

# 基于联合稀疏模型的无线传感网数据重构算法

刘义颖, 李国瑞, 田丽

(东北大学计算机科学与工程学院, 辽宁 沈阳 110819)

**摘 要:** 无线传感器网络中数据具有较强联合稀疏特性, 应用压缩感知理论, 通过联合编码压缩数据, 再使用联合解码进行还原, 可实现低采样代价收集传感数据。提出了一种基于联合稀疏模型与压缩感知理论的同步子空间追踪算法, 以稀疏特性为先验知识, 通过回溯迭代方式, 判断并选取合适的联合子空间, 用更少量观测值实现原始传感数据的精确重构。与 SCoSaMP 算法、SP 算法在不同稀疏特性和不同采样率下相比较, 同步子空间追踪算法具有较好的恢复性能。

**关键词:** 无线传感器网络; 压缩感知; 联合稀疏模型; 数据重构

**中图分类号:** TP393

**文献标识码:** A

## Joint sparse model based data reconstruction algorithm for wireless sensor network

LIU Yi-ying, LI Guo-rui, TIAN Li

(School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China)

**Abstract:** The data of wireless sensor network has strong joint sparse characteristics, by utilizing compressed sensing theory, compressed data by joint encoding, and then reconstructed the data by joint decoding, the sensed data can be gathered with low computational cost. A synchronous subspace pursuit algorithm based on joint sparse model and compressed sensing theory was proposed. By utilizing the sparsity of the sensed data, it selected the correct joint subspace and reconstruct the original signal group accurately with fewer observations in a backtracking iterative manner. Compared with SCoSaMP algorithm and SP algorithm, the proposed algorithm presents better data reconstruction performance under the conditions of different sparsity and sampling rate.

**Key words:** wireless sensor network, compressive sensing, joint sparse model, data reconstruction

### 1 引言

随着物联网应用的日益普及, 作为其核心技术之一的无线传感器网络已成为国内外学者关注和研究的重点。无线传感器网络是由大量部署在监测区域内的微型传感器节点组成, 通过无线通信方式形成的一个多跳的自组织网络系统, 其目的是协作感知、采集和处理网络覆盖区域内观测对象的相关信息, 并发送至观察者。无线传感器节点的计算、

存储和传输能力均受到限制, 通过对感知数据进行压缩采集, 可以有效地降低传感器网络的能量消耗。目前, 如何对无线传感器网络中的数据进行分布式压缩式采集, 进而延长传感器网络的工作寿命, 已成为无线传感器网络研究中的核心问题之一。

Candès 和 Donoho 等于 2006 年提出了一种新的信号处理理论——压缩感知 (CS, compressive sensing) 理论<sup>[1-3]</sup>。区别于传统信号采集时必须满足香农采样定理的要求, 压缩感知理论指出: 若信号是

收稿日期: 2016-09-02

通信作者: 李国瑞, lgr@neuq.edu.cn

基金项目: 国家自然科学基金资助项目(No.61402094); 辽宁省自然科学基金资助项目(No.201602254); 河北省自然科学基金资助项目(No.F2016501076)

**Foundation Items:** The National Natural Science Foundation of China(No.61402094), The Natural Science Foundation of Liaoning Province (No.201602254), The Natural Science Foundation of Hebei Province (No.F2016501076)

稀疏或可压缩的,对信号进行少量的随机投影并采用相应的重构算法就可重构出原始信号。也就是说,采样少量信息即可精确重构原始信号,从而可以减少数据采集和传输过程中的能量消耗。针对无线传感器网络应用场景,各传感器节点采集数据存在较强的时空相关性,可在相关稀疏基矩阵或字典下进行稀疏表达,从而为无线传感器网络分布式数据压缩采集提供了可行性。

压缩感知理论本身特性使其在生物<sup>[4]</sup>、雷达跟踪<sup>[5]</sup>、定位<sup>[6]</sup>、成像<sup>[7]</sup>和图像处理<sup>[8]</sup>等领域得到了广泛的应用,也成为了一种新的无线传感器网络数据采集技术<sup>[9-13]</sup>。传统的将压缩感知理论重点应用于单个传感器数据的独立压缩采集,而利用无线传感器网络中数据的时空相关性,建立合理的网络数学模型,可以实现多传感节点数据联合压缩采集,更大程度减小传感节点能量的消耗,延长网络生命周期。目前已有很多解决传统的压缩感知理论与无线传感器网络结合的数据重构算法<sup>[14-16]</sup>,本文针对无线传感器网络数据的时空相关性,提出一种重构联合稀疏特性数据的算法。

本文的主要贡献如下。

1) 针对无线传感器网络采集数据具有联合稀疏特性,提出同步子空间追踪算法。该算法利用传感数据的时空相关特性,通过回溯迭代方式实现用更少量采样信息精确重构原始传感数据,属于基于联合稀疏模型的数据重构算法。

2) 通过性能分析实验,验证了提出的联合稀疏重构算法相比其他联合稀疏重构算法以及传统稀疏重构算法有较好的重构性能。

## 2 压缩感知理论

压缩感知理论以信号具有稀疏特性为先验条件,主要包括信号的稀疏表达、编码测量及重构算法等 3 个方面<sup>[17]</sup>。若信号  $\mathbf{x} \in R^N$  中非零元素个数为  $k \ll N$ , 则信号  $\mathbf{x}$  可在某组稀疏基  $\Psi = [\psi_1, \psi_2, \dots, \psi_N]$  上进行  $k$ -稀疏表达

$$\mathbf{x} = \sum_{i=1}^k \psi_i \theta_i = \Psi \boldsymbol{\theta} \quad (1)$$

用一个与  $\Psi$  不相关的观测矩阵  $\Phi \in R^{M \times N} (M \ll N)$  对信号  $\mathbf{x}$  进行线性投影,可得到采样信号  $\mathbf{y} \in R^M$ , 即

$$\mathbf{y} = \Phi \mathbf{x} \quad (2)$$

得到的测量信号  $\mathbf{y}$  的维度远低于原始信号  $\mathbf{x}$ ,

从而实现了信号的压缩。而与传统数据采集不同,压缩感知理论在采集中便完成了数据的压缩,并不需要获取到信号的完整信息。此时的关键问题就是用得到的低维度测量信号  $\mathbf{y}$  还原原始信号  $\mathbf{x}$ 。显然,理论上式(2)不可解,即不能通过  $\mathbf{y}$  重构原始信号  $\mathbf{x}$ 。但当信号  $\mathbf{x}$  满足稀疏特性时,由式(1)可将式(2)转化为

$$\mathbf{y} = \mathbf{A} \boldsymbol{\theta} \quad (3)$$

其中,  $\mathbf{A} = \Phi \Psi$ , 此时可将求解式(2)转化为求解式(3)。

为确保能重建原始信号  $\mathbf{x}$ ,除须满足稀疏特性外,还需测量矩阵  $\Phi$  满足约束等距条件<sup>[18]</sup>,此约束条件一般通过稀疏基  $\Psi$  与观测矩阵  $\Phi$  不相关来保证<sup>[18]</sup>。此时,可通过  $l_0$  范数最小化问题来求解式(3)

$$\begin{aligned} \hat{\boldsymbol{\theta}} &= \arg \min \|\boldsymbol{\theta}\|_0 \\ \text{s.t. } & \mathbf{A} \boldsymbol{\theta} = \mathbf{y} \end{aligned} \quad (4)$$

再由式(1)可精确重构出原始信号  $\mathbf{x}$ 。

式(4)是一个 NP-难问题,目前有很多方法求解这个问题,常采用的算法中贪婪算法具有最快重构速度。代表性的贪婪算法包括匹配追踪 (MP, matching pursuit)、正交匹配追踪 (OMP, orthogonal matching pursuit)、分级正交匹配追踪 (SOMP, stagewise orthogonal matching pursuit)、压缩采样匹配追踪 (CoSaMP, compressive sampling matching pursuit)、子空间追踪 (SP, subspace pursuit)<sup>[19]</sup>等。SP 算法通过利用迭代逼近的方法获取每次候选原子支撑集。通过对当前估计支撑集的正确性进行判断,并剔除不可用原子集合,直到可精确重构信号,相比于其他贪婪算法有更高的还原精度。

Blanchard 等<sup>[20]</sup>提出了几种联合稀疏重构算法:同步迭代硬阈值算法 (SIHT, simultaneous iterative hard thresholding)、同步硬阈值追踪算法 (SHTP, simultaneous hard thresholding pursuit)、同步压缩采样匹配追踪 (SCoSaMP, simultaneous compressive sampling matching pursuit) 算法。SIHT 算法是基于迭代的思想,在联合稀疏条件下,每次以固定阈值确定的非线性算子估算代理信号,根据信号稀疏特性选取支撑集并计算选取对应原子,实现信号重构。SHTP 算法以非线性算子估算原始信号,依据信号大小选取与去除原子,通过最小二乘法一次性实现传感数据的重构。SCoSaMP 算法的主要思想是基于联合稀疏模型,采用回溯的思想,迭代时选取与代理信号中稀疏度 2 倍的最大传感数据子矩阵所

对应的序号集合，与上次迭代序号集合取并作为本次的候选序号集合，最后利用最小二乘法求出该序号集合上的传感数据子矩阵。实验表明 3 种算法中 SCoSaMP 算法还原精度高于另外 2 种算法。

### 3 同步子空间追踪算法

针对传感数据的内相关与互相关性，进行合理建模，可一次性对多个信号进行联合重构，实现用更少量观测值精确重构出原始传感数据。Baron 提出了 3 种联合稀疏模型 (JSM, joint sparse model): JSM1、JSM2、JSM3，这 3 种联合稀疏模型是近年来研究无线传感器网络数据建模的基础。康莉等<sup>[21]</sup>对 3 种模型进行了总结：假设有信号  $\mathbf{x}_t$ ，在 JSM1 下可表示为

$$\mathbf{x}_t = \mathbf{z}_c + \mathbf{z}_t, t \in \{1, 2, \dots, T\} \quad (5)$$

其中， $\mathbf{z}_c$  为信号的共同稀疏部分， $\mathbf{z}_t$  为信号的个体稀疏部分，且这 2 部分可用同一个稀疏基进行表示。

$$\begin{aligned} \mathbf{z}_c &= \Psi \boldsymbol{\theta}_c, \|\boldsymbol{\theta}_c\|_0 = K_c \\ \mathbf{z}_t &= \Psi \boldsymbol{\theta}_t, \|\boldsymbol{\theta}_t\|_0 = K_t \end{aligned} \quad (6)$$

其中， $\boldsymbol{\theta}_c$  为  $\mathbf{z}_c$  在稀疏基  $\Psi$  上的变换系数， $K_c$  表示  $\mathbf{z}_c$  在稀疏基  $\Psi$  上的稀疏度， $\boldsymbol{\theta}_t$  为  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的变换系数， $K_t$  表示  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的稀疏度。在 JSM2 下信号  $\mathbf{x}_t$  可表示为

$$\begin{aligned} \mathbf{x}_t &= \mathbf{z}_t = \Psi \boldsymbol{\theta}_t, \\ \|\boldsymbol{\theta}_t\|_0 &= K, t \in \{1, 2, \dots, T\} \end{aligned} \quad (7)$$

其中， $\mathbf{z}_t$  为信号的个体稀疏部分， $\boldsymbol{\theta}_t$  为  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的稀疏表达， $K$  表示  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的稀疏度。JSM2 中信号只包含具有相同稀疏基的个体稀疏部分，每个信号均可稀疏且稀疏度相同，但系数不同。在 JSM3 下信号  $\mathbf{x}_t$  可表示为

$$\mathbf{x}_t = \mathbf{z}_c + \mathbf{z}_t, t \in \{1, 2, \dots, T\} \quad (8)$$

其中， $\mathbf{z}_c$  为信号的共同非稀疏部分， $\mathbf{z}_t$  为信号的个体稀疏部分。虽然信号在 JSM3 下与在 JSM2 下表示相同，但 JSM3 表示中，只有  $\mathbf{z}_t$  可在稀疏基  $\Psi$  上进行稀疏表达

$$\begin{aligned} \mathbf{z}_c &= \Psi \boldsymbol{\theta}_c \\ \mathbf{z}_t &= \Psi \boldsymbol{\theta}_t, \|\boldsymbol{\theta}_t\|_0 = K_t \end{aligned} \quad (9)$$

其中， $\boldsymbol{\theta}_t$  为  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的变换系数， $K_t$  表示  $\mathbf{z}_t$  在稀疏基  $\Psi$  上的稀疏度， $\mathbf{z}_c$  不能在稀疏基  $\Psi$  上稀疏表示。本文基于 JSM2 提出一种同步子空间追踪

(SSP, simultaneous subspace pursuit) 算法。

用矩阵  $\mathbf{X} \in R^{S \times T}$  和矩阵  $\mathbf{Y} \in R^{M \times T}$  分别表示多传感节点数据与联合采样数据，则

$$\begin{aligned} \mathbf{X} &= \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_i \end{bmatrix}, i \in \{1, 2, \dots, S\} \\ \mathbf{Y} &= \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_j \end{bmatrix}, j \in \{1, 2, \dots, M\} \end{aligned} \quad (10)$$

其中， $S$  表示传感器节点数目， $T$  表示传感数据采集周期，向量  $\mathbf{x}_t \in R^{1 \times T}$  表示单传感节点在采样周期内的传感数据，向量  $\mathbf{y}_t \in R^{1 \times T}$  表示单传感节点在采样周期内的压缩采样数据。观测矩阵为  $\Phi \in R^{M \times S}$ ，整个采样过程可用式(2)表示。假设  $\mathbf{X}$  符合 JSM2，则  $\mathbf{X}$  可用式(1)进行稀疏表达，其中，稀疏基可用  $\Psi \in R^{S \times S}$  表示。为重构  $\mathbf{X}$ ，可将式(4)转化为求解最优  $l_1$  范数问题

$$\begin{aligned} \min_{\boldsymbol{\theta}} & \|\boldsymbol{\theta}\|_1 \\ \text{s.t.} & \mathbf{A}\boldsymbol{\theta} = \mathbf{Y} \end{aligned} \quad (11)$$

其中， $\boldsymbol{\theta}$  为  $\mathbf{X}$  在稀疏基  $\Psi$  下的稀疏表达， $\mathbf{A} = \Phi\Psi$ ，SSP 算法就是寻求上述问题的逼近解。

SSP 算法以与残差最匹配为原则，以数据的联合稀疏特性为标准，实现选取可精确重构原站数据的子空间。残差即由原始数据得到的采样数据与原始数据的逼近值求得的采样数据的差

$$\mathbf{Y}_r = \mathbf{Y} - \mathbf{A}\tilde{\boldsymbol{\theta}} \quad (12)$$

其中， $\mathbf{Y}$  表示原始采样数据， $\mathbf{Y}_r$  表示残差。SSP 算法中残差算式为

$$\mathbf{Y}'_r = \text{resid}(\mathbf{Y}_r, \mathbf{A}_T) \quad (13)$$

其中， $T$  表示支撑集，即选取的数据子空间所对应的序号集合， $\mathbf{Y}_r$  表示上一次迭代过程产生的残差， $\mathbf{A}_T$  表示在支撑集  $T$  上的观测矩阵分量， $\mathbf{Y}'_r$  表示本次迭代当前的残差。求取前  $R$  个与当前残差最匹配的传感数据子矩阵所对应的序号集合并与支撑集  $T$  合并，可得到当前候选支撑集

$$\mathbf{Q} = \text{DetectSupport}(\mathbf{A}^T \mathbf{Y}_r, R) \cup T_0 \quad (14)$$

其中， $R$  表示数据的联合稀疏特性，即数据矩阵的

秩,  $\mathcal{Q}$  为当前候选支撑集。根据当前候选支撑集可计算出当前最匹配的候选数据子空间

$$\mathbf{U} = \arg \min_{\text{supp}(\mathbf{W}) \subseteq \mathcal{Q}} \|\mathbf{Y} - \mathbf{A}\mathbf{W}\|_F \quad (15)$$

其中,  $\mathbf{U}$  为当前最匹配的候选数据子空间,  $\mathbf{W}$  为当前候选支撑集上的候选子空间, 式(15)可利用最小二乘法求解。根据当前候选数据子空间与数据的联合稀疏特性求得本次迭代支撑集

$$\mathbf{T} = \text{DetectSupport}(\mathbf{U}, R) \quad (16)$$

其中,  $\mathbf{T}$  表示本次迭代产生的支撑集, 可用于下次迭代选取与残差最匹配的数据子空间或计算本次与残差最匹配的数据子空间。算法迭代停止的条件为

$$\|\tilde{\mathbf{Y}}_r\|_2 > \|\mathbf{Y}_r\|_2 \quad (17)$$

即当本次迭代的残差大于上次迭代的残差时, 迭代停止, 在本次迭代产生的支撑集上求得的数据子空间即为传感数据稀疏表达的逼近解

$$\boldsymbol{\theta}' = \arg \min_{\text{supp}(\mathbf{W}) \subseteq \mathbf{T}} \|\mathbf{Y} - \mathbf{A}\mathbf{W}\|_F \quad (18)$$

其中,  $\boldsymbol{\theta}'$  为原始传感数据稀疏表达的逼近解, 根据式(1)可用  $\boldsymbol{\theta}'$  恢复出原始传感数据。SSP 算法的伪代码如算法 1 所示。

**算法 1** SSP 算法

**输入** 观测矩阵  $\mathbf{A}$ , 采样数据  $\mathbf{Y}$ , 数据矩阵的秩  $R$

**输出** 传感数据稀疏表达  $\boldsymbol{\theta}$  的逼近解  $\boldsymbol{\theta}'$

1) 初始化残差为  $\mathbf{Y}_r = \mathbf{Y}$ , 初始化最匹配的候选数据子空间为  $\mathbf{U} = \mathbf{A}^\top(\mathbf{Y} - \mathbf{A}\boldsymbol{\theta})$ , 根据式(16)初始化支撑集。

2) 新增候选支撑集: 由式(14)计算与当前残差最匹配的前  $R$  个传感数据子矩阵所对应的序号集合与当前支撑集的并集。

3) 计算当前候选支撑集上最匹配的数据子空间  $\mathbf{U} = \arg \min_{\text{supp}(\mathbf{W}) \subseteq \mathcal{Q}} \|\mathbf{Y} - \mathbf{A}\mathbf{W}\|_F$ 。

4) 由式(16)计算本次迭代支撑集。

5) 更新残差  $\tilde{\mathbf{Y}}_r = \text{resid}(\mathbf{Y}_r, \mathbf{A}_r)$ , 若达到式(17)给出的迭代停止条件, 停止执行, 由式(18)计算  $\boldsymbol{\theta}'$  并输出。否则, 令  $\mathbf{T}_0 = \mathbf{T}, \mathbf{Y}_r = \tilde{\mathbf{Y}}_r$ , 回到第 2) 步继续执行。

SSP 算法是一种应用于联合稀疏模型的信号重构算法, 本质仍遵循贪婪算法的迭代思想, 以稀疏特性为先验知识, 通过回溯迭代方式, 判断并选取

合适的联合子空间, 对传感数据进行联合重构。联合稀疏模型具有时空相关特性, SSP 算法在迭代选择过程中不需要为模型中的传感数据子矩阵依次进行支撑集的选择与更新。利用传感数据内相关与互相关性, 用更少量观测值实现原始传感数据的精确重构。

**4 实验与性能分析**

本文使用 Matlab 软件在 CPU 为 Intel Core i3 3, 30 GHz、内存 2 GB 的某品牌台式电脑环境下进行实验。实验参考 Gogna 等<sup>[12]</sup>提出的方法设计具有时空相关性的数据, 将一个列满秩矩阵与一个行满秩矩阵的乘积作为原始传感数据数据。实验主要分为 2 个部分, 一部分是分析 SSP 算法本身在不同稀疏特性与不同采样率下的还原精度, 另一部分是对比分析 SP 算法、SCoSaMP 算法与本文提出的 SSP 算法在不同稀疏特性与不同采样率下的还原精度与恢复效率。

实验用原始数据与重构数据的信噪比作为评判还原精度的标准。信噪比定义为

$$\text{SNR} = 10 \lg \frac{\|\mathbf{X}\|_2}{\|\mathbf{X} - \mathbf{X}'\|_2} \quad (19)$$

其中,  $\mathbf{X}$  为原始传感数据,  $\mathbf{X}'$  为  $\mathbf{X}$  压缩采样后经过 SSP 算法还原的传感数据。因采样传感数据必须满足维度大于原始传感数据的秩才能实现信号重构, 所以实验中设定采样传感数据维度以原始信传感数据的 2 倍作为起始值进行实验。4.1 节对 SSP 算法自身性能进行了分析, 4.2 节通过 SSP 算法与 SCoSaMP 算法和 SP 算法进行对比验证了算法性能。

**4.1 性能分析**

通过 3 部分实验对 SSP 算法进行了性能分析。

实验 1 设定将 256 个传感器节点随机分布在大小为  $100 \times 100$  的网格区域内, 采集传感数据的周期  $T$  为 256, 采样率为 0.5, 稀疏特性为 20, 分析 SSP 算法的重构性, 用原始数据与重构数据的残差来表示, 当残差小于  $10^{-6}$  时, 可以判定数据重构性较高。图 1 显示了实验条件下原始传感数据与重构传感数据以及 2 种数据的残差, 可以看出残差的范围小于  $10^{-13}$ , 因此 SSP 算法有很高的重构性。

实验 2 同样设定将 256 个传感器节点随机分布在大小为  $100 \times 100$  的网格区域内, 采集传感数据的周期  $T$  为 256, 分析 SSP 算法在不同稀疏特性与不同观测数目下的重构性, 用原始信号与重构信号的信噪比

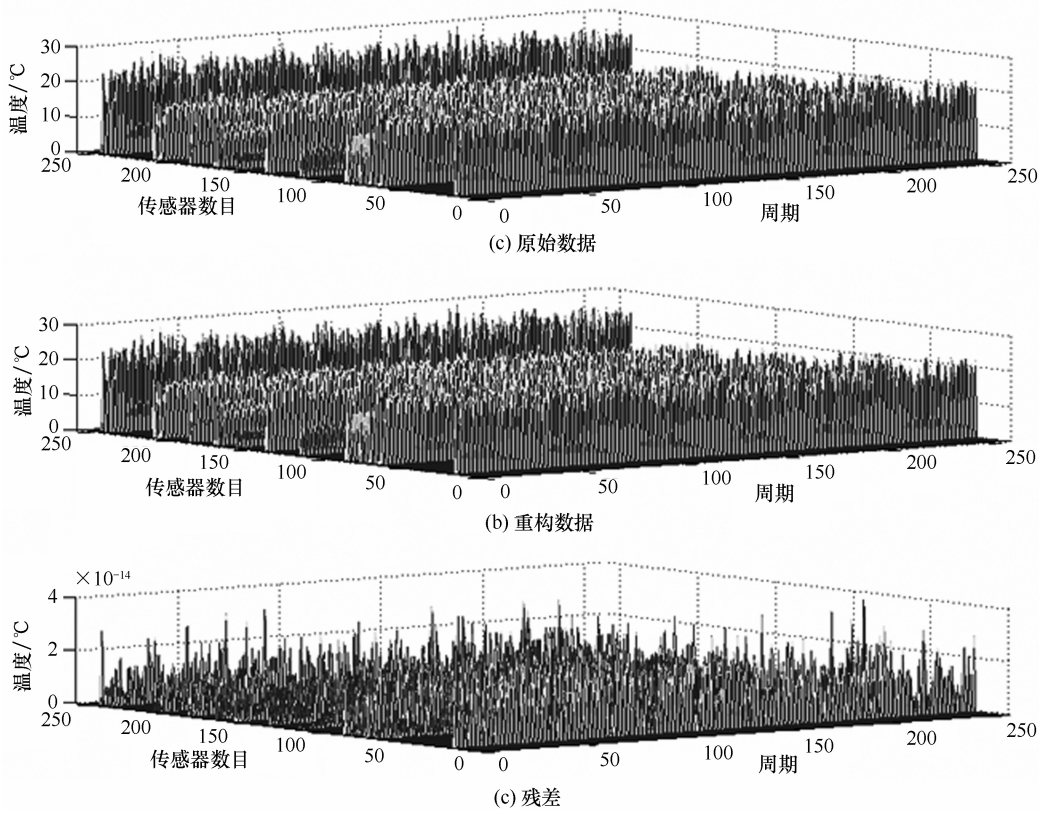


图1 原始数据、重构数据和残差

来表示。图 2 展示了 SSP 算法在不同稀疏特性与不同采样率下的信噪比。可以看出，稀疏特性一定的情况下，随着采样率的增加，原始传感数据与还原传感数据的信噪比逐渐增高，表明 SSP 算法恢复性能随着采样率的增加逐步增强。而当采样率一定时，原始传感数据与还原传感数据的信噪比随着稀疏特性的加强逐渐增加，显示出 SSP 算法可以在传感数据有较强时空相关性时精确重构原始传感数据。




图2 SSP 算法在不同稀疏特性与不同采样率下信噪比

实验 3 主要验证 SSP 算法在不同传感节点规模

下的性能。实验设定分别将 256、512、768、1 024 个传感器节点随机分布在大小为  $100 \times 100$  的网格区域内，采集传感数据的周期  $T$  分别为 256、512、768、1 024，选取具有相同稀疏特性的传感数据进行分析实验。图 3 展示了 SSP 算法在稀疏特性与采样率相同而传感节点规模不同情况下的信噪比。可以看出，在稀疏特性与采样率一定的情况下，随着传感节点规模的增加，原始传感数据与还原传感数据的信噪比逐渐增高，表明 SSP 算法恢复性能随着传感节点规模的扩大逐步增强。




图3 SSP 算法在不同传感节点规模下信噪比

### 4.2 性能比较

通过 3 部分实验对 SSP 算法、SCoSaMP 算法与 SP 算法进行了性能比较分析。

实验 4 设定将 256 个传感器节点随机分布在大小为  $100 \times 100$  的网格区域内, 收集周期  $T$  为 256 的时段内的传感数据, 选取具有不同稀疏特性的传感数据进行分析实验, 表 1 显示了 3 种数据重构算法在不同稀疏特性与不同采样率下原始传感数据与还原传感数据的信噪比, 对比可看出: 在相同稀疏特性下, 当采样率相同时, SSP 算法与 SP 算法的信噪比相同, 但明显高于 SCoSaMP 算法, 证明同等稀疏特性下使用 3 种算法重构原始传感数据, SSP 算法的重构精度高于 SCoSaMP 算法。从图 4(a) 中可明显观察到这一性能分析结果。对比不同稀疏特性下各算法的信噪比, 可看出当传感数据的秩越低时, SSP 算法的 SNR 越大于 SCoSaMP 算法的 SNR, 证明 SSP 算法在联合稀疏特性较明显的情况下相比其他算法有更好的还原精度。

表 1 3 种算法在不同稀疏特性与不同采样值下信噪比

传感数据秩	观测值	SNR/dB		
		SCoSaMP	SP	SSP
4	20	32.8	41.6	41.6
4	35	148.4	153.0	153.0
4	60	155.8	157.0	157.0
4	75	155.9	157.2	157.2
20	60	11.7	48.6	48.6
20	80	138.3	153.4	153.4
20	100	150.0	153.6	153.6
20	120	152.1	153.8	153.8
36	100	2.0	106.1	106.1
36	120	136.7	151.9	151.9
36	140	147.6	152.5	152.5
36	160	149.8	152.6	152.6

实验 5 与实验 4 设定相同, 验证 3 种算法在不同稀疏特性与不同采样率下的传感数据还原速率。观察表 2 可得出, 当稀疏特性相同时, SSP 算法与 SCoSaMP 算法还原传感数据的时间基本相同, 但明显少于 SP 算法还原传感数据的时间, 证明在稀疏特性相同的情况下, SSP 算法有较高的还原效率。

在不同稀疏特性下, 可看出当稀疏特性较明显时, SSP 算法的还原效率较高一些, 但变化不显著。

表 2 3 种算法在不同稀疏特性与不同采样值下还原时间

传感数据秩	观测值	还原时间/s		
		SCoSaMP	SP	SSP
4	20	0.016	0.312	0.009
4	35	0.015	0.328	0.015
4	60	0.016	0.343	0.016
4	75	0.016	0.359	0.015
20	60	0.016	0.687	0.016
20	80	0.016	1.138	0.016
20	100	0.015	0.968	0.015
20	120	0.016	0.827	0.016
36	100	0.016	1.513	0.015
36	120	0.031	1.357	0.032
36	140	0.047	1.419	0.047
36	160	0.031	1.404	0.047

实验 6 设定分别将 256、512、768、1 024 个传感器节点随机分布在大小为  $100 \times 100$  的网格区域内, 采集传感数据的周期  $T$  分别为 256、512、768、1 024, 选取具有相同稀疏特性的传感数据进行分析实验。图 4(a)~图 4(d)分别为传感数据规模为  $256 \times 256$ 、 $512 \times 512$ 、 $768 \times 768$ 、 $1\ 204 \times 1\ 204$  时 3 种算法在相同稀疏特性与相同采样率下的信噪比。对比可看出, 当矩阵规模变大时, SSP 算法的重构精度仍高于 SCoSaMP 算法的重构精度。

实验结果表明, SSP 算法对联合稀疏特性较明显的传感数据有更高的重构精度和还原速率, 重构精度高于联合稀疏重构算法 SCoSaMP, 还原速率高于单稀疏传感数据重构算法 SP 算法。

### 5 结束语

基于联合稀疏模型, 利用压缩感知理论进行无线传感器网络分布式数据采集, 实现了用更少的数据采集重构原始传感数据, 解决了无线传感器网络中传感器节点计算、存储传输的局限性问题, 提高了无线传感器网络数据采集效率。本文提出的同步子空间追踪算法, 针对无线传感器网络数据的联合稀疏特性, 以联合稀疏特性为先验知识, 计算支撑集并在其上选取最匹配的传感数据子矩阵, 通过迭代逼近, 还原传感数据。该算法基于联合稀疏模型与压缩感知理论, 相比单重构算法, 可通过更少的

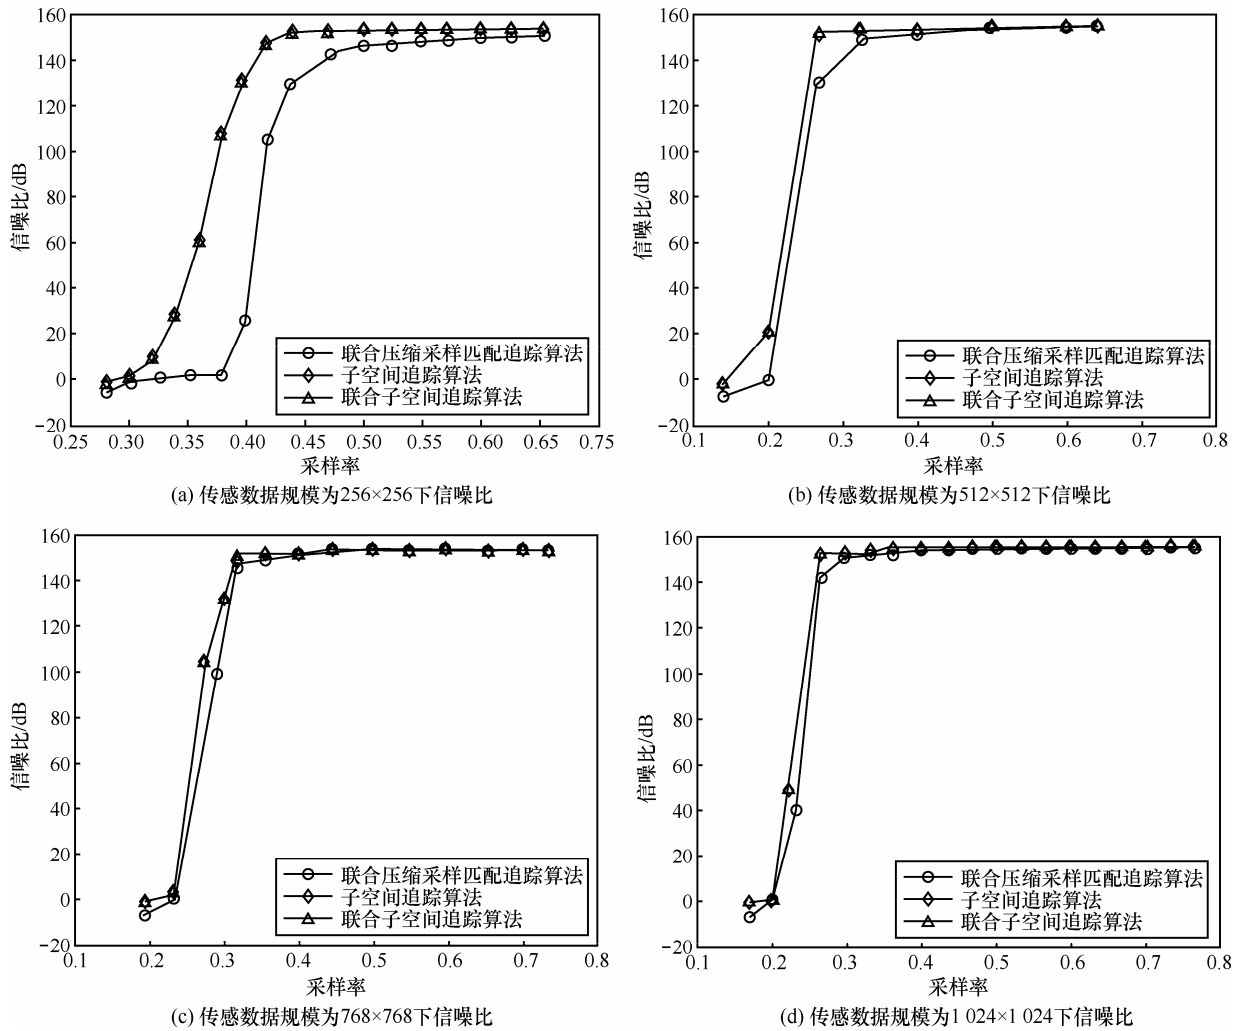


图 4 传感数据规模分别为 256×256、512×512、768×768、1 024×1 024，传感数据秩为 36 时 3 种算法在相同采样率下的信噪比

采样值实现原始传感数据的精确重构，提高传感数据还原速率。与 SCoSaMP 算法、SP 算法在不同稀疏特性和不同采样率下相比较，具有较好的恢复性能。但 SSP 算法以联合稀疏特性为先验条件，具有一定的局限性，后期将进一步优化联合稀疏特性的选择，使 SSP 算法有更广范围的应用。

参考文献：

[1] 许志强. 压缩感知[J]. 中国科学, 2012,42(9):865-877.  
 XU Z Q. Compressed sensing[J]. Science China, 2012, 42(9): 865-877.

[2] 戴琼海,付长军,季向阳. 压缩感知研究[J]. 计算机学报, 2011,34(3): 425-434.  
 DAI Q H, FU C J, JI X Y. Research on compressed sensing[J]. Chinese Journal of Computers, 2011, 34(3): 425-434.

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

[4] UDDIN B, CELEBI M E, KINGRAVI H. Accurate genomic signal recovery using compressed sensing[C]//International Conference on Pattern Recognition. 2012:3144-3147.

[5] KYRIAKIDES I. Adaptive compressive sensing and processing of delay-doppler radar waveforms[J]. IEEE Transactions on Signal Processing, 2012, 60(2): 730-739.

[6] LIU L, CHONG J S, WANG X Q. Adaptive source location estimation based on compressed sensing in wireless sensor networks[J]. International Journal of Distributed Sensor Networks, 2012, 8(1): 1-15.

[7] LIANG M, LI Y, MENG H. Reconfigurable array design to realize principal component analysis (PCA)-based microwave compressive sensing imaging system[J]. IEEE Antennas and Wireless Propagation Letters, 2015, 14: 1039-1042.

[8] AHN J H. Compressive sensing and recovery for binary images[J]. IEEE Transactions on Image Processing, 2016, 25(10): 4796-4802.

[9] WANG J, TANG S J, YIN B C. Data gathering in wireless sensor networks through intelligent compressive sensing[C]//International Conference on Computer Communications. 2012: 603-611.

[10] XU L W, QI X, WANG Y X. Efficient data gathering using compressed sparse functions[C]//International Conference on Computer Communications. 2013: 310-314.

[11] MALLOY M L, NOWAK R D. Near-optimal adaptive compressed sensing[J]. IEEE Transactions on Information Theory, 2014, 60(7): 4001-4012.

- [12] LI X L, TAO X F, LIU Y J. Autoregressive model based data gathering algorithm for wireless sensor networks with compressive sensing[C]//International Symposium on Personal, Indoor, and Mobile Radio Communications. 2015: 2044-2048.
- [13] SHEN Y R, HU W, RANA R. Nonuniform compressive sensing for heterogeneous wireless sensor networks[J]. IEEE Sensors Journal, 2013, 13(6):2120-2128.
- [14] 方红, 杨海蓉. 贪婪算法与压缩感知理论[J]. 自动化学报, 2011,37(12):1414-1421.  
FANG H, YANG H R. Greedy algorithms and compressed sensing[J]. Acta Automatica Sinica, 2011, 37(12): 1414-1421.
- [15] YU Z L, SU J C, YANG F. Fast compressive sensing reconstruction algorithm on FPGA using orthogonal matching pursuit[C]// International Symposium on Circuits and Systems. 2016: 249-252.
- [16] LIN Y M, KUO H C, WU A Y. Robust LMS-based compressive sensing reconstruction algorithm for noisy wireless sensor networks[C]//International Conference on Intelligent Green Building and Smart Grid. 2016: 1-5.
- [17] 李树涛, 魏丹. 压缩传感综述[J]. 自动化学报, 2009, 35(11): 1370-1377.  
LI S T, WEI D. A survey on compressive sensing[J]. Acta Automatica Sinica, 2009, 35(11): 1370-1377.
- [18] CANDÈS E J. The restricted isometry property and its implications for compressed sensing[J]. Comptes Rendus Mathematiques, 2008, 346(9-10): 589-592.
- [19] DAI W, MILENKOVIC O. Subspace pursuit for compressive sensing signal reconstruction[J]. IEEE Transactions on Information Theory, 2009, 55(5): 2230-2249.
- [20] BLANCHARD J D, CERMAK M, HANLE D. Greedy algorithms for joint sparse recovery[J]. IEEE Transactions on Signal Processing, 2014, 62(7): 1964-1704.
- [21] 康莉, 谢维信, 黄建军. 无线传感器网络中的分布式压缩感知技术[J]. 信号处理, 2013, 29(11): 1560-1567.  
KANG L, XIE W X, HUANG J J. Distributed compressive sensing for wireless sensor networks[J]. Journal of Signal Processing, 2013, 29(11): 1560-1567.
- [22] GOGNA A, SHUKLA A, AGARWAL H K. Split bregman algorithms for sparse/joint-sparse and low-rank signal recovery: application in compressive hyperspectral imaging[C]//IEEE International Conference on Image Processing. 2014: 1302-1306.

#### 作者简介:



刘义颖 (1991-), 女, 河北保定人, 东北大学硕士生, 主要研究方向为无线传感器网络、压缩感知。



李国瑞 (1980-), 男, 山西夏县人, 博士, 东北大学副教授、硕士生导师, 主要研究方向为无线传感器网络、压缩感知。



田丽 (1991-), 女, 河北唐山人, 东北大学硕士生, 主要研究方向为无线传感器网络、压缩感知。