

## 基于贝叶斯压缩感知的认知 W SN 数据融合策略

许晓荣<sup>1,3</sup>, 黄爱苹<sup>1,2</sup>, 章坚武<sup>3</sup>

(1. 浙江大学 浙江省综合信息网技术重点实验室, 浙江 杭州 310027;

2. 浙江大学 信息与通信工程研究所, 浙江 杭州 310027; 3. 杭州电子科技大学 通信工程学院, 浙江 杭州 310018)

**摘要:** 将贝叶斯压缩感知 (BCS) 应用于大规模认知无线传感器网络 (C-W SN) 中的汇聚节点数据融合, 提出了一种稀疏贝叶斯估计方法。根据大量认知节点对实际非平稳信号的空时相关性结构, 汇聚节点基于层次化贝叶斯分析模型的压缩感知方法进行数据融合, 以较大概率重构出多个认知节点的感知信息。仿真结果表明, 与基于贪婪算法的正交匹配追踪 (OMP) 相比, 基于 BCS 的数据融合具有较低的重构均方误差 (MSE), 且利用感知数据的时空相关性, 在较小的压缩比下即可实现快速收敛。所提策略可适用于大规模认知 W SN 汇聚节点端的数据稀疏重构。

**关键词:** 贝叶斯压缩感知; 认知无线传感器网络; 数据融合; 层次化贝叶斯分析模型; 稀疏重构

**中图分类号:** TN 911.7

**文献标识码:** A

**文章编号:** 1000-436X (2011)9A-0220-06

## Novel data fusion strategy based on Bayesian compressive sensing in cognitive W SN

XU Xiao-rong<sup>1,3</sup>, HUANG Ai-ping<sup>1,2</sup>, ZHANG Jian-wu<sup>3</sup>

(1. Zhejiang Provincial Key Laboratory of Information Network Technology, Zhejiang University, Hangzhou 310027, China;

2. Institute of Information and Communication Engineering, Zhejiang University, Hangzhou 310027, China;

3. College of Telecommunication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China)

**Abstract:** Bayesian compressive sensing (BCS) theory is investigated in the data fusion process for large-scale cognitive wireless sensor network (C-W SN). A sparse Bayesian estimation method was proposed, which was based on the spatial-temporal correlation structure of real non-stationary signals collected by massive cognitive sensor nodes. Data fusion strategy is implemented by hierarchical Bayesian analysis model compressive sensing method, with higher probability of reconstruction of original sensing signals. Simulation results indicate that, compared with orthogonal matched pursuit (OMP) which is based on greedy algorithm, the proposed BCS data fusion scheme has lower mean-square errors (MSE) in data reconstruction process, and fast convergence could be realized in lower compression rate which utilizes spatial-temporal correlation. This scheme provides the effectiveness of our approach and proves that it is suitable for sparse reconstruction in large-scale cognitive W SN.

**Key words:** Bayesian compressive sensing (BCS); cognitive W SN; data fusion; hierarchical Bayesian analysis model; sparse reconstruction

**收稿日期:** 2011-07-05

**基金项目:** 国家自然科学基金资助项目 (61102066、60972058); 中国博士后科学基金资助项目“认知无线网络中多用户资源分配与协作传输关键技术研究”; 浙江省综合信息网技术重点实验室开放课题 (201112); 浙江省教育厅科研基金资助项目 (Y201119890); 杭州电子科技大学青年教师科研启动基金资助项目 (KYS085610034)

**Foundation Items:** The National Natural Science Foundation of China (61102066, 60972058); China Postdoctoral Science Foundation Entitled Research on Key Technologies of Multi-user Resource Allocation and Cooperative Transmission in Cognitive Radio Networks; Open Project of Zhejiang Provincial Key Laboratory of Information Network Technology (201112); Scientific Research Project of Zhejiang Provincial Education Department (Y201119890); Young Staff Startup Research Foundation of Hangzhou Dianzi University (KYS085610034)

### 1 引言

认知无线传感器网络 (C-W SN, cognitive wireless sensor network) 包含大量具有认知功能的传感器节点, 节点能耗受限且数量众多, 多个节点通过分布式组网对周围环境中特定的参数信息进行感知、传输和处理<sup>[1,2]</sup>。在大规模认知 W SN 中, 节点机会地利用主用户 (PU, primary user) 频谱将本地感知信息发送到汇聚节点 (sink) 进行数据融合, sink 对多个认知节点的感知信息进行重构。然而, 大量节点在对同一目标进行感知的过程中, 在感知时间上存在着冗余<sup>[3]</sup>。此外, 节点分布位置的不同也带来了感知数据空间上的相关性<sup>[4]</sup>。在节点能耗和网络带宽受限的条件下, 如何高效地利用节点感知数据的时空相关性, 以高能效方式对感知数据进行融合与重构, 是认知 W SN 在实际应用中亟待解决的问题。

压缩感知 (CS, compressive sensing) 理论研究表明, 可压缩信号 (在某一基空间上具有稀疏表示) 的少量随机线性投影就包含了重构和处理的足够信息, 仅利用信号的先验知识和少量全局线性测量可以获得准确重构<sup>[5-7]</sup>。其中, 设计低观测次数且均方误差小的重构算法是 CS 实际应用的关键问题<sup>[8,9]</sup>。JIS 研究表明, 采用自适应观测矩阵可提高 CS 压缩比, 如采用贝叶斯压缩感知 (BCS) 构造自适应观测矩阵取代以高斯 (Gaussian) 或贝努利 (Bernoulli) 随机变量构成的随机观测矩阵, 可以提高 CS 重构

性能<sup>[10]</sup>。

本文基于该思想, 将 BCS 理论应用于认知 W SN, 利用节点感知数据的时空相关性, 研究基于 BCS 的认知 W SN 汇聚节点数据融合策略, 在提高感知信号重构性能的同时降低重构均方误差, 以保障网络节点能量有效性, 并通过仿真实验验证所提策略的均方误差性能。

### 2 贝叶斯压缩感知模型

在 C-W SN 中, sink 节点汇聚多个感知节点数据, 对各节点感知到的 PU 频谱信息进行估计与重构, 并使重构误差满足一定要求。假设 C-W SN 事件区域中包含有 N 个节点进行监控 PU 频谱占用情况, 在时刻 t 获得的感知信息向量  $x^{(t)} = (x_1^{(t)}, x_2^{(t)}, \dots, x_N^{(t)})^T$ ,  $t = 1, 2, \dots, T$ 。定义感知数据矩阵  $X = [x^{(1)}, x^{(2)}, \dots, x^{(T)}] \in R^{N \times T}$ , 由于  $x^{(t)}, t = 1, 2, \dots, T$  之间存在着时间相关性, 且由于节点分布位置的不同, 节点感知数据之间也具有空间相关性, 可以利用 CS 对时刻 t 的感知数据进行稀疏表示、数据融合与重构<sup>[11]</sup>。基于 BCS 的 C-W SN 数据融合与重构场景图如图 1 所示。

#### 2.1 BCS 基本原理

根据 CS 理论, 考虑  $x^{(t)}$  在正交基矩阵  $B \in R^{N \times N}$  上的投影系数向量  $\theta^{(t)}$ , 假设  $\theta^{(t)}$  中 M ( $M < N$ ) 个具有较大值的非零元素构成向量  $\theta_s^{(t)} \in R^N$ , 其余 (N - M) 个元素构成向量  $\theta_e^{(t)} \in R^N$ , 则  $\theta^{(t)} = \theta_s^{(t)} + \theta_e^{(t)}$ , 因此:

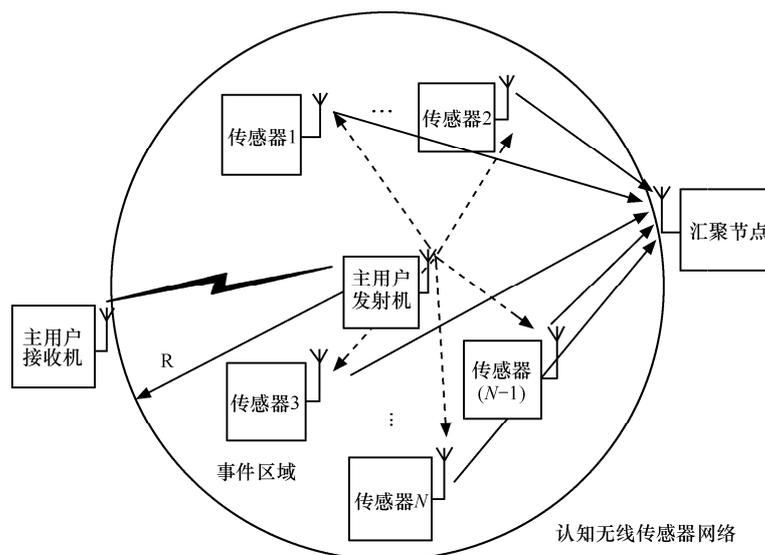


图1 基于BCS的C-W SN数据融合与重构场景

$$x^{(t)} = B \theta^{(t)} \tag{1}$$

利用观测矩阵  $\Phi$  对系数向量  $\theta^{(t)}$  进行线性变换,  $\Phi = \{j_i | j_i \in \mathbb{R}^N, i=1,2,\dots,M\}$  满足不相关性与约束等距性质 (RIP, restricted isometry property) 条件, 获得  $t$  时刻的  $M$  个观测值  $y^{(t)} \in \mathbb{R}^M$ , 即

$$y^{(t)} = \Phi B^T x^{(t)} = \Xi x^{(t)} \tag{2}$$

其中,  $\Xi \in \mathbb{R}^{M \times N}$  为 CS 信息算子。考虑含噪测量情况下, 当测量噪声为  $n_m^{(t)}$  时, 在时刻  $t$  的观测向量为

$$y^{(t)} = \Phi \theta_s^{(t)} + \Phi \theta_e^{(t)} + n_m^{(t)} = \Phi \theta_s^{(t)} + n^{(t)} \tag{3}$$

其中,  $n^{(t)} = \Phi \theta_e^{(t)} + n_m^{(t)} \in \mathbb{R}^M$  中元素服从均值为零、方差  $s^2$  的高斯分布, 即  $n_i \sim N(0, s^2), i=1,2,\dots,M$ 。考虑在时刻  $t$  的高斯似然函数

$$p(y^{(t)} | \theta_s^{(t)}, s^2) = \prod_{i=1}^M \frac{1}{2\pi s^2} e^{-\frac{n_i^2}{2s^2}} = (2\pi s^2)^{-\frac{M}{2}} \exp\left(-\frac{1}{2s^2} \|n^{(t)}\|_2^2\right) \tag{4}$$

其中,  $\|n^{(t)}\|_2 = \left(\sum_{i=1}^M |y_i^{(t)} - j_i \theta_{si}^{(t)}|^2\right)^{\frac{1}{2}}$ 。由于  $M < N$ , 式(2)有无穷多解,  $x^{(t)}$  不能直接从观测向量  $y^{(t)}$  中进行重构, 该欠定方程 (方程个数少于未知数个数) 需要通过求解  $l_0$  范数的优化问题获得最佳  $\theta_s^{(t)}$  [12], 即

$$\theta_s^{(t)} = \arg \min_{\theta_s^{(t)}} \ln \{ \|y^{(t)} - \Phi \theta_s^{(t)}\|_2^2 + t \|\theta_s^{(t)}\|_0 \} \tag{5}$$

其中, 式(5)中常数  $t = \frac{l}{s^2}$ 。通常式(5)为 NP 问题, 可以通过求解  $l_1$  范数优化问题得到它的等价解 [7,12]。

$$\theta_s^{(t)} = \arg \min_{\theta_s^{(t)}} \ln \{ \|y^{(t)} - \Phi \theta_s^{(t)}\|_2^2 + t \|\theta_s^{(t)}\|_1 \} \tag{6}$$

### 2.2 层次化贝叶斯分析模型

采用层次化贝叶斯分析模型对式(6)的重构问题进行求解, 首先定义时刻  $t$  的联合概率密度函数

$$p(\theta_s^{(t)}, \gamma, l, s^2, y^{(t)}) = p(y^{(t)} | \theta_s^{(t)}, s^2) p(s^2) p(\theta_s^{(t)} | \gamma) p(\gamma | l) p(l) \tag{7}$$

根据文献[10,12],  $t$  时刻  $\theta^{(t)}$  的后验分布服从高斯模型

$$p(\theta_s^{(t)} | \gamma) = \prod_{i=1}^N p(\theta_{si}^{(t)} | 0, g_i) \tag{8}$$

$\gamma$  中第  $i$  个元素的条件概率密度服从指数分布

$$p(g_i | l) = \frac{l}{2} \exp\left(-\frac{l}{2} g_i\right), g_i \geq 0, l \geq 0 \tag{12}$$

$$p(\theta_s^{(t)} | l) = \int p(\theta_s^{(t)} | \gamma) p(\gamma | l) d\gamma$$

$$= \prod_{i=1}^N \int p(\theta_{si}^{(t)} | g_i) \frac{l}{2} \exp\left(-\frac{l}{2} g_i\right) dg_i = \frac{l^{\frac{N}{2}}}{2^N} \exp\left(-\sqrt{l} \|\theta_s^{(t)}\|_1\right) \tag{9}$$

其中,  $\|\theta_s^{(t)}\|_1 = \sum_{i=1}^N |\theta_{si}^{(t)}|$ 。参数  $l$  和  $s^2$  分别服从条件 Gamma 分布 [12,13], 即

$$p(l | u) = G\left(l \mid \frac{u}{2}, \frac{u}{2}\right) \tag{10}$$

$$p(s^2 | a, b) = G(s^2 | a, b) \tag{11}$$

其中, 条件 Gamma 分布定义为  $G(x | a, b) = \frac{b^a}{\Gamma(a)}$

$x^{a-1} e^{-bx}$ , Gamma 函数  $\Gamma(a) = \int_0^\infty t^{a-1} e^{-t} dt, a > 0$ 。因此, 根据最大后验概率准则 (MAP, maximum a posteriori probability), 将式(4)、式(9)~式(11)代入式(7), 通过迭代更新式(7)中的参数, 得到  $\theta_s^{(t)}$  的最佳估计  $\hat{\theta}_s^{(t)}$ 。图 2 给出了层次化贝叶斯分析模型的参数关系。

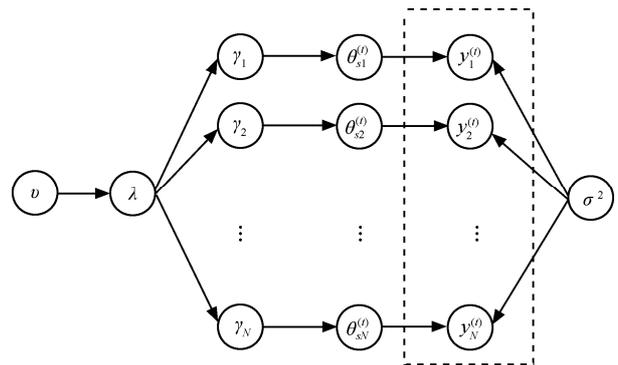


图 2 层次化贝叶斯分析模型参数关系

### 3 基于 BCS 的数据融合算法

考虑在  $t$  之前的  $T$  个时刻汇聚节点感知信息向量集合为  $\chi^{(t)} = [x^{(t-1)}, x^{(t-2)}, \dots, x^{(t-T)}] \in \mathbb{R}^{N \times T}$ , 它与感知数据矩阵  $X$  具有时间相关性, 时间参数  $T$  可根据它与  $X$  的相关性强弱确定 [15]。定义时刻  $t$  感知数据矩阵  $X$  的时间平均与协方差矩阵分别为

$$E[X] = \bar{X}^{(t)} = \frac{1}{T} \sum_{t=1}^T X^{(t)} \tag{12}$$

$$\text{cov}[X] = C^{(t)} = \frac{1}{T} \sum_{t=1}^T (X^{(t)} - \bar{X}^{(t)}) (X^{(t)} - \bar{X}^{(t)})^T \tag{13}$$

由于时间相关性 [15],  $E[\chi^{(t)}] \triangleq \bar{\chi}^{(t)}, \text{cov}(\chi^{(t)}) \triangleq C^{(t)}$ 。

令  $\theta_s^{(t)} = U^T (x^{(t)} - \bar{x}^{(t)})$ ，其中  $U$  为正交阵 ( $U^T = U^{-1}$ )，对比式 (1)，通过构造特殊的正交基矩阵  $U$  获得稀疏系数向量  $\theta_s^{(t)}$ 。在本文中，采用树型结构小波基 (TSW, tree structured wavelet) 构造矩阵  $U$ ，即通过小波的 Mallat 分解构造树型结构小波基<sup>[16]</sup>。在 TSW 下， $\theta_s^{(t)}$  具有统计稀疏性，各节点感知数据可以进行压缩，进而通过层次化贝叶斯分析模型获得最佳估计  $\theta_s^{(t)}$ <sup>[16]</sup>。因此，通过 TSW 变换，可以得到汇聚节点数据融合后的最佳估计：

$$x^{(t)} = \bar{x}^{(t)} + U \theta_s^{(t)} \tag{14}$$

定义重构均方误差 (MSE, mean square error) 为

$$MSE_{BCS} = E \left[ \frac{\|\theta_s^{(t)} - \hat{\theta}_s^{(t)}\|_2^2}{\|\theta_s^{(t)}\|_2^2} \right] \tag{15}$$

综上所述，基于 BCS 的认知 WSN 数据融合重构算法流程如下。

1) 首先通过层次化 Bayesian 模型对式 (6) 所示重构问题进行求解，获得时刻  $t$  的联合概率密度函数 (如式 (7) 所示)。

2) 将式 (4)、式 (9)~式 (11) 代入式 (7)，迭代更新式 (7) 中的参数，得到  $\theta_s^{(t)}$  的最佳估计  $\hat{\theta}_s^{(t)}$ 。

3) 汇聚节点根据式 (12) 求得时刻  $t$  感知数据矩阵  $X$  的时间平均  $\bar{x}^{(t)}$ ，并构造 TSW 正交基矩阵  $U$ 。

4) 汇聚节点根据式 (14) 重构感知数据的最佳估计  $\hat{x}^{(t)}$ ，并计算重构均方误差。

### 4 仿真性能分析

考虑大规模认知 WSN 中的节点随机均匀分布于某一事件区域内，假设该事件区域内分别分布有 120/180 个节点<sup>[17]</sup>。在指定时刻，各节点分别对 PU 频谱占用情况进行本地感知，产生 1bit 本地频谱感知数据，分布式感知数据在向汇聚节点传输的过程中叠加了均值为零，方差为 0.01 的高斯白噪声。汇聚节点运行基于 TSW BCS 的数据融合算法，以重构事件区域中各节点感知数据，并计算重构均方误差 (MSE)。

根据文献 [13, 16~18] 的仿真参数设置，本文将基于贪婪算法的 OMP 重构算法作为对比，OMP 采用 Gaussian 观测获得线性测量，算法所需最小观测次数为  $M = O(K \ln N)$  ( $N$  为节点数， $K$  为稀疏度)<sup>[18]</sup>。基于 TSW BCS 的数据融合算法采用  $N = 4$  的 Daubechies 系紧支集正交小波 (db4) 构造基矩阵  $U$ ，

具有 4 阶消失矩，Mallat 分解层数为 6<sup>[16]</sup>。最大相关时间  $T = 10s$ ，参数  $L = 1$ 。仿真比较 2 种重构算法的重构 MSE 与观测数据个数  $M$ 、压缩比  $\left(\frac{M}{N}\right)$  之间的关系。

图 3 给出了基于 OMP 与 TSW BCS 2 种数据融合重构算法的观测次数与重构 MSE 之间关系。由图可知，在相同节点数下，TSW BCS 的重构 MSE 明显小于 OMP。当事件区域内 WSN 节点数为 120 时，OMP 的 MSE 为 14，TSW BCS 的 MSE 仅为 4。然而，OMP 的 MSE 收敛快于 BCS，但其重构性能较 BCS 差。由于 OMP 采用高斯观测，当节点数为 120 和 180 时，经高斯变换后的感知数据量  $N$  仍为 120 和 180，其最小观测数均为 15，即观测数  $M > 15$  时可以达到收敛。而 BCS 采用 db4 小波基，节点数为 120 和 180 时，小波域的感知数据量  $N$  分别为 159 和 218，其最小观测数分别为 35 和 40，且随着节点数的增大，最小观测数  $M$  增加，重构 MSE 减小，达到收敛时重构 MSE 均趋于零。

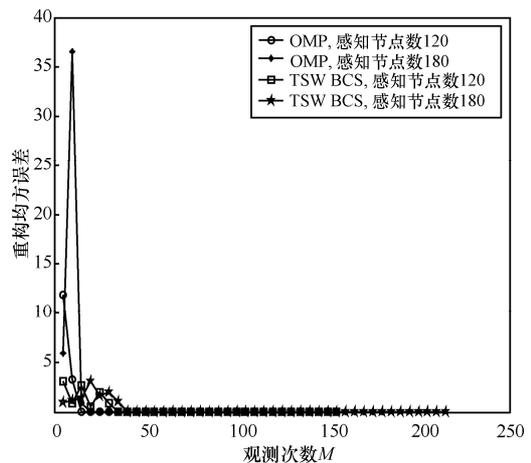


图 3 2 种数据融合重构算法观测次数与重构 MSE 关系

图 4 给出了 2 种数据融合重构算法的压缩比与重构 MSE 之间关系。压缩比定义为观测次数  $M$  与变换域内的感知数据量  $N$  之比。由图可知，OMP 的重构 MSE 仍远大于 TSW BCS，但 OMP 收敛速度快，如节点数为 120 时，OMP 在压缩比为 0.12 时即收敛。TSW BCS 在压缩比 0.22 时收敛。此外，对于 BCS，节点数的增加使得感知数据之间的时空相关性增大，其稀疏性越好，即在相同压缩比下，重构 MSE 随着节点数的增加而下降，如当压缩比为 0.18 时，节点数 120 对应的重构 MSE 小于 0.25，节点数 180 对应的重构 MSE 小于 0.16。随着节点

数的增大, 重构 MSE 在较小的压缩比下即可达到收敛。因此, 基于时空相关性的 TSW BCS 在保证一定重构 MSE 要求下, 可较好地实现认知 WSN 感知数据的变换域压缩与重构。

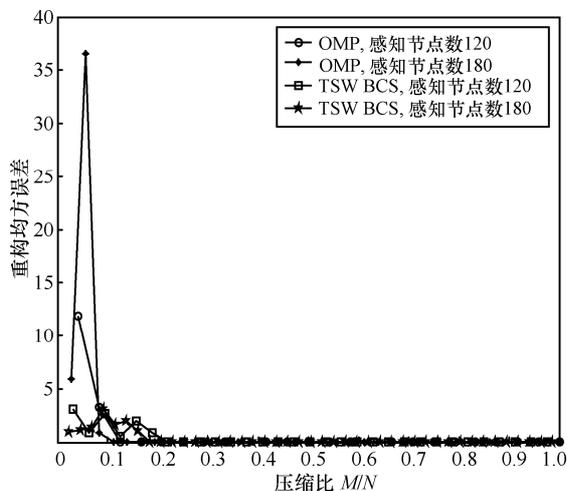


图 4 2 种数据融合重构算法压缩比与重构 MSE 关系

### 5 结束语

本文研究了认知无线传感器网络 (C-W SN) 中基于小波树型结构贝叶斯压缩感知 (TSW BCS) 的数据融合重构策略。利用 C-W SN 认知节点对事件区域感知信号的时空相关性, 汇聚节点基于层次化贝叶斯分析模型获得稀疏估计, 进而构造 TSW 小波基矩阵, 以重构各节点的感知数据向量。对基于 OMP 与 TSW BCS 2 种数据融合重构算法分别进行了仿真比较, 与基于贪婪算法的 OMP 相比, 基于 BCS 的数据融合具有较低的重构 MSE。尽管 OMP 收敛快于 BCS, 但其重构性能较 BCS 差。利用感知数据的时空相关性, BCS 在较小的压缩比下即可实现快速收敛。因此, 所提策略适用于大规模认知 WSN 汇聚节点侧的数据稀疏重构。此外, 基于 BCS 的自适应数据融合<sup>[10]</sup>以及结合主分量分析 (PCA, principal component analysis) 的 BCS 数据压缩重构<sup>[15]</sup>将是进一步研究的重点, 将这 2 种方法应用于大规模 C-W SN (如基于云计算的大规模认知 WSN) 数据融合, 以提高 BCS 的压缩与重构性能, 需要我们做进一步的研究。

### 参考文献:

[1] 崔莉, 鞠海玲, 苗勇等. 无线传感器网络研究进展[J]. 计算机研究与发展, 2005, 42(1): 163-174.

CUI L, JU H L, MIAO Y, et al. Overview of wireless sensor networks[J]. Journal of Computer Research and Development, 2005, 42(1): 163-174.

[2] WANG Q, YANG W. Energy consumption model for power management in wireless sensor networks[A]. Proceedings of the 4th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks[C]. Pisa, Italy, 2007. 142-151.

[3] VURAN M C, AKAN O B. Spatial-temporal characteristics of point and field sources in wireless sensor networks[A]. Proceedings of 2006 International Communications Conference[C]. Istanbul, Turkey, 2006. 234-239.

[4] VURAN M C, AKYILDIZ I F. Spatial correlation-based collaborative medium access control in wireless sensor networks[J]. IEEE Transactions on Networking, 2006, 14(2): 316-329.

[5] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.

[6] CANDESE J. Compressive sampling[A]. Proceedings of International Congress of Mathematicians[C]. Madrid, Spain, 2006. 1433-1452.

[7] CANDESE J, TAO T. Near optimal signal recovery from random projections: universal encoding strategies[J]. IEEE Transactions on Information Theory, 2006, 52(12): 5406-5425.

[8] 石光明, 刘丹华, 高大化等. 压缩感知理论及其研究进展[J]. 电子学报, 2009, 37(5): 1070-1081.

SHIG M, LIU D H, GAO D H, et al. Advances in theory and applications of compressed sensing[J]. Acta Electronica Sinica, 2009, 37(5): 1070-1081.

[9] 金坚, 谷源涛, 梅顺良. 压缩采样技术及其应用[J]. 电子与信息学报, 2010, 32(2): 470-475.

JIN J, GU Y T, MEI S L. An introduction to compressed sampling and its applications[J]. Journal of Electronics and Information Technology, 2010, 32(2): 470-475.

[10] JI S, XUE Y, CARRIN L. Bayesian compressed sensing[J]. IEEE Transactions on Signal Processing, 2008, 56(6): 2346-2356.

[11] YANG A Y, GASTPAR M, BAJCSY R, et al. Distributed sensor perception via sparse representation[J]. Proceedings of the IEEE, 2010, 98(6): 1077-1088.

[12] BABACAN S D, MOLINA R, KATSAGGELOS A K. Bayesian compressed sensing using Laplace priors[J]. IEEE Transactions on Image Processing, 2010, 19(1): 53-63.

[13] 汪振兴, 杨涛, 胡波. 基于互信息的分布式贝叶斯压缩感知[J]. 中国科学技术大学学报, 2009, 39(10): 1045-1051.

WANG Z X, YANG T, HU B. Distributed bayesian compressed spectrum sensing based on mutual information[J]. Journal of University of Science and Technology of China, 2009, 39(10): 1045-1051.

[14] 张正浩, 裴昌幸, 陈南等. 宽带认知无线电网络分布式协作压缩频

谱感知算法[J]. 西安交通大学学报, 2011, 45(4): 67-71, 114.

ZHANG Z H, PEI C X, CHEN N, et al. A sensing algorithm based on distributed cooperative compressed spectrum for wideband cognitive radio networks[J]. Journal of X ian Jiaotong U niversity, 2011, 45(4): 67-71, 114.

- [15] M A S I E R O R, O U E R G, R O S S I M, et al. A bayesian analysis of compressive sensing data recovery in wireless sensor networks[A]. Proceedings of International Conference on Ultra M odem Telecommunications and W orkshops (ICUM T 2009)[C]. St Petersburg, Russia, 2009. 1-6.

- [16] H E L, C A R I N L. Exploiting structure in wavelet-based bayesian compressive sensing[J]. IEEE Transactions on Signal Processing, 2009, 57(9): 3488-3497.

- [17] 胡海峰, 杨震. 无线传感器网络中基于空间相关性的分布式压缩感知[J]. 南京邮电大学学报, 2009, 29(6): 12-16.

H U H F, Y A N G Z. Spatial correlation based distributed compressed sensing in wireless sensor networks[J]. Journal of N anjing U niversity of Posts and Telecom m unications, 2009, 29(6): 12-16.

- [18] T R O P P J A, G I L B E R T A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.

#### 作者简介:



**许晓荣** (1982-), 男, 浙江杭州人, 博士, 浙江大学信息与通信工程博士后科研流动站在站博士后, 杭州电子科技大学讲师, 主要研究方向为认知无线网络、压缩感知、多用户协作通信等。



**黄爱苹** (1953-), 女, 江苏南京人, 浙江大学教授、博士生导师, 主要研究方向为移动通信、无线网络、宽带接入和信号处理等。



**章坚武** (1961-), 男, 浙江杭州人, 博士后, 杭州电子科技大学教授、硕士生导师, 主要研究方向为个人通信与移动通信、无线通信与网络信号处理等。