

基于 Jacobi ADMM 的传感网分布式压缩感知数据重构算法

李国瑞¹ 孟 婕¹ 彭三城² 王 聪¹

¹(东北大学计算机科学与工程学院 沈阳 110819)
²(广东外语外贸大学语言工程与计算实验室 广州 510006)
(lgr@neuq.edu.cn)

A Distributed Data Reconstruction Algorithm Based on Jacobi ADMM for Compressed Sensing in Sensor Networks

Li Guorui¹, Meng Jie¹, Peng Sancheng², and Wang Cong¹

¹(School of Computer Science and Engineering, Northeastern University, Shenyang 110819)
²(Laboratory of Language Engineering and Computing, Guangdong University of Foreign Studies, Guangzhou 510006)

Abstract Considering the application scenario of decentralized data collection in wireless sensor networks (WSNs), a distributed data reconstruction algorithm based on Jacobi ADMM (alternating direction method of multipliers) for compressed sensing is proposed by adopting the JSM-1 (joint sparse model-1) model in the distributed compressed sensing (DCS) theory. Through exchanging the common information among cluster heads to determine the common components in the correlated sensed data and update the innovation components in each cluster head, the compressed sensed data in WSNs are reconstructed in a distributed way. The data collection operation in wireless sensor networks is firstly abstracted as a distributed optimization problem. In order to avoid non-convergence in the distributed data reconstruction process, a proximal component is then introduced into the aforementioned optimization problem with the goal of converting the sub-problem of the optimization objective function into its strictly convex form. After that, the ADMM method is utilized to solve the data reconstruction problem. Both the synthetic dataset and the real world datasets are used in the experiments to verify the performance of the proposed algorithm. Experimental results show that the proposed data reconstruction algorithm can provide higher data reconstruction accuracy than the state of the art data reconstruction algorithms.

Key words wireless sensor networks (WSNs); distributed algorithm; compressed sensing; data reconstruction; optimization

摘 要 针对无线传感网中分布式数据收集及应用,采用分布式压缩感知理论中的 JSM-1 (joint sparse model-1)模型,提出了一种基于 Jacobi ADMM (alternating direction method of multipliers)的分布式压缩感知数据重构算法.该算法通过在簇头节点间交换公共信息以挖掘关联数据集的公共部分,并在各个

收稿日期:2019-08-23;修回日期:2019-11-25
基金项目:国家自然科学基金项目(61876205);中央高校基本科研业务费专项资金(N172304022);广州市科技计划项目(201804010433);语言工程与计算实验室招标课题(LEC2017ZBKT001)
This work was supported by the National Natural Science Foundation of China (61876205), the Fundamental Research Funds for the Central Universities (N172304022), the Science and Technology Plan Project of Guangzhou (201804010433), and the Bidding Project of Laboratory of Language Engineering and Computing (LEC2017ZBKT001).
通信作者:彭三城(psc346@aliyun.com)

簇头节点内部更新各自的独立部分,从而实现无线传感网中相关感知数据的分布式压缩重构.首先,将无线传感网中的数据收集问题抽象为一个分布式优化问题.然后,为了能够有效地解决分布式计算过程中产生的不收敛问题,在优化目标函数中引入了近似项,从而使得子优化问题具有严格凸性,并利用交替方向乘子法求解压缩感知数据的重构问题.最后,分别利用合成数据集和真实数据集进行验证.实验结果表明:与现有其他数据重构算法相比,基于 Jacobi ADMM 的分布式压缩感知数据重构算法具有更高的数据重构精度.

关键词 无线传感器网络;分布式算法;压缩感知;数据重构;优化

中图法分类号 TP393

无线传感器网络通常由部署在监测区域的若干无线传感器节点构成,每个传感器节点通过感知环境信息,并将其处理后以无线多跳的方式传输至 Sink 节点^[1].无线传感器节点通常部署在无人值守的野外区域或复杂的工业控制现场,更换电池极为不便.同时,无线传感器节点的计算、存储和能量等各项资源极为有限,因此,将传感器节点采集到的监测数据压缩后再进行传输可有效地延长无线传感器网络的存活周期.目前,无线传感器网络中的数据压缩与重构技术已成为该领域研究中的核心问题之一^[2-3].

时空关联分析预测^[4]与分布式压缩编码^[5]是传统无线传感器网络中采用的 2 类数据压缩技术,但两者均需在节点中执行复杂的运算,同时还需在网络中传输大量的同步参数.因此,存在明显的弊端^[6].近年来,压缩感知(compressed sensing, CS)理论作为信号处理领域中一个备受关注的研究热点,以远低于 Nyquist 采样定理规定的方式压缩数据,并通过求解优化问题实现稀疏或可压缩数据的精确重构,从而为传感网中的数据压缩与重构研究提供了一个新的方向^[7].

经典的压缩感知理论仅支持单个信号的压缩与重构,然而在大规模监测网络中同一个区域内的多个信号之间存在一定的相关性^[8].因此,Baron 等人^[9]在压缩感知理论的基础上进行了扩充,把对单个信号的压缩采样扩展到了对信号群的压缩采样,提出了分布式压缩感知(distributed compressed sensing, DCS)理论.该理论包含 3 种典型的联合稀疏模型(joint sparse model, JSM),与经典的压缩感知理论相比,由于其充分发掘了信号的内相关性和互相关性,可以有效地节约信号观察数量,并提高信号的重构精度.

目前,分布式压缩感知重构算法主要包括集中式重构和分布式重构 2 类算法.其中,集中式重构算

法的研究较为成熟,典型的算法包括同步正交匹配追踪(simultaneous orthogonal matching pursuit, SOMP)算法^[10]、同步子空间追踪(simultaneous subspace pursuit, SSP)算法^[11]和同步压缩采样匹配追踪(simultaneous compressive sampling matching pursuit, SCoSaMP)算法^[12]等.然而,由于集中式重构算法需要将各个监测节点的感知数据传输至统一的数据中心进行集中式重构,不但对网络的带宽、延时和节点的能耗要求较高,而且各级监测/控制节点不能直接获取重构结果.因此,无法满足无线传感器网络的实际应用需求.

分布式重构算法采用分布式计算模式避免了上述问题,通过在部分簇头节点之间交换公共信息,并以迭代的方式更新个体信息,从而实现信号群的高精度压缩数据重构.Li 等人^[13]通过改进集中式的压缩采样匹配追踪算法和子空间追踪算法,提出了分布式协同子空间追踪(decentralized and collaborative subspace pursuit, DCSP)算法,并进行了详细的理论分析和验证.Xu 等人^[14]基于交替方向乘子法迭代求解信号群中的公共部分和个体部分,从而实现了分布式的压缩数据重构.然而,该方案在簇头节点数量大于等于 3 时无法确保迭代重构的收敛性,还具有一定的局限性.

本文针对无线传感器网络的分布式数据收集应用场景,采用分布式压缩感知理论中的 JSM-1 模型,通过在优化问题的目标函数中增加近似项以确保分布式压缩数据重构的收敛性,从而设计了一种基于 Jacobi ADMM 的分布式压缩数据重构算法.该算法通过在簇头节点间迭代交换公共信息以提取相关感知数据的公共部分,并在各个簇头节点内部更新各自的独立部分,从而实现无线传感网中相关感知数据的分布式压缩重构.实验结果表明,与现有其他重构算法相比,本文所提出的算法具有更高的数据重构精度.

1 研究背景

1.1 分布式压缩感知理论

在利用经典的压缩感知理论对原始信号 $f \in \mathbb{R}^n$ 进行压缩时,整个投影压缩过程可以抽象为

$$\mathbf{y} = \Phi \mathbf{f} + \mathbf{e}, \tag{1}$$

其中, $\mathbf{y} \in \mathbb{R}^m$ 为测量信号, $\Phi \in \mathbb{R}^{m \times n}$ 为观测矩阵, $\mathbf{e} \in \mathbb{R}^m$ 为测量过程中的噪声.由于原始信号一般具有稀疏性,可利用特定的变化基 $\Psi \in \mathbb{R}^{n \times n}$ 稀疏化^[15],因此,式(1)可以转换为

$$\mathbf{y} = \mathbf{A} \mathbf{x} + \mathbf{e}, \tag{2}$$

其中, $\mathbf{A} = \Phi \Psi \in \mathbb{R}^{m \times n}$ 为感知矩阵, $\mathbf{x} \in \mathbb{R}^n$ 为稀疏向量.由于 $m \ll n$,利用简单的投影运算即可实现数据压缩,非常适用于资源受限的传感器节点.由测量信号 $\mathbf{y}$ 重构原始信号 $\mathbf{f}$ 可通过求解 l_0 最小化问题:

$$\begin{aligned} \min_x & \|\mathbf{x}\|_0 \\ \text{s.t. } & \|\mathbf{A} \mathbf{x} - \mathbf{y}\|_2 \leq \epsilon, \end{aligned} \tag{3}$$

随后再利用变化基 Ψ 将 $\mathbf{x}$ 还原至原始空间得到,其中 $\epsilon > 0$ 为重构误差.由于式(3)为 NP 难问题^[16],通常将其松弛为 l_1 最小化问题进行求解:

$$\begin{aligned} \min_x & \|\mathbf{x}\|_1 \\ \text{s.t. } & \|\mathbf{A} \mathbf{x} - \mathbf{y}\|_2 \leq \epsilon. \end{aligned} \tag{4}$$

分布式压缩感知理论针对经典的压缩感知理论进行了扩展,把对单个信号的压缩采样扩展到了对信号群的压缩采样,通过利用信号之间的互相关性和内相关性来实现对多个压缩信号的联合稀疏重构.无线传感网采集的监测数据符合分布式压缩感知理论中的 JSM-1 模型^[14].因此,可将第 i 个节点对应的稀疏信号 $\mathbf{x}_i \in \mathbb{R}^n$ 分解为公共部分 $\mathbf{z}_{c,i} \in \mathbb{R}^n$ 和个体部分 $\mathbf{z}_i \in \mathbb{R}^n$:

$$\mathbf{x}_i = \mathbf{z}_{c,i} + \mathbf{z}_i. \tag{5}$$

由于公共部分为所有节点所共有,即 $\mathbf{z}_{c,1} = \mathbf{z}_{c,2} = \dots = \mathbf{z}_{c,n}$,因此可将该式表示为

$$(\mathbf{z}_{c,1}, \mathbf{z}_{c,2}, \dots, \mathbf{z}_{c,n}) \begin{pmatrix} -1 & 1 & & & \\ & -1 & \ddots & & \\ & & \ddots & \ddots & \\ 1 & & & & 1 \\ & & & & -1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ \ddots \\ 0 \end{pmatrix}. \tag{6}$$

$$\mathbf{B} = \begin{pmatrix} -1 & 1 & & & \\ & -1 & \ddots & & \\ & & \ddots & \ddots & \\ 1 & & & & 1 \\ & & & & -1 \end{pmatrix},$$

则在分布式压缩感知中 l_1 最小化问题(即式(4))可表示成:

$$\begin{aligned} \min_{\mathbf{z}_{c,i}, \mathbf{z}_i} & \sum_{i=1}^n \|\mathbf{z}_{c,i} + \mathbf{z}_i\|_1, \\ \text{s.t. } & \|\mathbf{A}_i(\mathbf{z}_{c,i} + \mathbf{z}_i) - \mathbf{y}_i\|_2 \leq \epsilon_i, \\ & \mathbf{Z}_c \mathbf{B} = \mathbf{0}. \end{aligned} \tag{7}$$

1.2 ADMM 算法

ADMM 算法主要用于求解多变量优化问题,目前已被广泛应用于大规模分布式网络系统的优化计算领域^[17].ADMM 算法解决问题的一般形式为

$$\begin{aligned} \min & f(\mathbf{x}) + g(\mathbf{z}), \\ \text{s.t. } & \mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{z} = \mathbf{d}, \end{aligned} \tag{8}$$

其中, $\mathbf{x} \in \mathbb{R}^n, \mathbf{z} \in \mathbb{R}^m, \mathbf{A} \in \mathbb{R}^{p \times n}, \mathbf{B} \in \mathbb{R}^{p \times m}, \mathbf{d} \in \mathbb{R}^p$.该算法的核心思想就是把优化问题(即式(8))迭代分解为多个子问题,然后对这些子问题进行逐个求解,具体的迭代步骤为

$$\begin{aligned} \mathbf{x}^{(k+1)} &= \arg \min_x f(\mathbf{x}) + \\ & \frac{\rho}{2} \|\mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{z}^{(k)} - \mathbf{d} + \mathbf{u}^{(k)}\|_2^2, \\ \mathbf{z}^{(k+1)} &= \arg \min_z g(\mathbf{z}) + \\ & \frac{\rho}{2} \|\mathbf{A} \mathbf{x}^{(k+1)} + \mathbf{B} \mathbf{z} - \mathbf{d} + \mathbf{u}^{(k)}\|_2^2, \\ \mathbf{u}^{(k+1)} &= \mathbf{u}^{(k)} + (\mathbf{A} \mathbf{x}^{(k+1)} + \mathbf{B} \mathbf{z}^{(k+1)} - \mathbf{d}), \end{aligned} \tag{9}$$

其中, ρ 为惩罚参数, $\mathbf{u}$ 为拉格朗日乘子.

2 系统模型

本文提出的分布式数据重构算法适用于层次结构的无线传感器网络,其系统模型如图 1 所示:




Fig. 1 The network system model
图 1 网络系统模型

令

$$\mathbf{Z}_c = (\mathbf{z}_{c,1}, \mathbf{z}_{c,2}, \dots, \mathbf{z}_{c,n}),$$

整个无线传感器网络由大量簇成员节点和簇头节点构成,簇成员节点在采集到感知数据后利用相应的测量矩阵进行投影压缩,并将压缩后的数据传输至各自的簇头节点^[18].簇头节点汇集本簇内的压缩数据后运行本文所提出的分布式压缩数据重构算法,从而以分布式方式在无线传感器网络内实现压缩数据的重构操作.

3 基于分布式压缩感知的数据重构算法

在无线传感器网络中,为求解分布式压缩数据重构问题(即式(7)),首先构造增广拉格朗日函数:

$$L(\mathbf{z}_{c,i}, \mathbf{z}_i) = \sum_{i=1}^n (\|\mathbf{z}_{c,i}\|_1 + \|\mathbf{z}_i\|_1 + \frac{\mu}{2} \|\mathbf{y}_i - \mathbf{A}_i(\mathbf{z}_{c,i} + \mathbf{z}_i)\|_2^2) + \langle \boldsymbol{\alpha}, \mathbf{Z}_c \mathbf{B} \rangle + \frac{\gamma}{2} \|\mathbf{Z}_c \mathbf{B}\|_F^2, \quad (10)$$

其中, $\boldsymbol{\alpha} \in \mathbb{R}^{n \times n}$ 为拉格朗日乘子, μ 和 γ 为惩罚参数.然而,文献[19]已证明在分布式计算环境中经典的 ADMM 算法当节点个数 $n \geq 3$ 时并不一定收敛.受文献[20]的启发,本文在求解分布式压缩数据重构时引入近似项 $\|\mathbf{z}_{c,i} - \mathbf{z}_{c,i}^{(k)}\|_{\mathbf{P}_i}^2 / 2$, 其中 $\mathbf{P}_i$ 为一个对称半正定矩阵, $\|\mathbf{z}_{c,i}\|_{\mathbf{P}_i}^2 = \mathbf{z}_{c,i}^T \mathbf{P}_i \mathbf{z}_{c,i}$. 当增广拉格朗日函数的子问题不是严格凸时,通过引入该近似项可使得相应的子问题具有严格凸性,不但使得子问题更易于求解,而且严格凸性还可确保子问题具有唯一最优解.在本文算法中,令 $\mathbf{P}_i = -2\gamma \mathbf{I}$. 于是,分布式压缩数据重构问题(即式(7))可根据交替方向乘子法进行求解:

$$\begin{aligned} \mathbf{z}_{c,i}^{(k+1)} &= \arg \min_{\mathbf{z}_{c,i}} \|\mathbf{z}_{c,i}\|_1 + \|\mathbf{z}_i\|_1 + \frac{\mu}{2} \|\mathbf{y}_i - \mathbf{A}_i(\mathbf{z}_{c,i} + \mathbf{z}_i)\|_2^2 + \\ &\quad \frac{\gamma}{2} \left\| \mathbf{Z}_c \mathbf{B} + \frac{\boldsymbol{\alpha}}{\gamma} \right\|_F^2 + \frac{1}{2} \|\mathbf{z}_{c,i} - \mathbf{z}_{c,i}^{(k)}\|_{\mathbf{P}_i}^2 = \\ &\arg \min_{\mathbf{z}_{c,i}} \|\mathbf{z}_{c,i}\|_1 + \frac{\mu}{2} \|\mathbf{y}_i - \mathbf{A}_i(\mathbf{z}_{c,i} + \mathbf{z}_i)\|_2^2 + \\ &\gamma(2\mathbf{z}_{c,i}^{(k)} - \mathbf{z}_{c,i-1}^{(k)} - \mathbf{z}_{c,i+1}^{(k)} + (\boldsymbol{\alpha}_{i+1} - \boldsymbol{\alpha}_i)/\gamma) \mathbf{z}_{c,i}, \quad (11) \\ \mathbf{z}_i^{(k+1)} &= \arg \min_{\mathbf{z}_i} \|\mathbf{z}_i\|_1 + \frac{\mu}{2} \|\mathbf{y}_i - \mathbf{A}_i(\mathbf{z}_{c,i} + \mathbf{z}_i)\|_2^2, \quad (12) \\ \boldsymbol{\alpha}^{(k+1)} &= \boldsymbol{\alpha}^{(k)} + \nu \gamma (\mathbf{Z}_c \mathbf{B}), \quad (13) \end{aligned}$$

其中, ν 为惩罚参数.通过求解子问题(即式(11)和式(12))即可在重构出无线传感器网络中的感知数据.

基于 Jacobi ADMM 的分布式压缩数据重构算法如算法 1 所示,它通过迭代更新数据的公共部分和个体部分进行求解.算法 1 在执行时首先初始化参数,将公共部分 $\mathbf{z}_{c,i}$ 和个体部分 $\mathbf{z}_i$ 初始化为随机稀疏向量.算法主体由内层循环和外层循环 2 部分构成,内层循环在计算得到公共部分 $\mathbf{z}_{c,i}$ 后通过与邻居簇头节点交换信息,从而更加精确地提取信号群的公共部分;外层循环在获得公共部分 $\mathbf{z}_{c,i}$ 的基础上计算个体部分 $\mathbf{z}_i$,进而获得所需重构的感知数据.在求解子问题(即式(11)和式(12))时,可使用定点连续(fixed point continuation, FPC)算法^[21],其适用于求解形如 $\min_{\mathbf{x}} \|\mathbf{x}\|_1 + f(\mathbf{x})$ 的 l_1 最小化问题,其中 $f(\mathbf{x})$ 为可微凸函数.本算法通过设置内层迭代次数阈值 k_{th} 、外层迭代次数阈值 l_{th} 和残差阈值 r 来控制循环的执行.

算法 1. 基于 Jacobi ADMM 的分布式压缩数据重构算法.

输入:感知矩阵 $\mathbf{A}_i$ 、测量信号 $\mathbf{y}_i$;

输出:稀疏信号 $\mathbf{x}_i$.

- ① 初始化拉格朗日乘子 $\boldsymbol{\alpha}$, 惩罚参数 μ, γ, ν , 公共部分 $\mathbf{z}_{c,i}$ 和个体部分 $\mathbf{z}_i$, 内层迭代次数阈值 k_{th} 和外层迭代次数阈值 l_{th} , 残差阈值 r ;
- ② while $l < l_{th}$ or $\|\mathbf{res}_i^{(k+1)} - \mathbf{res}_i^{(k)}\|_2 > r$
- ③ while $k < k_{th}$
- ④ 求解式(11)得到 $\mathbf{z}_{c,i}^{(k+1)}$, 计算支撑集 $\Omega_{c,i}$;
- ⑤ 簇头节点 i 与邻居簇头节点 j 交换公共部分 $\mathbf{z}_{c,i}^{(k+1)}$ 和 $\mathbf{z}_{c,j}^{(k+1)}$, 更新支撑集 $\Omega_{c,i} = \Omega_{c,i} \cap \Omega_{c,j}$;
- ⑥ $\mathbf{z}_{c,i}^{(k+1)}(\bar{\Omega}_{c,i}) = 0$;
- ⑦ 根据式(13)更新 $\boldsymbol{\alpha}$;
- ⑧ $k = k + 1$;
- ⑨ end while
- ⑩ 通过求解子问题式(12)更新独立部分 $\mathbf{z}_i$;
- ⑪ 根据式(5)计算原始信号 $\mathbf{x}_i^{(k+1)}$ 以及迭代误差 $\mathbf{res}_i^{(k+1)} = \|\mathbf{x}_i^{(k+1)} - \mathbf{x}_i^{(k)}\|_2$;
- ⑫ $l = l + 1$;
- ⑬ end while

4 实验结果与分析

为了验证本文所提出的算法在无线传感器网络中的数据重构性能,本节分别利用合成数据集和

真实数据集进行实验验证.其中,合成数据集由 Matlab 软件仿真合成,真实数据集选用了黑河流域中游生态水文数据集^[22]和 City Pulse 空气污染物数据集^[23].在衡量算法性能时,使用相对均方误差 (relative mean square error, RMSE) 进行度量,用 τ 表示,其定义为

$$\tau = \sum_{i=1}^n \|\hat{\mathbf{x}}_i - \mathbf{x}_i\|_2 / \sum_{i=1}^n \|\mathbf{x}_i\|_2, \quad (14)$$

其中, $\mathbf{x}_i$ 和 $\hat{\mathbf{x}}_i$ 分别表示原始信号和重构信号.在实验分析中所对比的数据重构算法包括:

- 1) 分布式重构算法^[14].该算法属于分布式数据重构算法,通过将数据分解成公共部分和个体部分,利用 ADMM 算法进行迭代重构.
- 2) 分布式贝叶斯算法^[24].该算法属于分布式数据重构算法,通过将数据分解成公共部分和个体部分,利用变分贝叶斯推断进行迭代重构.
- 3) SSP 算法^[11].该算法属于集中式数据重构算法,利用相同的稀疏基,通过改进子空间追踪贪婪算法进行迭代重构.
- 4) SCoSaMP 算法^[12].该算法属于集中式数据重构算法,利用相同的稀疏基,通过改进压缩采样匹配追踪贪婪算法进行迭代重构.

4.1 合成数据实验

在生成合成数据集时,首先随机生成 $m \times n$ 的高斯矩阵作为测量矩阵 $\mathbf{A}_i$,然后从中随机挑选 k 个小于 n 的索引并随机生成稀疏信号 $\mathbf{x}_i$,最后利用投影运算 $\mathbf{y}_i = \mathbf{A}_i \mathbf{x}_i + \mathbf{e}_i$ 生成测量信号 $\mathbf{y}_i$,其中 $\mathbf{e}_i$ 为高斯随机噪声.

图 2 展示了在采样率 $m/n = 40\%$ 、稀疏度 $k = 0.05n$ 的条件下,本文算法与其余 4 种算法的数据




Fig. 2 Influence of m on the data reconstruction accuracy
图 2 观测信号长度 m 对数据重构性能的影响

重构性能比较.从图 2 可以看出,本文算法具有最高的数据重构精度.同时,所有压缩数据重构算法的重构误差都随着观测信号长度 m 的增加而降低,并逐渐趋于稳定.另外,所有将数据分解成公共部分和个体部分的分布式算法在数据重构精度方面均优于基于贪婪思想的集中式算法.

图 3 展示了稀疏信号群中个体部分数量对 5 种数据重构算法的数据重构精度的影响.实验的参数为 $m = 96, n = 240, k = 15$.从图 3 可以看出,本文算法依然具有最高的数据重构精度.同时,所有压缩数据重构算法的重构误差都随着个体部分数量的增加而降低.显然,信号群中的信号越相似,重构算法重构时越容易,因此重构精度也就越高.另外,从图 3 还可以看出,信号群中个体部分数量对分布式算法的影响较大,而对基于贪婪思想的集中式算法影响较小.




Fig. 3 Influence of number of innovation components on the data reconstruction accuracy
图 3 个体部分数量对数据重构性能的影响

表 1 展示了 5 种压缩数据重构算法在不同簇头节点数量 N 和观测信号长度 m 条件下的相对均分误差.从表 1 可以看出,本文算法具有最高的数据重构精度.同时,所有算法的数据重构误差都随着簇头节点数量 N 和观测信号长度 m 的增加而降低.但是,簇头节点数量 N 的变化对数据重构误差的影响不显著.

图 4 和图 5 分别展示了本文算法在与图 3 相同的实验参数条件下稀疏度 k 和通信簇头数量 c 对数据重构精度的影响.从图 4 和图 5 可以看出,本文算法的数据重构误差随着稀疏度 k 的增加而逐渐升高,随着通信簇头数量 c 的增加而逐渐降低.显然,信号的稀疏度越高,数据重构算法的重构难度越大,

因此本文算法的数据重构精度也就相应越低.同时,互相通信的簇头节点越多,对信号群中公共部的

分的计算越精确,因此本文算法的数据重构精度也就越高.

Table 1 Influence of N and m on the Data Reconstruction Accuracy

表 1 簇头节点数 N 与观测信号长度 m 对数据重构精度的影响

Algorithms	$N=20$ $m=48$	$N=20$ $m=96$	$N=20$ $m=120$	$N=50$ $m=48$	$N=50$ $m=96$	$N=50$ $m=120$
Proposed Algorithm	7.8326×10^{-4}	5.0823×10^{-4}	4.4213×10^{-4}	7.7166×10^{-4}	5.0048×10^{-4}	4.3604×10^{-4}
Decentralized Reconstruction Algorithm	$10^{-3} \times 1.9$	7.8235×10^{-4}	7.0054×10^{-4}	$10^{-3} \times 1.3$	7.5791×10^{-4}	6.8253×10^{-4}
Decentralized Bayesian Algorithm	$10^{-3} \times 8.5$	$10^{-3} \times 5.0$	$10^{-3} \times 4.1$	$10^{-3} \times 8.3$	$10^{-3} \times 4.2$	$10^{-3} \times 3.3$
SSP Algorithm	$10^{-3} \times 12.9$	$10^{-3} \times 5.1$	$10^{-3} \times 4.9$	$10^{-3} \times 12.3$	$10^{-3} \times 6.0$	$10^{-3} \times 4.8$
SCoSaMP Algorithm	$10^{-3} \times 10.8$	$10^{-3} \times 4.9$	$10^{-3} \times 4.0$	$10^{-3} \times 9.9$	$10^{-3} \times 4.8$	$10^{-3} \times 3.9$




Fig. 4 Influence of k on the data reconstruction accuracy

图 4 稀疏度 k 对数据重构性能的影响




Fig. 5 Influence of c on the data reconstruction accuracy

图 5 通信簇头数量 c 对数据重构性能的影响

4.2 真实数据实验

在真实数据集实验中,首先基于黑河流域中游

生态水文数据集对比本文算法与其余 4 种数据重构算法的数据重构性能.实验中使用了离散小波变换基对原始数据进行稀疏表示,实验参数为 $n=128$, $\mu=16$, $\gamma=0.5$, $N=35$.

图 6 展示了 5 种算法在该数据集上的数据重构误差.从图 6 可以看出,本文算法具有最高的数据重构精度.同时,所有压缩数据重构算法的重构误差都随着采样率的增加而降低.显然,采样率越高,数据重构算法的重构难度越低,因此数据重构的误差也就相应越低.




Fig. 6 Data reconstruction accuracy of the ecological hydrological dataset in the middle reaches of the Heihe river

图 6 黑河流域中游生态水文数据集的数据重构精度

图 7 展示了所有压缩数据重构算法在 City Pulse 空气污染物数据集上的数据重构误差,其中选用了 NO₂ 浓度数据,除簇头节点数量 N 取值修改为 25 外其余实验参数与图 6 保持一致.基于该数据集的实验结论与基于黑河流域中游生态水文数据集的结论一致,本文算法依然展现出最高的数据重构性能.




Fig. 7 Data reconstruction accuracy of the City Pulse air pollutant dataset

图 7 City Pulse 空气污染物数据集的数据重构精度

5 结束语

本文提出了一种适用于无线传感器网络的分布式压缩数据重构算法.该算法采用分布式压缩感知理论中的 JSM-1 模型,通过将信号分解为公共部分和个体部分,并在交替方向乘子法中引入近似项求解,从而实现无线传感器网络的分布式数据收集操作.实验过程中分别使用合成数据集和真实数据集进行验证,结果表明,本文所提出的算法在数据重构精度方面优于现有的分布式压缩数据重构算法.在未来的工作中,将重点考虑如何引入边缘计算技术以实现大规模物联网中的分布式压缩数据重构.

参 考 文 献

[1] Nicolas P, Rafael F, Rami A, et al. A review of computational intelligence techniques in wireless sensor and actuator networks [J]. IEEE Communications Surveys & Tutorials, 2018, 20(4): 2822-2854

[2] Li Guorui, He Jingsha, Peng Sancheng, et al. Energy efficient data collection in large-scale Internet of things via computation offloading [J]. IEEE Internet of Things Journal, 2019, 6(3): 4176-4187

[3] Sheltami T, Musaddiq M, Shakshuki E. Data compression techniques in wireless sensor networks [J]. Future Generation Computer Systems, 2016, 64: 151-162

[4] Li Guorui, Wang Ying. Automatic ARIMA modeling-based data aggregation scheme in wireless sensor networks [J]. EURASIP Journal on Wireless Communications and Networking, 2013, 2013: 1-13

[5] Zimos E, Toumpakaris D, Munteanu A, et al. Multiterminal source coding with copula regression for wireless sensor networks gathering diverse data [J]. IEEE Sensors Journal, 2017, 17(1): 139-150

[6] Li Guorui, Peng Sancheng, Wang Cong, et al. An energy-efficient data collection scheme using denoising autoencoder in wireless sensor networks [J]. Tsinghua Science and Technology, 2019, 24(1): 86-96

[7] Dai Qionghai, Fu Changjun, Ji Xiangyang. Research on compressed sensing [J]. Chinese Journal of Computers, 2011, 34(3): 425-434 (in Chinese)
(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)

[8] Li Zhetao, Zang Lang, Tian Shujuan, et al. Data collection method in clustering network based on hybrid compressive sensing [J]. Journal of Computer Research and Development, 2017, 54(3): 493-501 (in Chinese)
(李哲涛, 臧浪, 田淑娟, 等. 基于混合压缩感知的分簇式网络数据收集方法[J]. 计算机研究与发展, 2017, 54(3): 493-501)

[9] Baron D, Duarte M, Sarvotham S, et al. An information-theoretic approach to distributed compressed sensing [C] // Proc of the 43rd Annual Allerton Conf on Communication, Control, and Computing. Monticello, Illinois: University of Illinois Press, 2005: 814-825

[10] Tropp J, Gilbert A, Strauss M. Algorithms for simultaneous sparse approximation. Part I: Greedy pursuit [J]. Signal Processing, 2006, 86(3): 572-588

[11] Feng J, Lee C. Generalized subspace pursuit for signal recovery from multiple-measurement vectors [C] // Proc of IEEE Wireless Communications and Networking Conf. Piscataway, NJ: IEEE, 2013: 2874-2878

[12] Blanchard J, Cermak M, Handle D. Greedy algorithms for joint sparse recovery [J]. IEEE Transactions on Signal Processing, 2014, 62(7): 1964-1704

[13] Li Gang, Wimalajeewa T, Varshney P. Decentralized and collaborative subspace pursuit: A communication-efficient algorithm for joint sparsity pattern recovery with sensor networks [J]. IEEE Transactions on Signal Processing, 2015, 64(3): 556-566

[14] Xu Wenbo, Cui Yupeng, Li Zhilin. A decentralized reconstruction algorithm for distributed compressed sensing [J]. Wireless Personal Communications, 2017, 96(4): 6175-6182

[15] Middy R, Chakravarty N, Naskar M. Compressive sensing in wireless sensor networks—A survey [J]. IETE Technical Review, 2017, 34(6): 642-654

[16] Xu Zhiqiang. Compressed sensing: A survey [J]. Scientia Sinica Mathematica, 2012, 42(9): 865-877 (in Chinese)
(许志强. 压缩感知[J]. 中国科学: 数学, 2012, 42(9): 865-877)

[17] Boyd S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. Foundations and Trends in Machine Learning, 2011, 3(1): 1-122

[18] Zhang Ce, Zhang Xia, Li Ou, et al. Data gathering using dynamic clustering based on WSNs compressive sensing algorithm [J]. Journal of Computer Research and Development, 2016, 53(9): 2000-2008 (in Chinese)
(张策, 张霞, 李欧, 等. 基于 CS 的无线传感器网络动态分簇数据收集算法 [J]. 计算机研究与发展, 2016, 53(9): 2000-2008)

[19] He Bingsheng, Hou Liusheng, Yuan Xiaoming. On full Jacobian decomposition of the augmented Lagrangian method for separable convex programming [J]. SIAM Journal on Optimization, 2015, 25(4): 2274-2312

[20] Deng Wei, Lai Mingjun, Peng Zhimin, et al. Parallel multi-block ADMM with $o(1/k)$ convergence [J]. Journal of Scientific Computing, 2013, 71(2): 712-736

[21] Hale E, Yin Wotao, Zhang Yin. Fixed-point continuation for l_1 -minimization: Methodology and convergence [J]. SIAM Journal on Optimization, 2008, 19(3): 1107-1130

[22] Jin Rui, Li Xin, Yan Baoping, et al. A nested eco-hydrological wireless sensor network for capturing surface heterogeneity in the middle-reach of Heihe river basin, China [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(11): 2015-2019

[23] Ali M, Gao Feng, Mileo A. CityBench: A configurable benchmark to evaluate RSP engines using smart city datasets [C] // Proc of the 14th Int Semantic Web Conf. Berlin: Springer, 2015: 374-389

[24] Chen Wei, Wassell I. A decentralized Bayesian algorithm for distributed compressive sensing in networked sensing systems [J]. IEEE Transactions on Wireless Communications, 2016, 15(2): 1282-1292



Li Guorui, born in 1980. PhD, associate professor, master supervisor. Member of CCF. His main research interests include wireless sensor networks, optimization theory, and machine learning.



Meng Jie, born in 1995. Master. Her main research interests include wireless sensor networks and optimization theory.



Peng Sancheng, born in 1974. PhD, professor, master supervisor. Senior member of CCF. His main research interests include network and information security, social networks, trust computing, and mobile computing.



Wang Cong, born in 1981. PhD, associate professor, master supervisor. Member of CCF. His main research interests include cloud computing and intelligence algorithm.