

基于分布式压缩感知的无线传感器网络异常数据处理

侯明星¹ 亓慧¹ 黄斌科²

1 太原师范学院计算机科学与技术系 山西 晋中 030619

2 西安交通大学电子与信息工程学院 西安 710049

(mingxing_hou@qq.com)



摘要 无线传感器网络的海量数据采集、传输和处理,对传感器节点的处理能力和功耗提出了严峻挑战,而且现实环境中传感器故障或者环境因素的突变会导致部分采集数据异常,而传统的数据处理方法无法对包含异常的数据进行有效的处理。针对上述问题,文中提出了两类无线传感器网络的异常数据模型,以及相应的基于分布式压缩感知的异常数据处理方法。通过协同的多个传感器进行数据压缩采样,当多个传感器采集的数据包含异常成分时,分布式压缩感知技术对数据中相同的正常分量进行一次统一重构,仅对不同的异常分量进行单独重构,从而避免了对相同数据分量的重复处理,提高了对包含异常成分数据处理的效率。另外,分布式压缩感知技术充分利用数据间的相关性,可有效减少传感器网络的数据采集量,加强其对抗异常数据的鲁棒性。对两类异常数据模型的数值仿真结果表明:相比于传统的基于单组测量值的压缩感知技术,基于分布式压缩感知技术的数据处理方法在提高异常数据重构准确率的同时,将采样数据量减少了约 33%,证明了该方法的有效性。

关键词: 分布式压缩感知;无线传感器网络;异常数据;联合稀疏;压缩采样

中图法分类号 TP393

Data Abnormality Processing in Wireless Sensor Networks Based on Distributed Compressed Sensing

HOU Ming-xing¹, QI Hui¹ and HUANG Bin-ke²

1 Department of Computer Science and Technology, Taiyuan Normal University, Jinzhong, Shanxi 030619, China

2 School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China

Abstract In wireless sensor networks, massive data acquisition, transmission and processing not only pose severe challenges to the processing ability and power consumption of sensors, but also suffer data anomalies frequently due to sensor failures or sudden changes of environmental factors, which cannot be effectively dealt with by traditional data processing methods. Regarding the problems above, this paper proposed two kinds of data abnormality models and corresponding processing method based on distributed compressed sensing (DCS) for wireless sensor networks. When the data collected by multiple sensors contains abnormal components, the DCS reconstructs the same normal component of data only once and the different abnormal components individually, which avoids the repeated processing of the same normal component and improves the processing efficiency of the data containing abnormal components. In addition, DCS makes full use of the correlation of data, which can effectively reduce the amount of data acquisition and enhance the robustness against data anomalies. Numerical simulation results of two kinds of data abnormality models show that compared with the traditional compressed sensing based on single set of measurement, the data processing method based on DCS improves the accuracy of abnormal data reconstruction and reduces the amount of data by about 33%, which proves the effectiveness of the proposed method.

Keywords Distributed compressed sensing, Wireless sensor networks, Data abnormality, Joint sparsity, Compressed sampling

1 引言

物联网技术的快速发展,使得无线传感器网络的应用场景和部署规模不断扩大。无线传感器网络使用众多小型化、

低成本的传感器装置进行各类监测数据的采集和无线收发,随着网络规模的扩大,采集和传输的数据量呈指数级增加,这使得传感器的数据采集、存储、传输、功耗等方面均受到了严峻挑战^[1]。另外,传感器装置通常部署在无人值守的环境中,

到稿日期:2018-09-06 返修日期:2019-01-02 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:山西省教育厅项目(J2018159);山西省重点研发计划项目(201803D31055);山西省重点研发计划项目(201803D121088)

This work was supported by the Project of Educational Committee of Shanxi Province (J2018159), Key Research and Development Program of Shanxi Province (201803D31055), Key Research and Development Program of Shanxi Province (201803D121088).

通信作者:亓慧(qihui@tynu.edu.cn)

传感器故障或者环境因素(如温度、湿度等)的突变经常会产生异常数据,导致信息的不可逆损失。因此,对于目前的大规模无线传感器网络,亟需一种高效且稳定的数据处理方法,一方面减小传感器采集、存储和传输的数据量,降低功耗水平,另一方面,能有效对抗数据中存在的异常成分,保证整个传感器网络信息监测的鲁棒性。

近年来,为降低传感器节点的功耗和内存资源,提出了多种数据有损压缩方法,其通常基于域变换思想,将以奈奎斯特速率采样的传感器信号变换到某种特定的稀疏域,如频域或小波域。在稀疏域中,原信号能量主要集中在有限个较大的非零值中,因此只保留这些少量的较大非零值即可实现数据的压缩,同时存储和传输这些压缩后的数据可有效降低了传感器的通信功耗和存储资源。但是,这类数据压缩技术将采样和压缩分步执行,即先采样后压缩,在采样过程中需要至少以奈奎斯特速率获得原始数据的全部采样值并进行存储,随后执行数据压缩算法使用全部采样数据来计算稀疏域中的系数值,不仅对传感器节点的数据采样能力和计算资源是极大负担,而且压缩过程会丢弃大部分小值数据,造成采样数据的大量浪费。

压缩感知(CS)理论^[2]自2006年被正式提出以来,在图像处理^[3]、医学信号检测^[4]、通信^[5]等众多领域掀起了持续的研究热潮。基于信号的稀疏特性,CS可以通过一个压缩测量矩阵将原始的高维信号映射到低维空间,以远低于奈奎斯特的采样率同步实现信号的压缩和测量,当测量矩阵满足RIP条件时,可保证压缩变换几乎不损失原始信息,而后基于少量的压缩测量值,通过一定的优化算法精确恢复出原始信号。之后,Baron等于2009年提出了分布式压缩感知^[6](DCS),相比于传统的CS通过单组测量值恢复原始高维信号,DCS使用多组测量值进行联合稀疏恢复,通过利用多组测量值的共同稀疏性,能够以更少的测量值个数和更高的鲁棒性精确恢复原始高维信号。

目前,许多学者已经就DCS技术在无线传感器网络领域的应用展开了大量研究,并且取得了一定成果。Cardozo等^[7]设计了一种基于规则事件的物联网DCS方法,该方法以分布式的方式对传感器的数据收集和处理过程进行管理。Li等^[8]提出了一种改进的DCS方法来处理无线传感器网络中的光滑信号,该方法不仅可以使使用更少的测量数据来恢复原始信号,而且信号的恢复效果优于传统的DCS方法。Masoum等^[9]提出了一种基于时空相关性的DCS方法,该方法利用传感器节点间的空间相关性将传感器节点组成集群,然后在每个传感器集群内部使用基于时空相关性的DCS方法管理传感器节点,并对其采集的数据进行编码,在数据精度和能量效率方面具有明显优势。Azarnia等^[10]提出了一种基于分布式协作的稀疏重构算法,该算法通过每个传感器与其相邻传感器的协作来共同重构稀疏信号,并且在恢复质量和收敛速度方面优于同类算法。Wimalajeewa等^[11]提出了一种基于DCS的无线传感器网络随机事件探测方法,该方法利用DCS技术减少传感器采集和传输的数据量,然后在数据处理中心重构原始信号并构建协方差矩阵,最后利用协方差矩阵

的信息进行随机事件的统计决策。程银波等^[12]提出了一种面向分簇无线传感器网络的层次化DCS方法,该方法利用分簇无线传感器网络所采集信号的结构化稀疏特性,建立块稀疏簇内联合稀疏模型与块稀疏簇间联合稀疏模型,在保证重建信号质量的同时,能够有效减轻簇头的通信负担,并显著缩短Sink上的信号重构时间。

虽然DCS技术在无线传感器网络中的应用研究已经取得了显著成果,但是已有研究都没有涉及一种常见的情形,即现实环境中的无线传感器网络由于传感器故障或环境因素(温度、湿度等)突变导致的数据异常现象^[13-14],在这种情况下,传感器采集的数据同时包含正常数据分量和异常数据分量。

针对上述情况,本文建立了两类无线传感器网络的异常数据模型,并提出了一种基于DCS技术的无线传感器网络异常数据处理方法。第一类异常数据模型为多个传感器记录的数据包含完全相同正常数据分量和不同的异常数据分量两部分,而第二类异常数据模型中,正常数据分量又包含相同成分和相异成分,因此构成更为复杂。针对上述两类异常数据模型,DCS将采样和压缩两个步骤合并进行,在采样的同时完成数据压缩,同时利用多个传感器数据间的相关性和联合稀疏特性,传感器节点只需向数据中心传送极少量的压缩数据,而数据中心依托高性能计算和存储资源,可基于少量的压缩采样数据精确重构出原始的传感器数据,并且在重构过程中,对于多个传感器数据中的相同成分只进行一次统一重构,仅需对相异成分进行分别处理。该方法相比于传统的基于单个传感器节点数据的CS方法,不仅在采样数据量上有所减少,而且所需的数据重构次数也有明显降低。因此,本文提出的异常数据模型DCS处理方法能够在有效减少每个传感器节点采集和传输的数据量同时,增强算法对抗异常数据的鲁棒性。

2 理论模型

通常,无线传感器网络通过部署的大量传感器感知自然信号(如压力、温度、湿度等),传统的CS技术基于单组测量值重构稀疏信号,而DCS利用多组测量值进行联合稀疏重构,在保证信号重构质量的同时,可以进一步减少稀疏重构所需的数据量,进而简化了传感器硬件结构,降低了传感器工作功耗,延长了传感器生命周期。

接下来将分别对无线传感器网络的两类异常数据模型及相应的DCS异常数据处理技术进行介绍。

2.1 两类异常数据模型

正常情况下,无线传感器网络利用多个空间分布的传感器测量信号,得到的信号内部具有时间相关性,因此在频域上是稀疏的。然而,当传感器发生故障或环境因素(温度、湿度等)突变时,传感器记录的数据会发生异常,此时,记录的数据中不仅包含频域稀疏的正常数据分量,还包含时域稀疏的异常数据分量。

第一类异常数据模型:多个传感器记录的数据包含正常数据分量和异常数据分量,其中,正常数据分量相同,异常数

据分量各异。第 i 个传感器记录的数据可写为如下形式:

$$\mathbf{x}_i = \mathbf{x}_i^N + \mathbf{x}_i^{AN} \quad (1)$$

其中, \mathbf{x}_i 是长度为 N 的数据, \mathbf{x}_i^N 为正常数据分量, \mathbf{x}_i^{AN} 为异常数据分量, $i=1, 2, \dots, J$, J 为所用传感器的个数。

进一步, 将正常数据分量 \mathbf{x}_i^N 和异常数据分量 \mathbf{x}_i^{AN} 在相应的稀疏域进行稀疏表示:

$$\begin{aligned} \mathbf{x}_i^N &= \Psi \mathbf{z}_i^N \\ \mathbf{x}_i^{AN} &= \mathbf{I} \mathbf{z}_i^{AN} \end{aligned} \quad (2)$$

其中, Ψ 为 $N \times N$ 维正交变换矩阵(此处为傅里叶变换矩阵); \mathbf{I} 为 $N \times N$ 维的单位矩阵; \mathbf{z}_i^N 为正常数据分量的频域稀疏表示, 稀疏度为 K^N ; \mathbf{z}_i^{AN} 为异常数据分量的时域稀疏表示, 稀疏度为 K_i^{AN} 。因此, \mathbf{x}_i 可以表示为:

$$\mathbf{x}_i = [\Psi \ \mathbf{I}] \begin{bmatrix} \mathbf{z}_i^N \\ \mathbf{z}_i^{AN} \end{bmatrix} = \bar{\Psi} \mathbf{z}_i \quad (3)$$

其中, $\bar{\Psi}$ 为 $N \times 2N$ 维的超完备稀疏字典矩阵。

第二类异常数据模型: 多个传感器记录的数据包含正常数据分量和异常数据分量, 其中, 正常数据分量又分为相同部分和不同部分, 异常数据分量各异。第 i 个传感器记录的数据可写为如下形式:

$$\mathbf{x}_i = \mathbf{x}_i^N + \mathbf{x}_i^N + \mathbf{x}_i^{AN} \quad (4)$$

其中, \mathbf{x}_i 是长度为 N 的数据, \mathbf{x}_i^N 为正常数据分量的相同部分, \mathbf{x}_i^N 为正常数据分量的不同部分, \mathbf{x}_i^{AN} 为异常数据分量, $i=1, 2, \dots, J$, J 为所用传感器的个数。

同理, 将正常数据分量 \mathbf{x}_i^N , \mathbf{x}_i^N 和异常数据分量 \mathbf{x}_i^{AN} 在相应的稀疏域进行稀疏表示:

$$\mathbf{x}_i = [\Psi \ \Psi \ \mathbf{I}] \begin{bmatrix} \mathbf{z}_i^N \\ \mathbf{z}_i^N \\ \mathbf{z}_i^{AN} \end{bmatrix} = \bar{\Psi} \mathbf{z}_i \quad (5)$$

其中, Ψ 为 $N \times N$ 维正交变换矩阵(此处为傅里叶变换矩阵); \mathbf{I} 为 $N \times N$ 维的单位矩阵; \mathbf{z}_i^N 为正常数据分量相同部分的频域稀疏表示, 稀疏度为 K_i^N ; \mathbf{z}_i^N 为正常数据分量不同部分的频域稀疏表示, 稀疏度为 K_i^N ; \mathbf{z}_i^{AN} 为异常数据分量的时域稀疏表示, 稀疏度为 K_i^{AN} ; $\bar{\Psi}$ 为 $N \times 3N$ 维的超完备稀疏字典矩阵。

2.2 基于分布式压缩感知的异常数据处理

DCS 技术进一步利用了多个传感器节点采集的数据间的空间相关性, 通过多组测量值的联合稀疏重构, 可在保证重构性能的前提下进一步减少数据准确重构所需的数据量。下面介绍基于 DCS 的无线传感器网络异常数据处理方法。

对于第一类异常数据模型, 信号包含相同的正常数据分量和各异的异常数据分量, 共 J 个传感器记录的原始数据 \mathbf{x} 可写为:

$$\mathbf{x} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_J]^T \quad (6)$$

由于各传感器记录的数据中正常数据分量完全相同, 即 $\mathbf{x}_1^N = \mathbf{x}_2^N = \dots = \mathbf{x}_J^N = \mathbf{x}^N$, 因此, 对 \mathbf{x} 的稀疏表示可写为:

$$\mathbf{x} = \tilde{\Psi} \mathbf{z}' \quad (7)$$

$$\text{其中, } \mathbf{z}' = [\mathbf{z}^N \ \mathbf{z}_1^{AN} \ \dots \ \mathbf{z}_J^{AN}]^T, \tilde{\Psi} = \begin{bmatrix} \mathbf{F} & \mathbf{I} & 0 & \dots & 0 \\ \mathbf{F} & 0 & \mathbf{I} & \dots & 0 \\ \vdots & \vdots & & & \vdots \\ \mathbf{F} & 0 & \dots & \mathbf{I} & 0 \\ \mathbf{F} & 0 & \dots & 0 & \mathbf{I} \end{bmatrix}, \mathbf{F}$$

为 $N \times N$ 维傅里叶变换矩阵, \mathbf{I} 为 $N \times N$ 维单位矩阵, \mathbf{z}^N 为正常数据分量的频域稀疏表示, \mathbf{z}_i^{AN} 为第 i 个传感器记录的异常数据分量的时域稀疏表示。

使用高斯随机测量矩阵对多个传感器记录的原始高维数据进行压缩测量, 获得多组压缩测量值。该过程可表示为:

$$\mathbf{y} = \tilde{\Phi} \mathbf{x} = \tilde{\Phi} \tilde{\Psi} \mathbf{z}' \quad (8)$$

$$\text{其中, } \tilde{\Phi} = \begin{bmatrix} \Phi & 0 & \dots & 0 \\ 0 & \Phi & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & \dots & 0 & \Phi \end{bmatrix}, \Phi \text{ 为 } M \times N (M \ll N) \text{ 维的高斯}$$

随机测量矩阵, $\mathbf{y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_{i-1} \ \mathbf{y}_i \ \mathbf{y}_{i+1} \ \dots \ \mathbf{y}_J]^T$, \mathbf{y}_i 为第 i 个传感器的压缩测量值。

式(8)即为第一类异常数据模型的 DCS 处理方法。

对于第二类异常数据模型, 信号包含正常数据分量和各异的异常数据分量, 其中, 正常数据分量又分为相同部分和不同部分, 其表达式如式(4)所示。同样, 对原始数据 \mathbf{x} 进行稀疏表示:

$$\mathbf{x} = \tilde{\Psi} \mathbf{z}'' \quad (9)$$

$$\text{其中, } \mathbf{z}'' = [\mathbf{z}_C^N \ \mathbf{z}_1^N \ \dots \ \mathbf{z}_J^N \ \mathbf{z}_1^{AN} \ \dots \ \mathbf{z}_J^{AN}]^T, \tilde{\Psi} = \begin{bmatrix} \mathbf{F} & \mathbf{F} & 0 & \dots & 0 & \mathbf{I} & 0 & \dots & 0 \\ \mathbf{F} & 0 & \mathbf{F} & 0 & \dots & 0 & \mathbf{I} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & & \vdots & & & \vdots \\ \mathbf{F} & 0 & \dots & 0 & \mathbf{F} & 0 & \dots & 0 & \mathbf{I} \end{bmatrix}, \mathbf{F}$$

为 $N \times N$ 维傅里叶变换矩阵, \mathbf{I} 为 $N \times N$ 维单位矩阵, \mathbf{z}_C^N 为正常数据分量中相同部分的频域稀疏表示, \mathbf{z}_i^N 为第 i 个传感器记录的正常数据分量中不同部分的频域稀疏表示, \mathbf{z}_i^{AN} 为第 i 个传感器记录的异常数据分量的时域稀疏表示。

同理, 使用高斯随机测量矩阵对多个传感器记录的原始高维数据进行压缩测量, 获得多组压缩测量值, 该过程可表示为:

$$\mathbf{y} = \tilde{\Phi} \mathbf{x} = \tilde{\Phi} \tilde{\Psi} \mathbf{z}'' \quad (10)$$

式(10)即为第二类异常数据模型的 DCS 处理方法。

对于式(8)和式(10)表示的两种基于 DCS 技术的异常数据处理模型, 已知测量值 \mathbf{y} 和感知矩阵 $\mathbf{A} = \tilde{\Phi} \tilde{\Psi}$, 通过一定的优化算法可精确重构出高维稀疏数据 \mathbf{z}' 或 \mathbf{z}'' , 之后通过稀疏反变换获得原始数据 \mathbf{x} 。

常用的优化算法有基于 l_1 范数最小化的凸优化算法, 如基追踪算法^[15]、基于重加权 l_1 范数最小化算法^[16]等, 以及基于迭代思想的贪婪优化算法, 如正交匹配追踪^[17]、子空间追踪^[18]等。本文使用基追踪(BP)算法进行基于多测量值的 DCS 联合稀疏恢复。

3 模型仿真

本节通过数值仿真, 对两类基于 DCS 技术的无线传感器

网络异常数据模型进行数值仿真,并通过与传统的基于单组测量值的CS方法进行对比,以证明本文方法的优越性。为方便比较算法的性能,定义数据重构的均方误差(MSE)为:

$$MSE = \frac{\|\hat{\mathbf{S}}_{x_i} - \mathbf{S}_{x_i}\|_2}{\|\mathbf{S}_{x_i}\|_2} \quad (11)$$

其中, \mathbf{S}_{x_i} 和 $\hat{\mathbf{S}}_{x_i}$ 分别为传感器记录的原始数据和经CS或DCS技术重构的数据。

对于第一类异常数据模型,每个传感器记录的数据包含相同的正常数据分量和相异的异常数据分量,其中正常数据分量是稀疏度为5的频域稀疏信号,异常数据分量是稀疏度为3的时域稀疏信号,整个数据长度为100,测量值个数为20~80,传感器个数 J 分别取1,5,20,其中, $J=1$ 表示只有一个传感器,对应传统的基于单组测量值的CS处理方法; $J=5$ 和 $J=20$ 表示存在多个传感器进行信号测量,对应基于多组测量值联合稀疏重构的DCS处理方法。对式(8)所示的第一类异常数据模型使用BP算法进行数据重构,每组参数组合采用蒙特卡洛法运行200次,计算相应数据重构的MSE,结果如图1所示。




图1 第一类异常数据模型数据重构的MSE

Fig. 1 MSE of data reconstruction for the first data abnormality model

由图1可以明显看出,当传感器数量一定时,随着传感器测量值个数的增加,基于CS方法和DCS方法的数据重构的MSE均逐步降低,即要提高数据重构精度,需要相应地增加传感器采集的数据量,使其符合CS理论中关于测量值个数和重构精度的关系。另外,当只有一个传感器,即只有一组测量值可用时,采用基于单组测量值的CS方法几乎需要60个测量值才能准确恢复原始数据,但是当协同处理的传感器个数增加至20时,采用DCS方法,每个传感器只需40个测量值即可准确恢复原始数据,相比CS处理方法所需的数据量减少了约33%。因此,当可用传感器的数量增加时,相比基于单组测量值的CS方法,DCS方法通过对多个传感器的测量数据进行协同处理和联合重构,能够以更少的测量值个数实现同样的数据重构精度,即无线传感器网络中每个传感器测量和传输的数据量均减小。

对于第二类异常数据模型,每个传感器记录的数据包含正常数据分量和异常数据分量。其中,正常数据分量是稀疏度为5的频域稀疏信号,包括相同部分和不同部分;异常数据分量各异,是稀疏度为3的时域稀疏信号。整个数据长度同样为100,其余仿真参数的选取与第一类异常数据模型相同,同样 $J=1$ 对应于传统的CS处理方法, $J=5$ 和 $J=20$ 对应于DCS处理方法。对式(10)所示的第二类异常数据模型,使用

BP算法进行数据重构,对每组参数组合采用蒙特卡洛法运行200次,计算相应数据重构的MSE,结果如图2所示。




图2 第二类异常数据模型数据重构的MSE

Fig. 2 MSE of data reconstruction for the second data abnormality model

由图2可以看出,在传感器数量一定的条件下,无论是基于单组测量值的CS处理方法还是基于多组测量值的DCS方法,数据重构的MSE均随着传感器测量值个数的增加而逐步降低,与图1所示趋势相同。另外,可以注意到,当可用传感器数量为20时,每个传感器约需要60个测量值即可实现原始数据的准确重构,但是当只存在一个可用传感器时,即使传感器测量值个数达到80,使用基于单组测量值的CS处理方法依旧存在较大的重构误差,重构性能明显差于基于多组测量联合处理的DCS方法。

接下来对上述两类异常数据模型的仿真结果进行分析。对于传统的CS方法,其利用单组测量值进行数据重构,每个传感器节点独立进行数据采集和压缩,并将各自的压缩测量值传送至数据处理中心,各自分别进行原数据重构。而DCS方法在处理包含异常数据的模型时,对多个传感器的测量数据进行协同处理,利用多组测量数据间的空间相关性进行联合稀疏重构,一方面,通过充分利用多组数据内部蕴含的结构信息,减少了数据准确重构所需的数据量;另一方面,DCS方法在处理时对多个传感器数据中相同的分量只进行一次统一的重构,只对不同分量进行相应的重构,这同样减少了数据重构所需的数据量。因此,DCS方法的数据压缩和重构性能明显优于依靠单组测量值的CS方法。所提方法不仅有效减少了每个传感器采集和传输的数据量,降低了传感器的硬件成本和功耗,而且在数据重构时所需数据量的减少进一步增强了算法对抗传感器网络异常数据的鲁棒性。

结束语 无线传感器网络通常需要采集和传输大量数据,并且经常会遭遇传感器故障或环境因素突变,造成数据异常。针对此问题,本文提出了两类无线传感器网络的异常数据模型,以及相应的基于分布式压缩感知的异常数据处理方法。本文借助于传感器网络本身具有的多个空间分布的传感器,综合使用多个传感器的测量数据进行联合稀疏重构,不仅进一步减少了传感器网络采集和传输的数据量,而且有效增强了整个网络对抗异常数据的鲁棒性。

本文所提出的数据模型还未考虑实际环境中各类干扰和测量噪声等非理想因素的影响,属于理想模型;下一步工作将完善无线传感器网络的数据模型,引入影响较大的非理想因素,使理论结果更加符合工程实际,以加强算法和模型的工程实用性。另外,我们已经着手搭建64节点的无线传感器物理

测试系统,通过人为引入异常数据,测试本文算法的处理能力,相关结果将在后续工作中进行呈现。

参 考 文 献

- [1] KIMURA N, LATIFI S. A Survey on Data Compression in Wireless Sensor Networks[C]// International Conference on Information Technology Coding and Computing. Las Vegas: IEEE, 2005: 8-13.
- [2] CANDÉS E J. Compressive Sampling[C]// Proceedings of the International Congress of Mathematicians. Madrid, Spain, 2006: 1433-1452.
- [3] CHAN W L, MORAVEC M L, BARANIUK R G, et al. Terahertz Imaging with Compressed Sensing and Phase Retrieval[J]. Optics letters, 2008, 33(9): 974-976.
- [4] LUSTIG M, DONOHO D L, SANTOS J M, et al. Compressed Sensing MRI [J]. IEEE Signal Processing Magazine, 2008, 25(2): 72-82.
- [5] BERGER C R, WANG Z, HUANG J, et al. Application of Compressive Sensing to Sparse Channel Estimation[J]. IEEE Communications Magazine, 2010, 48(11): 164-174.
- [6] BARON D, DUARTE M F, WAKIN M B, et al. Distributed Compressive Sensing[J]. arXiv:0901.3403.
- [7] CARDOZO A, YAMIN A, XAVIER L, et al. An Architecture Proposal to Distributed Sensing in Internet of Things [C]// Instrumentation Systems, Circuits and Transducers (INSCIT). Belo Horizonte: IEEE, 2016: 67-72.
- [8] LI B, GAO F, LIU X, et al. Improved Distributed Compressed Sensing for Smooth Signals in Wireless Sensor Networks[C]// 2016 International Conference on Computer, Information and Telecommunication Systems (CITS). Kunming, China: IEEE, 2016: 1-5.
- [9] MASOUM A, MERATNIA N, HAVINGA P J, et al. Compressive Sensing Based Data Collection in Wireless Sensor Networks [C]// 2017 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI). Daegu, South Korea: IEEE, 2017: 442-447.
- [10] AZARNIA G, TINATI M A, REZAI T Y, et al. Cooperative and Distributed Algorithm for Compressed Sensing Recovery in WSNs[J]. IET Signal Processing, 2017, 12(3): 346-357.
- [11] WIMALAJEewa T, VARSHNEY P K. Robust Detection of Random Events with Spatially Correlated Data in Wireless Sensor Networks via Distributed Compressive Sensing[C]// 2017 IEEE 7th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP). Curacao, Netherlands Antilles: IEEE, 2017: 1-5.
- [12] CHENG Y B, SI J J, HOU X L. Hierarchical Distributed Compressed Sensing for Wireless Sensor Network[J]. Journal of Electronics & Information Technology, 2017, 39(3): 539-545.
- [13] LUO C, WU F, SUN J, et al. Efficient Measurement Generation and Pervasive Sparsity for Compressive Data[J]. IEEE Transactions on Wireless Communications, 2010, 9(12): 3728-3738.
- [14] WANG J, TANG S, YIN B, et al. Data Gathering in Wireless Sensor Networks through Intelligent Compressive Sensing [C]// Proceedings of the IEEE International Conference on Compute Communications (INFOCOM). Orlando, 2012: 603-611.
- [15] CHEN S S, DONOHO D L, SAUNDERS M A, et al. Atomic Decomposition by Basis Pursuit[J]. SIAM Review, 2001, 43(1): 129-159.
- [16] CANDES E J, WAKIN M B, BOYD S P, et al. Enhancing Sparsity by Reweighted ℓ_1 Minimization[J]. Journal of Fourier Analysis and Applications, 2008, 14(5/6): 877-905.
- [17] TROPP J A, GIBERT A C. Signal Recovery from Random Measurements via Orthogonal Matching Pursuit [J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
- [18] DAI W, MILENKOVIC O. Subspace Pursuit for Compressive Sensing Signal Reconstruction[J]. IEEE Transactions on Information Theory, 2009, 55(5): 2230-2249.



HOU Ming-xing, born in 1990, postgraduate, is member of China Computer Federation (CCF). Her main research interests include compressed sensing, wireless sensor network and machine learning.



QI Hui, born in 1981, postgraduate, associate professor, postgraduate supervisor, is member of China Computer Federation (CCF). Her main research interests include machine learning and cloud computing.