium on Mobile Ad hoc Networking and Computing*, New Orleans, LA, USA, May 18-21, 2009: 125-134.
- [12] Yuan Xiang-hui, Han Chong-zhao, and Duan Zhan-sheng, *et al.* Comparison and choice of models in tracking target with coordinated turn motion[C]. *IEEE 8th International Conference on Information Fusion*, Philadelphia, PA, USA, July 25-28, 2005, 2: 1497-1502.

高庆华: 女, 1980 年生, 博士生, 研究方向为无线传感器网络、认知无线电等。

金明录: 男, 1958 年生, 教授, 博士生导师, 研究方向为无线传感器网络、信号处理快速算法等。

王 洁: 男, 1981 年生, 博士生, 研究方向为无线传感器网络、RFID、移动自组织网络等。