

认知 WSN 中基于能量有效性自适应观测的梯度投影稀疏重构方法

许晓荣* 姚英彪 包建荣 陆宇
(杭州电子科技大学通信工程学院 杭州 310018)

摘要: 针对认知无线传感器网络中传感器节点侧的模拟信息转换器对本地感知数据进行稀疏表示与压缩测量, 该文提出一种基于能量有效性观测的梯度投影稀疏重构(GPSR)方法。该方法根据事件区域内认知节点对实际感知到的非平稳信号空时相关性结构, 映射到小波正交基级联字典进行稀疏变换, 通过加权能量子集函数进行自适应观测, 以能量有效的方式获取合适的观测值, 同时对所选观测向量进行正交化构造测量矩阵。汇聚节点采用 GPSR 算法进行自适应压缩重构。仿真比较了 GPSR 自适应重构与正交匹配追踪(OMP)重构算法。仿真结果表明, 在压缩比小于 0.2 的区域内, 基于能量有效性观测的 GPSR 自适应重构效果优于传统随机高斯测量信号重构。在相同节点数情况下, GPSR 自适应压缩重构方法在低信噪比区域内具有较小的重构均方误差, 且该方法所需观测数明显低于随机高斯观测, 同时有效保障了感知节点的能耗均衡。

关键词: 认知无线传感器网络; 能量有效性; 梯度投影稀疏重构; 自适应压缩; 加权能量子集函数

中图分类号: TP393

文献标识码: A

文章编号: 1009-5896(2014)01-0027-07

DOI: 10.3724/SP.J.1146.2013.00392

Gradient Projection Sparse Reconstruction Approach Based on Adaptive Energy-efficiency Measurement in Cognitive WSN

Xu Xiao-rong Yao Ying-biao Bao Jian-rong Lu Yu

(College of Telecommunication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: Cognitive sensor local information sparse representation and compressive measurement are investigated, which are conducted by Analog-to-Information Converters (AIC) at each sensor in Cognitive Wireless Sensor Networks (C-WSN). Gradient Projection Sparse Reconstruction (GPSR) scheme based on energy-efficiency measurement is proposed. According to the spatial-temporal correlation structure of non-stationary signals perceived by massive cognitive sensors in Event Region (ER), these signals are mapped to wavelet orthogonal basis concatenate dictionaries to perform sparse representation. Adaptive measurement is implemented via weighted energy subset function, which could obtain the proper observation in energy-efficiency approach. The corresponding measurement matrix is constructed by the orthogonalization of these selected measurement vectors. Adaptive compressive reconstruction is performed at sink via GPSR algorithm, which is compared with conventional Orthogonal Matching Pursuit (OMP) algorithm. Simulation results indicate that, signal reconstruction effect based on energy-efficiency measurement GPSR adaptive compression is superior to Gaussian random measurement in the region where compression ratio is less than 0.2. With the same sensor numbers, the proposed GPSR adaptive compression approach has small reconstruction Mean Square Error (MSE) at low Signal-to-Noise Ratio (SNR) region, and the required measurement number is less than Gaussian random measurement, which guarantees sensors' energy balance effectively.

Key words: Cognitive Wireless Sensor Networks (C-WSN); Energy-efficiency; Gradient Projection Sparse Reconstruction (GPSR); Adaptive compression; Weighted energy subset function

1 引言

认知无线传感器网络(C-WSN)中包含大量具有

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^[1,2]。在 C-WSN 中, 节点机会地利用主用户(Primary User, PU)频谱将本地感知信息发送到汇聚节点(sink)进行数据融合, 汇聚节点对多个认知节点的感知信息进行重构^[3]。在对同一目标进行感知的过程中, 节点在感知时间和空间

2013-03-28 收到, 2013-07-27 改回

国家自然科学基金(61102066, 61100044, 61001133)和浙江省自然科学基金(LY12F01007)资助课题

*通信作者: 许晓荣 xuxr@hdu.edu.cn

位置上均存在着相关性^[4]。利用感知数据的时空相关性，通过设计满足约束等距性质(Restricted Isometry Property, RIP)的自适应观测矩阵，使得变换域稀疏的可压缩信号在观测过程中不发生信息丢失且能够以高概率实现稀疏重构，是压缩感知(Compressed Sensing, CS)在C-WSN应用中亟待解决的问题。此外，由于WSN节点能耗受限，必须考虑在保障节点能量有效性条件下的自适应压缩重构^[1,5]。

目前，已有文献将CS理论应用于WSN，且考虑到节点能耗问题，如文献[1,5]提出在汇聚节点利用CS重构原信号，以设定阈值的方式优化重构时的准确度，同时采用混合观测矩阵保障时延与能耗之间的平衡。但是，该方法需要考虑节点剩余能量与设定门限值的关系，若节点剩余能量多于设定的门限值，则采用收敛速度快的自适应压缩感知算法；若节点剩余能量低于门限值，则采用能量均衡算法，以实现时延与能耗的兼顾。由于门限值的设定需要探测每个时间间隔的节点剩余能量，故该方法在保障WSN节点能耗的前提下增加了重构算法的复杂度，且阈值更新也增加了重构时延。文献[6]提出了能量有效的WSN协作压缩感知机制，WSN节点根据各自的能量消耗状态，通过协作的方式选择稀疏基，进而通过冗余字典增大数据表示过程中的稀疏度，有效地增强了协作融合时的鲁棒性，延长了WSN网络生存时间。但是，论文采用超完备冗余函数代替正交基函数，并未考虑感知信号通过超完备字典稀疏逼近时的额外能耗。文献[7]通过基扩展构造正交基字典，WSN节点根据本地感知信号特性自适应选择最优正交基进行稀疏表示，以保障节点能量有效性。然而，通过正交基字典稀疏表示的信号难以构造出满足RIP特性的合适观测矩阵，该方法在实际应用中有待进一步探索。因此，设计满足RIP特性且具有较低观测次数的自适应观测矩阵是CS理论在WSN实际应用的关键问题^[8,9]。文献[10,11]表明了基于贪婪算法(如正交匹配追踪(Orthogonal Matching Pursuit, OMP)^[10]，正则化自适应匹配追踪(Regularized Adaptive Matching Pursuit, RAMP)^[10,11])的重构算法中，测量矩阵列向量的非线性相关性是匹配追踪系列重构算法的前提，并且测量矩阵的非线性相关性越强，矩阵元素的稀疏度越高，则信号重构时迭代次数越少^[10,11]。此外，二次规划凸松弛法可以将压缩感知信号恢复问题转变为最小 l_1 范数凸优化问题。基于二次规划(Quadratic Programming, QP)的凸优化方法主要有内点法(Interior Point, IP)^[10,12]，梯度投影稀疏重

构(Gradient Projection Sparse Reconstruction, GPSR)^[13]，迭代收缩阈值法(Iterative Shrinkage Thresholding, IST)^[14]等，它们通过将非凸问题转化为凸优化问题进行重构信号的恢复，在相同重构均方误差要求下，其重构信号所需的观测次数均小于贪婪算法^[12,13]。

本文在上述文献WSN中基于CS理论进行感知信号稀疏重构与节点能耗分析的基础上，根据认知节点对实际感知到的非平稳信号空时相关性结构，感知数据首先映射到Daubechies系列小波正交基(db2和db4)级联字典进行稀疏变换^[15]，通过选择变换域观测向量，以能量有效的方式获取合适的观测值，同时对所选观测向量进行正交化构造测量矩阵。小波正交基级联字典稀疏变换矩阵与构造的观测矩阵之间满足RIP条件^[15]，以此得到基于能量有效性的自适应观测向量，感知节点侧的模拟信息转换器(Analog-to-Information Converter, AIC)将经自相关运算后的观测向量发送至汇聚节点，采用GPSR凸松弛法进行信号重构，形成自适应压缩。

2 基于能量有效性的自适应观测

2.1 C-WSN 测量矩阵设计准则

假设C-WSN事件区域(Event Region, ER)中包含有 N 个节点进行监控PU频谱占用情况，传感器节点获取的感知向量为 $\mathbf{x} = \boldsymbol{\psi}\mathbf{s}$ ，其中 $\boldsymbol{\psi} \in R^{N \times N}$ 为正交基矩阵， $\mathbf{s} \in R^{N \times 1}$ 为包含 K ($K \ll N$)个非零元素的变换域稀疏向量，可由汇聚节点根据一定的优化算法从 M ($M < N$)维观测向量中进行重构^[8,9]。考虑 \mathbf{x} 在正交基矩阵 $\boldsymbol{\psi} = \{\psi_i | \psi_i \in R^N, i \in \{1, 2, \dots, N\}\}$ 下为 K 稀疏的，其投影向量 $\mathbf{s} = (s_1, s_2, \dots, s_N)^T$ ，非零元素为 $s_i = \langle \mathbf{x}, \psi_i \rangle$ 。由于 \mathbf{x} 中的每一元素均来自不同的感知节点，元素间具有相关性，利用测量矩阵 $\boldsymbol{\Phi} = \{\varphi_j | \varphi_j \in R^N, j \in \{1, 2, \dots, M\}\}$ 对稀疏系数 \mathbf{s} 进行线性变换， $\boldsymbol{\Phi}$ 与 $\boldsymbol{\psi}$ 满足不相关性与 K 阶RIP，获得 M 个观测值 $\mathbf{y} \in R^M$ 。在含噪测量的情况下，测量噪声向量 \mathbf{n} 为零均值，方差为 σ^2 的高斯向量^[8,9]，即 $n_i \sim N(0, \sigma^2), i = 1, 2, \dots, M$ 。观测向量 \mathbf{y} 表示为

$$\mathbf{y} = \boldsymbol{\Phi}\boldsymbol{\psi}\mathbf{s} + \mathbf{n} = \boldsymbol{\Xi}\mathbf{s} + \mathbf{n} \quad (1)$$

其中 $\boldsymbol{\Xi} \in R^{M \times N}$ 为CS算子。根据 l_0 和 l_1 最优化问题稀疏解的等价性^[8,10]，在信号与噪声均未知的情况下，汇聚节点侧的含噪信号恢复问题可以表示为带约束的二次规划(Bound Constrained Quadratic Programming, BCQP)问题^[13]。

$$\hat{\mathbf{s}} = \arg \min_{\mathbf{s}} \left\{ \|\mathbf{y} - \boldsymbol{\Xi}\mathbf{s}\|_2^2 + \tau \|\mathbf{s}\|_1 \right\} \quad (2)$$

上述问题为包含 l_2 范数二次误差项和 l_1 范数正

则项的凸优化问题。其中, l_2 范数给出估计值与原信号能量的差别, 以增强算法的抑制噪声能力; l_1 范数则是增强算法的稀疏能力。当信号稀疏度 K 已知时, 可以采用最小绝对收缩与选择算子 (Least Absolute Shrinkage and Selection Operator, LASSO) 算法求解最佳 $\hat{\mathbf{s}}^{[10]}$ 。然而, 实际 C-WSN 中信号与噪声均未知, 汇聚节点重构问题为式(2)给出的 BCQP 问题。由于 BCQP 问题为最小 l_1 范数的凸优化问题, 通常采用内点法(IP)^[10,12]、梯度投影稀疏重构(GPSR)^[13]、迭代收缩阈值法(IST)^[14]等方法对感知信号进行非线性重构。

测量矩阵在压缩反馈与信号重构过程中具有重要作用。若重建算法不变, 测量矩阵 Φ 的性能越好, 则重构均方误差(Mean Square Error, MSE)越小。测量矩阵列向量的非线性相关性越强, 矩阵元素的稀疏度越高, 经压缩反馈后的信号重构效果更好^[9,10]。测量矩阵 Φ 设计要求满足的 3 个特征, 即: Φ 列向量需要满足一定的线性独立性; Φ 列向量体现某种类似噪声的独立随机性; 满足稀疏度的解是满足 $l_p, 0 < p \leq 1$ 范数最小的向量。上述性质对 Φ 的设计起着至关重要的作用^[5,9,10,12]。

不同于传统随机高斯或贝努利观测的随机信号压缩, 在本文场景中, 需要设计满足 RIP 条件且具有较低观测次数的自适应观测矩阵对节点实际感知到的非平稳信号进行自适应观测, 同时兼顾 C-WSN 节点的能量有效性。文献[16]已经证明了基于变换域最大能量子集构造的自适应观测矩阵与稀疏变换基矩阵不相关, 即满足 RIP 性质。本文在文献[16]的基础上, 根据各节点感知时的能耗, 构造加权的变换域稀疏信号能量子集函数, 以获得最大加权能量子集, 并进行正交化处理, 形成保障节点能量有效性的自适应观测。同时, 汇聚节点采用 GPSR 算法进行自适应压缩重构。

2.2 基于最大加权能量子集的自适应观测

传统压缩反馈通常采用随机测量方案(Random Measurement Scheme, RMS), RMS 并未考虑感知信号的特点^[9,16]。在本文场景中, 由于节点能耗受限, 且分布位置与感知能耗均不相同, 可以根据节点的接收能耗设计合适的测量矩阵, 即通过节点感知信号的能量构造加权的变换域能量子集函数, 以自适应地确定测量矩阵行数 M , 从而减少测量次数和汇聚节点重构均方误差(Mean Square Error, MSE)。

考虑 C-WSN 事件区域内包含 N 个节点, 在第 k 个采样时刻, 第 i 个 WSN 节点感知信号可以表示为

$$x_i(k) = d_i^{-n} h_i \sqrt{P_{\text{PU}}} s_i(k) + n_i(k), \quad i = 1, 2, \dots, N \quad (3)$$

其中 d_i 为 PU 与第 i 个 WSN 节点之间的距离, n 为

路径衰耗指数 ($2 \leq n \leq 4$), h_i 为 PU 到第 i 个 WSN 节点的下行信道衰落系数, P_{PU} 为主用户发射功率。

相应地, 第 i 个节点的接收信噪比为 $\gamma_i = \frac{|h_i|^2 P_{\text{PU}}}{d_i^n \sigma_n^2}$ 。

其中, $\sigma_n^2 = n_0 B$ 为噪声功率, 正比于感知信号带宽 B , 通常在加性白高斯噪声 (Additive White Gaussian Noise, AWGN) 信道下单边噪声功率谱密度为 $n_0 = -174$ dBm/Hz^[17]。假设各信道衰落系数均为均值为零, 方差为 σ_n^2 的循环对称复高斯随机变量, 且感知信道与压缩反馈信道相互独立, 则信道矩阵 \mathbf{H} 的 Frobenius 范数 $\|\mathbf{H}\|_F^2 = \sum_{i=1}^{2N} |h_i|^2$ 服从自由度为 $2N$ 的中心 chi-square 分布, 即 $\chi_{2N}^2(0)$ ^[17]。根据一致不确定原则 (Uniform Uncertainty Principle, UUP)^[2,8], CS 算子需要满足 RIP 条件, 有以下定理:

定理 1 设存在一个能量子集 $E, E \subset A = \{1, 2, \dots, N\}$, 在 CS 算子的列向量中根据 E 选择一个 CS 算子的子矩阵 Ξ_E , 则对任意常数 $\delta_K < 1$, 使得

$$(1 - \delta_K) \|\mathbf{s}\|_2^2 \leq \|\Xi_E \mathbf{s}\|_2^2 \leq (1 + \delta_K) \|\mathbf{s}\|_2^2 \quad (4)$$

其中 $|E| < K$ 。上述定理说明了观测向量 \mathbf{y}_E 保持了 K 稀疏向量 \mathbf{s} 的能量分布 (变换域感知信号能量)。

第 i 个 WSN 节点的接收功率 $\alpha_i = \frac{|h_i|^2 P_{\text{PU}}}{d_i^n}$ 为节点能耗, 将它作为第 i 个节点感知信号 x_i 的加权因子, 则定义为:

定义 1 设信号向量 $\mathbf{x} \in R^N$, 在能量子集 E 上存在映射 $S: \alpha \mathbf{x} \rightarrow \|\alpha \mathbf{x}_E\|_2^2$, 其中 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_N)$ 。 $\alpha \mathbf{x}_E$ 记为加权能量子集函数, 若存在 $E_{\max} = \max_{E \subset A} \|\alpha \mathbf{x}_E\|_2^2$, 则 E_{\max} 为集合 A 的最大加权能量子集, 元素个数为 $|E_{\max}| = M$ 。

最大加权能量子集表明了感知信号能量与节点感知时的能耗之间关系。由 Parseval 定理, 由于信号在变换域能量守恒, 故根据 RIP 定理式(4), 令 $T = M = |E_{\max}|$, 通过分析 $\mathbf{y} = \Phi_{E_{\max}} \alpha \mathbf{x}$ 的能量分布即可获得加权感知信号的能量, 构造测量矩阵 $\Phi_{E_{\max}}$, 从而获得自适应观测 $\mathbf{y}_{E_{\max}}$, 并将 $\mathbf{y}_{E_{\max}}$ 的自相关向量 $\mathbf{r}_{\mathbf{y}, E_{\max}}$ 反馈至汇聚节点进行 GPSR 压缩重构。具体步骤如下:

步骤 1 认知 WSN 汇聚节点事先给 ER 内的 N 个节点发送信令, 各节点进行 PU 频谱检测产生感知信号向量 \mathbf{x} , 而后各节点根据接收功率得到能耗加权向量 α , 它与 \mathbf{x} 进行内积运算后映射到小波正交基级字典 Ψ 进行稀疏变换, 得到由 K 个非零元素构成的稀疏系数向量 \mathbf{s} 。本方案中采用二阶和四阶 Daubechies 系列紧支集正交小波基 (db2 和 db4)

级联字典,通过马拉特(Mallat)塔式分解构造树型结构小波基(Tree Structured Wavelet, TSW)矩阵 Ψ ,初始观测阵 Φ 为满秩矩阵,记为

$$\mathbf{y} = \Phi\Psi\mathbf{s} + \mathbf{n} \quad (5)$$

步骤2 ER中各节点通过AIC计算观测信号的变换域能量 $\|\mathbf{y}_E\|_2^2$,寻找最大加权量子集 E_{\max} ,并获取其对应元素个数 $M = |E_{\max}|$ 。AIC由伪随机序列 $p_c(t)$ 相乘器与模拟低通滤波器 $h(t)$ 构成,经低速采样后量化得到自适应观测向量 $\mathbf{y}^{[15,16]}$,则

$$E_{\max}^M = \max_{E_{CA}} \|\mathbf{y}_E\|_2^2 = \max_{E_{CA}} \|\Phi_{E_{\max}} \boldsymbol{\alpha}\|_2^2 \quad (6)$$

步骤3 AIC在初始观测矩阵 $\Phi \in R^{N \times N}$ 中选取 $M = |E_{\max}|$ 个正交行向量构造基于最大加权量子集的子测量矩阵 $\Phi_{E_{\max}} \in R^{M \times N}$,从而产生自适应观测向量 $\mathbf{y}_{E_{\max}}$,进行能耗加权感知向量的压缩反馈,即

$$\mathbf{y}_{E_{\max}} = \Phi_{E_{\max}} \boldsymbol{\alpha} \quad (7)$$

步骤4 由式(7)可知,自适应观测 $\mathbf{y}_{E_{\max}}$ 中的元素是基于最大加权量子集的测量矩阵行向量与能耗加权感知信号向量相乘后得到。若该测量矩阵行向量之间相互独立,则自适应观测向量 $\mathbf{y}_{E_{\max}}$ 元素之间的相关性也相应减少。因此,我们对 $\Phi_{E_{\max}}$ 的行向量还需进行正交化处理,即构造满足定理1的正交自适应观测矩阵。

步骤5 各节点AIC将输出自适应观测向量 $\mathbf{y}_{E_{\max}}$ 进行自相关运算,将自相关向量 $\mathbf{r}_{y,E_{\max}}$ 反馈至汇聚节点。汇聚节点为了重构稀疏系数向量,需准确获知最大加权量子集 E_{\max} ,因此AIC与自相关器将观测向量中的元素位置与该元素对应的自相关值 $(i, r_{y,E_{\max}}(i)), i = 1, 2, \dots, |E_{\max}|$ 压缩反馈给汇聚节点进行稀疏信号重构^[18]。

图1给出了C-WSN中基于能量有效性观测的GPSR压缩重构流程图。

3 汇聚节点GPSR压缩重构

在第 k 个采样时刻, N 个节点经过初始测量后输入AIC的感知信号向量可以表示为 $\mathbf{s}_k = [s_{kN}, s_{kN+1}, \dots, s_{kN+(N-1)}]^T$,AIC输出向量为 $\mathbf{y}_k = [y_{kM}, y_{kM+1}, \dots, y_{kM+(M-1)}]^T$ 。根据CS理论,式(1)可写成




图1 C-WSN中基于能量有效性观测的GPSR压缩重构流程图

$$\mathbf{y}_k = \Xi\mathbf{s}_k + \mathbf{n}_k, \quad k = 0, 1, 2, \dots \quad (8)$$

AIC基于最大加权量子集函数构造自适应观测矩阵 $\Phi_{E_{\max}}$,则输出向量 \mathbf{y}_k 的自相关矩阵 \mathbf{R}_{y_k} 记为

$$\mathbf{R}_{y_k} = E[\mathbf{y}_k\mathbf{y}_k^H] = E[\Xi\mathbf{s}_k\mathbf{s}_k^H\Xi^H] = \Xi\mathbf{R}_s\Xi^H \quad (9)$$

AIC输入与相关器输出的自相关矩阵分别记为 $[\mathbf{R}_s]_{ij} = r_s(i-j), i, j = 1, 2, \dots, N$ 和 $[\mathbf{R}_{y_k}]_{ij} = [r_{y_k}(i-j), i, j = 1, 2, \dots, E_{\max}]$ 。AIC输入 \mathbf{s}_k 与相关器输出 \mathbf{y}_k 的自相关向量分别表示为 $\mathbf{r}_s = [r_s(-N+1), r_s(-N+2), \dots, r_s(N-1), r_s(N)]^T$ 和 $\mathbf{r}_{y_k} = [r_{y_k}(-E_{\max}+1), r_{y_k}(-E_{\max}+2), \dots, r_{y_k}(E_{\max}-1), r_{y_k}(E_{\max})]^T$ 。两者关系为 $\mathbf{r}_{y_k} = \mathbf{X}\mathbf{r}_s$,信号重构问题可以转化为对信号自相关向量的重构^[19],亦为无约束的QP问题,即

$$\hat{\mathbf{r}}_s = \arg \min_{\mathbf{r}_s} \left\{ \|\mathbf{r}_{y_k} - \mathbf{X}\mathbf{r}_s\|_2^2 + \tau \|\mathbf{r}_s\|_1 \right\} \quad (10)$$

其中 $\mathbf{X} = \begin{pmatrix} \Xi\mathbf{X}_1 & \Xi\mathbf{X}_2 \\ \Xi\mathbf{X}_3 & \Xi\mathbf{X}_4 \end{pmatrix} \in R^{2E_{\max} \times 2N}$, $\mathbf{X}_1, \mathbf{X}_2$ 为

Hankel矩阵, $\mathbf{X}_3, \mathbf{X}_4$ 为Toeplitz矩阵^[18]。本方案根据加权量子集选取最佳观测值 E_{\max} ,结合GPSR Barzilai-Borwein(GPSR-BB)凸优化方法^[18],快速搜索合适的步进因子,迭代更新重构向量。

设第 j 个节点的AIC输入自相关向量 $\mathbf{r}_{s,j}$ 可分解为正值部分 \mathbf{u}_j 和负值部分 \mathbf{v}_j ,则 $\mathbf{r}_{s,j} = \mathbf{u}_j - \mathbf{v}_j, j = 1, 2, \dots, N$,其中, $u_j(i) = (r_{s,j}(i))^+, v_j(i) = (-r_{s,j}(i))^+, i = 1, 2, \dots, 2N$ 。 $\mathbf{r}_{s,j}$ 的 l_1 范数为 $\|\mathbf{r}_{s,j}\|_1 = \mathbf{1}_{2N}^T \mathbf{u}_j + \mathbf{1}_{2N}^T \mathbf{v}_j$,其中 $\mathbf{1}_{2N} = (1, 1, \dots, 1)^T$ 为包含 $2N$ 个1的列向量^[13,18]。式(10)可以写成BCQP形式^[13,18]:

$$\left. \begin{aligned} F(\mathbf{z}_j) &= \arg \min_{\mathbf{z}_j} \mathbf{b}^T \mathbf{z}_j + \frac{1}{2} \mathbf{z}_j^T \mathbf{B} \mathbf{z}_j \\ \text{s.t.} \quad & \mathbf{z}_j \geq 0, \quad j = 1, 2, \dots, N \end{aligned} \right\} \quad (11)$$

其中 $\mathbf{z}_j = \begin{pmatrix} \mathbf{u}_j \\ \mathbf{v}_j \end{pmatrix}, \mathbf{b}_t = \mathbf{X}^T \mathbf{r}_{y,j}, \mathbf{b} = \tau \mathbf{1}_{4N} + \begin{pmatrix} -\mathbf{b}_t \\ \mathbf{b}_t \end{pmatrix}$,且

$\mathbf{B} = \begin{pmatrix} \mathbf{X}^T \mathbf{X} & -\mathbf{X}^T \mathbf{X} \\ -\mathbf{X}^T \mathbf{X} & \mathbf{X}^T \mathbf{X} \end{pmatrix}$ 为Toeplitz方阵^[13]。从 $\mathbf{z}_j^{(k)}$ 到

$\mathbf{z}_j^{(k+1)}$ 的迭代更新仅需一次乘法。若第 j 个节点在第 k 个时刻的步进因子 $\alpha_j^{(k)} > 0$,则 $\mathbf{z}_j^{(k)}$ 的迭代更新公式为

$$\mathbf{z}_j^{(k+1)} = \mathbf{z}_j^{(k)} - \alpha_j^{(k)} \nabla F(\mathbf{z}_j^{(k)}) \quad (12)$$

其中 $\nabla F(\mathbf{z}_j^{(k)})$ 为目标函数 $F(\mathbf{z}_j)$ 在第 k 时刻的梯度,即 $\nabla F(\mathbf{z}_j^{(k)}) = \mathbf{b} + \mathbf{B}\mathbf{z}_j^{(k)}$ 。根据计算步进因子的不同,存在两种GPSR重构方法:基本GPSR算法和GPSR Barzilai-Borwein算法(GPSR-BB)^[13,18,19]。本文选取GPSR-BB算法。GPSR-BB算法利用Barzilai-Borwein等式协助计算步进因子 α_j ,在获得最佳估计向量的同时降低计算复杂度。结合本文

所提基于能量有效性观测的加权能量子集测量值 $M = |E_{\max}|$ ，在汇聚节点侧采用 GPSR-BB 压缩重构方法的具体步骤如下^[13,18,19]：

步骤 1 选择初始值 $\mathbf{z}_j^{(0)}$ ，步进因子取值区间为 $[\alpha_{\min}, \alpha_{\max}]$ ，迭代计数器初值 $k = 0$ ；

步骤 2 计算第 j 个节点相邻时刻估计值的步进。采用海深逆矩阵与 $\nabla F(\mathbf{z}_j^{(k)})$ 负梯度矩阵相乘进行近似，即

$$\delta_j^{(k)} = (\mathbf{z}_j^{(k+1)})^+ - \mathbf{z}_j^{(k)} = -\mathbf{H}_k^{-1} \nabla F(\mathbf{z}_j^{(k)}) \quad (13)$$

其中 $\mathbf{z}_j^{(k+1)}$ 在式(12)中给出， $\mathbf{H}_k \approx \eta^{(k)} \mathbf{I}$ 为 $F(\mathbf{z}_j^{(k)})$ 的海深矩阵近似，海深矩阵为 $F(\mathbf{z}_j^{(k)})$ 的二阶偏导数矩阵 $\mathbf{H}_k = \nabla^2 F(\mathbf{z}_j^{(k)})$ 。相邻时刻的目标函数梯度之差为 $\nabla F(\mathbf{z}_j^{(k+1)}) - \nabla F(\mathbf{z}_j^{(k)}) \approx \eta^{(k+1)} (\mathbf{z}_j^{(k+1)} - \mathbf{z}_j^{(k)})$ ，其中第 $(k+1)$ 时刻的 $\eta^{(k+1)}$ 参数选择需要符合最小均方准则^[19]；

步骤 3 通过后向线搜索更新估计值。参数 $\lambda_j^{(k)} \in [0,1]$ 的选择使目标函数 $F(\mathbf{z}_j^{(k+1)})$ 最小化，更新估计向量为

$$\mathbf{z}_j^{(k+1)} = \mathbf{z}_j^{(k)} + \lambda_j^{(k)} \delta_j^{(k)} = \mathbf{z}_j^{(k)} - \lambda_j^{(k)} \mathbf{H}_k^{-1} \nabla F(\mathbf{z}_j^{(k)}) \quad (14)$$

步骤 4 第 j 个认知 WSN 节点在第 k 个时刻的线搜索参数 $\lambda_j^{(k)}$ 采用以下闭式解进行估计：

$$\lambda_j^{(k)} = \text{mid} \left\{ 0, \frac{(\delta_j^{(k)})^T \nabla F(\mathbf{z}_j^{(k)})}{(\delta_j^{(k)})^T \mathbf{B} \delta_j^{(k)}}, 1 \right\} \quad (15)$$

令 $\gamma_j^{(k)} = (\delta_j^{(k)})^T \mathbf{B} \delta_j^{(k)}$ ，如果 $\gamma_j^{(k)} = 0$ ，则 $\lambda_j^{(k)} = 1$ 。更新步进因子 $\alpha_j^{(k)}$ ，即

$$\alpha_j^{(k+1)} = \text{mid} \left\{ \alpha_{\min}, \frac{\|\delta_j^{(k)}\|_2^2}{\gamma_j^{(k)}}, \alpha_{\max} \right\} \quad (16)$$

步骤 5 令 $k = k + 1$ ，根据式(14)进行迭代，直到满足以下收敛条件时，停止迭代^[18]：

$$\|\mathbf{r}_{y,j} - \mathbf{X} \mathbf{r}_{s,j}\|_2^2 \leq \varepsilon \|\mathbf{r}_{y,j} - \mathbf{X} \mathbf{r}_{s,j,GP}\|_2^2 \quad (17)$$

其中 ε 为一个较小的正数。由最佳 $\mathbf{z}_j^{*(k+1)}$ 可重构出第 j 个 C-WSN 节点的 AIC 输入自相关向量 $\mathbf{r}_{s,j}^*$ ，进而得到重构的小波域稀疏系数向量 $\mathbf{s}_{E_{\max}}^*$ ，则重构的能耗加权感知向量为 $\alpha \mathbf{x}_{E_{\max}}^* = \Psi \mathbf{s}_{E_{\max}}^*$ 。

4 仿真与性能分析

本文仿真参数设置如下：C-WSN 中感知节点随机分布于 100×100 的事件区域(ER)内，区域中心为汇聚节点^[1]。PU 与 WSN 节点之间的距离在 $[0,100]$ 内均匀分布，自由空间路径衰耗指数 $n = 2$ ，PU 发射信号强度归一化为 1，各感知信道衰落系数 $|h_i|$ 服从自由度为 2 的中心 chi-square 分布。各 WSN 节点分别对 PU 频谱占用情况进行本地感知，同时根据

节点接收功率 α_i 获得本地节点能耗权值，加权的感知信号在进行 AIC 和基于能量有效性观测的自适应压缩反馈过程中叠加了均值为零，方差为 0.01 的高斯白噪声。汇聚节点采用 GPSR-BB 算法从压缩反馈的观测向量中重构 AIC 输入自相关向量，进一步重构能耗加权感知向量。

图 2 给出了不同感知节点数情况下 OMP 与 GPSR-BB 两种重构方法的重构 MSE 性能。压缩比定义为观测数 M 与感知数据量 N 之比。由图可知，在相同感知节点数情况下，OMP 重构均方误差在低压缩比未收敛时远高于 GPSR-BB 算法，但其收敛速度快，收敛时重构 MSE 随压缩比迅速下降。例如，在感知节点数为 60 的 ER 区域，低压缩比未收敛时的 OMP 重构 MSE 高于 10 dB，在收敛时 OMP 算法的重构均方误差则在 -20 dB 附近波动。GPSR-BB 算法在低压缩比未收敛时的重构均方误差为 0 dB，其在低压缩比区域内具有较小的重构 MSE。当压缩比大于 0.15 时，重构 MSE 随压缩比的增加迅速下降直至收敛，其重构 MSE 可达 -20 dB。GPSR-BB 重构收敛曲线平稳，波动不明显，方差性能较好。对于相同重构算法，重构均方误差随着感知节点数的增加而上升。这是因为感知节点数增加使得感知数据之间的时空相关性增大，当稀疏度一定时，加权能量子集观测数 M 也相应增加。在相同压缩比下，重构均方误差随着节点数增加而上升。

图 3 比较了不同节点数时基于能量有效性观测自适应压缩反馈 GPSR 与随机压缩反馈 GPSR 的重构 MSE 性能。由图可知，随着节点数的增加，GPSR 重构的 MSE 均明显升高，这与图 2 的结果一致。当节点数相同时，自适应压缩反馈 GPSR 重构在低压缩比(压缩比小于 0.2)区域内的重构 MSE 优于随机压缩反馈 GPSR。随机压缩反馈 GPSR 的重构 MSE 在低压缩比区域均在 0 dB 附近波动，但在高压压缩比区域，随机压缩反馈 GPSR 的重构 MSE 将迅速下降并达到收敛。究其原因，采用加权能量子集自适应压缩反馈 GPSR 重构的最优观测数为 $M = 40$ ，当 $N > M$ 时，重构 MSE 收敛值将低于 -10 dB。较随机压缩反馈，基于能量有效性观测的自适应压缩反馈在较低的压缩比(即较少的观测数)情况下即可实现感知信号快速重构。

图 4 比较了不同信噪比时基于能量有效性观测自适应压缩反馈 GPSR 与随机压缩反馈 GPSR 的重构 MSE 性能。为获得较低的均方误差，取仿真节点数为 60。由图可知，相同压缩反馈 GPSR 算法随着 SNR 的提高，重构 MSE 将显著降低，如当 SNR 为 10 dB 时，随着压缩比的增加，自适应压缩反馈




图 2 不同节点数情况下 OMP 与 GPSR-BB 两种重构方法的重构均方误差性能




图 3 不同节点数时自适应压缩反馈与随机压缩反馈重构均方误差

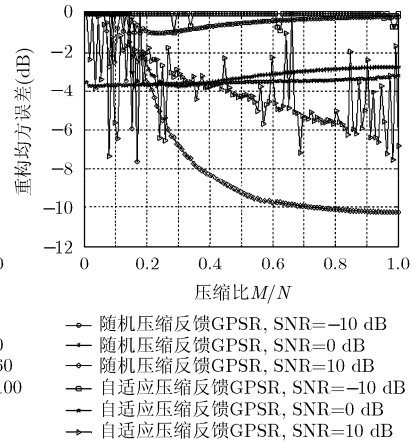


图 4 不同信噪比时自适应压缩反馈与随机压缩反馈重构均方误差

GPSR 算法的重构 MSE 可达 -6 dB, 但波动较大。在低 SNR 情况下, 算法的重构 MSE 较为平稳。此外, 低 SNR 情况下的自适应压缩反馈 GPSR 重构 MSE 性能优于随机压缩反馈, 如当 SNR 为 0 dB 时, 自适应压缩反馈 GPSR 重构 MSE 优于随机压缩反馈约 1 dB, 收敛时重构 MSE 达到 -3.5 dB, 且重构 MSE 随压缩比的变化并不明显。当 SNR 为 10 dB 时, 随机压缩反馈 GPSR 重构 MSE 迅速下降至 -10 dB, 明显优于自适应压缩反馈 GPSR。因此, 基于能量有效性观测的自适应压缩反馈 GPSR 在低信噪比区域具有一定的优势, 可应用于实际 C-WSN 低信噪比场景中。

5 结束语

在 C-WSN 中, 传统压缩反馈机制中采用的测量矩阵为随机高斯或贝努利测量矩阵, 其元素取值具有随机性, 即不具备自适应特性。针对 C-WSN 中感知信号的时空相关性特点, 论文提出了一种基于能量有效性观测的自适应压缩反馈梯度投影稀疏重构(GPSR)方法。该方法以节点接收能耗作为权值, 将加权感知信号通过 AIC 进行稀疏表示与压缩测量, 加权感知向量经正交小波基级联字典稀疏变换后能量守恒, 即以能量有效的方式构造自适应测量矩阵, 形成自适应压缩反馈。汇聚节点采用 GPSR-BB 凸优化算法重构感知信号的自相关向量, 以此获得重构的加权感知向量。仿真结果表明, 在相同重构均方误差要求下, GPSR-BB 算法重构信号所需的观测值小于传统 OMP 贪婪算法所需观测值。基于能量有效性观测的 GPSR 自适应压缩重构在低压缩比和低信噪比情况下的收敛特性均优于随机高斯观测 GPSR 重构, 该方法在低压缩比和低信噪比区域内可实现感知信号的快速重构, 同时有效保障了感知节点的能耗均衡。

参考文献

- [1] 唐亮, 周正, 石磊, 等. 基于能量均衡的无线传感器网络压缩感知算法[J]. 电子与信息学报, 2011, 33(8): 1919-1923.
Tang Liang, Zhou Zheng, Shi Lei, et al. Energy balance based WSN compressive sensing algorithm[J]. *Journal of Electronics & Information Technology*, 2011, 33(8): 1919-1923.
- [2] 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.
- [3] Dyonisius D A and Geert L. Compressive wideband power spectrum estimation[J]. *IEEE Transactions on Signal Processing*, 2012, 60(9): 4775-4789.
- [4] Tsung H Y, Oussama S, Santiago R P, et al. A wideband spectrum sensing processor with adaptive detection threshold and sensing time[J]. *IEEE Transactions on Circuits and Systems*, 2011, 58(11): 2765-2775.
- [5] 唐亮. 压缩感知及其在超宽带无线传感器网络中的应用研究[D]. [博士学位], 北京邮电大学, 2011: 80-95.
Tang Liang. The research of compressive sensing and its application in UWB and wireless sensor networks[D]. [Ph.D. dissertation], Beijing University of Posts and Telecommunications, 2011: 80-95.
- [6] 吴大鹏, 孙青文, 唐季超, 等. 能量有效的无线传感器网络协作压缩感知机制[J]. 电子与信息学报, 2012, 34(11): 2687-2693.
Wu Da-peng, Sun Qing-wen, Tang Ji-chao, et al. Energy efficient cooperative compressive sensing mechanism in wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2012, 34(11): 2687-2693.
- [7] Peyre G. Best basis compressed sensing[J]. *IEEE Transactions on Signal Processing*, 2010, 58(5): 2613-2622.
- [8] 焦李成, 杨淑媛, 刘芳, 等. 压缩感知回顾与展望[J]. 电子学

- 报, 2011, 39(7): 1651-1662.
- Jiao Li-cheng, Yang Shu-yuan, Liu Fang, *et al.* Development and prospect of compressed sensing[J]. *Acta Electronica Sinica*, 2011, 39(7): 1651-1662.
- [9] 李小波. 基于压缩感知的测量矩阵研究[D]. [硕士学位论文], 北京交通大学, 2010: 2-6, 9-16, 22-24.
- Li Xiao-bo. Research on measurement matrix based on compressed sensing[D]. [Master dissertation], Beijing Jiaotong University, 2010: 2-6, 9-16, 22-24.
- [10] 杨海蓉, 张成, 丁大为, 等. 压缩传感理论与重构算法[J]. 电子学报, 2011, 39(1): 142-148.
- Yang Hai-rong, Zhang Cheng, Ding Da-wei, *et al.* The theory of compressed sensing and reconstruction algorithm[J]. *Acta Electronica Sinica*, 2011, 39(1): 142-148.
- [11] 刘亚新, 赵瑞珍, 胡绍海, 等. 用于压缩感知信号重建的正则化自适应匹配追踪算法[J]. 电子与信息学报, 2010, 32(11): 2713-2717.
- Liu Ya-xin, Zhao Rui-zhen, Hu Shao-hai, *et al.* Regularized adaptive matching pursuit algorithm for signal reconstruction based on compressive sensing[J]. *Journal of Electronics & Information Technology*, 2010, 32(11): 2713-2717.
- [12] 叶蕾, 杨震, 王天荆, 等. 行阶梯观测矩阵、对偶仿射尺度内点重构算法下的语音压缩感知[J]. 电子学报, 2012, 40(3): 429-434.
- Ye Lei, Yang Zhen, Wang Tian-jing, *et al.* Compressed sensing of speech signal based on row echelon measurement matrix and dual affine scaling interior point reconstruction method[J]. *Acta Electronica Sinica*, 2012, 40(3): 429-434.
- [13] Figueiredo M A T, Nowak R D, and Wright S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 586-597.
- [14] Wright S J, Nowark R D, and Figueiredo M A T. Sparse reconstruction by separable approximation[J]. *IEEE Transactions on Signal Processing*, 2009, 57(7): 2479-2493.
- [15] Elad M. Optimized projections for compressed sensing[J]. *IEEE Transactions on Signal Processing*, 2007, 55(12): 5695-5702.
- [16] Xu Xiao-rong, Zhang Jian-wu, Huang Ai-ping, *et al.* An adaptive measurement scheme based on compressed sensing for wideband spectrum detection in cognitive WSN[J]. *Journal of Electronics (China)*, 2012, 29(6): 585-592.
- [17] 江若宜, 季薇, 郑宝玉. 无线传感器网络中协作通信的能耗优化方法研究[J]. 电子与信息学报, 2010, 32(6): 1475-1479.
- Jiang Ruo-yi, Ji Wei, and Zheng Bao-yu. Joint optimization of energy consumption in cooperative wireless sensor networks[J]. *Journal of Electronics & Information Technology*, 2010, 32(6): 1475-1479.
- [18] Tan L T, Kong H Y, and Bao V N Q. Projected Barzilai-Borwein methods applied to distributed compressive spectrum sensing[C]. *IEEE International Symposia on New Frontiers in Dynamic Spectrum Access Networks (IEEE DySPAN)*, Singapore, 2010: 1-7.
- [19] 邓军. 基于凸优化的压缩感知信号恢复算法研究[D]. [硕士学位论文], 哈尔滨工业大学, 2011: 20-37.
- Deng Jun. Research on compressive sensing signal reconstruction by convex optimization[D]. [Master dissertation], Harbin Institute of Technology, 2011: 20-37.
- 许晓荣: 男, 1982年生, 讲师, 博士, 研究方向为认知无线网络、压缩感知、无线传感器网络等.
- 姚英彪: 男, 1976年生, 副教授, 博士, 研究方向为无线传感器网络等.
- 包建荣: 男, 1978年生, 副教授, 博士, 研究方向为压缩感知、深空通信信道编码理论等.
- 陆宇: 男, 1977年生, 讲师, 博士, 研究方向为压缩感知、非线性优化理论等.