

基于分布式压缩感知的可穿戴多传感数据 联合重构新方法

徐海东¹ 吴建宁¹ 王珏²

¹(福建师范大学数学与计算机科学学院 福州 350007)

²(西安交通大学生物医学信息工程教育部重点实验室 西安 710049)

摘要 为提高可穿戴多传感数据远程联合重构性能,提出了一种基于分布式压缩感知的可穿戴多传感加速度数据联合重构新方法。该方法首先对可穿戴多传感原始数据压缩编码,将数据融合传送至远端服务器;然后,基于可穿戴传感数据的时空相关性,构建块稀疏贝叶斯学习联合重构算法,实现压缩数据解码,准确重构各传感原始数据;最后,新方法对美国加州伯克利大学可穿戴多传感运动数据进行分析。实验结果表明,对不同编码采样率,文章所提方法重构性能明显优于传统的算法,并且能够准确解码压缩数据,有望在远程医疗环境下推广应用。

关键词 分布式压缩感知;多传感器数据;联合重构;块稀疏贝叶斯学习

中图分类号 TP 393 **文献标志码** A

A Novel Distributed Compressed Sensing-Based Joint Reconstruction Method for Multiple Sensor Data from Wearable Device

XU Haidong¹ WU Jianning¹ WANG Jue²

¹(School of Mathematics and Computer Science of Fujian Normal University, Fuzhou 350007, China)

²(Key Laboratory of Biomedical Information Engineering of Education Ministry, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract In order to improve the performance of joint reconstruction of multi-sensor acceleration data from different wearable devices, a novel approach to jointly reconstruct based on distributed compressed sensing (DCS) algorithm was proposed. The basic idea was that the raw data was firstly compressed through encoding, and the encoded data was sent to remote terminal. Then, with the spatiotemporal correlation of data from sensors, the joint reconstruction method based on Block Sparse Bayesian Learning (BSBL) was applied to decode the compressed data at remote terminal. At last, the wearable data from University of California-Berkeley database was analyzed. Experiments show that the proposed approach can gain better performance than the traditional joint reconstruction algorithms such as TMSBL and tMFOCUSS, and decode the compressed data accurately.

收稿日期: 2015-04-25 修回日期: 2015-07-05

基金项目: 国家科技支撑项目(2012BAI33B01); 福建省自然科学基金项目(2013J01220); 福建省高等学校教学改革研究项目(JAS14674); 福建师范大学本科教学改革项目(I201302021); 福建师范大学2014年研究生教育改革研究项目(MSY201426)

作者简介: 徐海东, 硕士研究生, 研究方向为无线传感网技术与应用; 吴建宁(通讯作者), 副教授, 研究方向为生物医学信号处理、嵌入式系统与物联网、可穿戴技术与医学应用, E-mail: jianningwu@fjnu.edu.cn; 王珏(通讯作者), 教授, 研究方向为脑功能障碍发病机制、干预策略和方法, 远程康复技术, E-mail: juewang@mail.xjtu.edu.cn.

The proposed technique may be helpful for telemedicine application.

Keywords distributed compressed sensing; multi-sensor data; joint reconstruction; block sparse Bayesian learning

1 引言

目前, 基于低成本可穿戴设备的无线体域网 (Wireless Body Area Networks, WBANs) 在远程诊断、监护、康复评价等医疗领域得到广泛的关注和应用^[1]。该技术通过佩戴于人体身上的生物医学传感器获取多种生理信息 (例如心电、脉搏、血压、运动加速度等), 然后经互联网传送至远端, 为医院、健康评价中心等远端单位医疗评价提供可靠数据。目前, 可穿戴设备的低功耗、远端数据准确联合重构困扰着无线体域网在远程医疗环境中的应用。因此, 如何降低可穿戴设备功耗、准确联合重构各传感节点数据是众多学者探讨的热点问题。

当前, 在传输数据前采用数据压缩方法来降低体域网系统功耗是一种行之有效的方式。其基本思路是首先通过压缩数据, 减少数据传输量, 力争降低数据在传输中的系统能量损耗; 然后准确重构数据, 恢复原始数据。然而, 传统的数据压缩方法依赖于奈奎斯特采样率, 在数据压缩编码过程中, 仅能依靠主观阈值方法选取数据压缩变换系数, 易丢失数据相关信息。近年来出现的压缩感知技术 (Compressed Sensing, CS)^[2] 是一种全新的数据压缩方法, 在低功耗可穿戴研究领域中得到广泛关注。该技术不同于传统的数据压缩方法, 它主要依赖于数据稀疏性, 采用不同于稀疏表示数据的测量矩阵, 实现数据压缩和重构。在无线体域网应用中, 可自定义测量矩阵, 采用线性投影技术压缩数据, 可有效降低可穿戴节点设备功耗, 降低传输带宽^[3]。同时, 在远端服务

器通过求解优化问题准确重构压缩数据。然而, 压缩感知技术仅考虑数据的时间相关性或空间相关性, 仅能实现点对点单一的数据重构问题, 未能充分利用数据间的时空相关性, 难以实现多点对多点的传感数据联合重构问题, 影响其在无线体域网远程医疗环境中的应用。

与 CS 单一点对点数据重构不同的是, 分布式压缩感知 (Distributed Compressive Sensing, DCS)^[4] 在多节点数据压缩重构研究领域受到关注。该技术充分将多元编码技术和压缩感知技术相结合, 旨在有效利用多节点数据的时空相关性, 减少数据冗余性, 实现多节点数据准确联合重构。在无线体域网应用中, 可减少重构数据测量维数, 降低传感节点能量消耗, 节省存储空间, 降低计算复杂度, 有效解决传统多传感数据融合分布式编码算法 (如预编码算法^[5]、分布式 KLT 编码算法及分布式小波变换算法^[6]等) 仅考虑单个节点数据相关性, 未考虑节点间互相关性不足问题。在分布式压缩感知技术研究中, 联合重构算法是其中一个研究热点^[7]。其中, 典型的重构模型是 JSM (Joint Sparse Model), 包括: JSM-1、JSM-2 和 JSM-3。这些模型假设融合数据存在联合稀疏性, 将数据划分为公共部分和自身部分, 减少重构算法冗余性, 提高算法精度。但在算法实现过程中, 能否准确划分数据两个部分的比例将影响算法性能。近年来, 一些相关研究从多传感数据融合矩阵模型角度来探索联合重构算法, 其基本思想是可将多个传感数据联合重构问题假设为一个多测量向量 (Multiple Measurement Vector, MMV) 问题^[8,9], 即由共享

支撑集组成的多传感稀疏数据联合重构问题。而联合稀疏性是 MMV 重构算法的核心, 与分布式压缩感知的联合稀疏模型 JSM-2 类似。但该模型难以适用于非稀疏性的生物医学数据联合重构。在解决非稀疏数据重构研究中, 基于块稀疏贝叶斯学习算法(Block Sparse Bayesian Learning, BSBL)^[10]受到广泛重视。该算法假设非稀疏数据可由块数据结构组成, 通过充分利用块稀疏性提高非稀疏数据重构精度^[11,12]。目前常用的算法主要有: BSBL-EM(期望最大化)、BSBL-BO(边界优化), BSBL-L1 和 BSBL-FM^[13](快速边缘化)。但这些算法仅适用于单测量向量(Single Measurement Vector, SMV)模型。除此之外, 有学者尝试将数据块结构和 MMV 模型相结合, 构建了一些基于块结构 MMV 重构算法(如 Liu 等^[14]提出的用于解决多通道生理信号联合重构问题的 MBSBL-FM 算法, 该算法能够在降低体域网系统功耗的同时实现多通道生理信号的精确联合重构, 然而该算法只是针对胎儿心电信号, 而不是非稀疏性的加速度信号), 虽尚未取得较满意结果, 但无疑是无线体域网多传感数据联合重构问题提供了新的途径。

本研究针对无线体域网多传感数据的时空相关性、非稀疏性等特点, 提出了一种基于分布式压缩感知的无线体域网多传感数据联合重构新方法。其基本思想是将无线体域网多传感节点数据压缩编码, 融合多传感传输数据, 然后将融合数据进行块划分, 采用 MBSBL-FM 算法实现多传感数据联合重构, 为可穿戴传感节点低功耗、以及后续的医疗评价获取数据提供可靠的技术支撑。采用美国加州伯克利大学的动作识别数据中多传感加速度数据验证所提算法的有效性, 并与一些传统联合重构算法, 如 TMSBL(Temporal MMV Sparse Bayesian Learning)、tMFOCUSS(Temporal MMV Focal Undetermined System Solver)相比较, 进一步评价

所提算法的可行性。

2 基于分布式压缩感知的多传感数据联合重构

无线体域网传感加速度数据在随时间变化的非平稳随机过程中, 能够保持短时平稳性, 且各传感节点保持一定的空间相关性, 采用分布式压缩感知技术可将无线体域网多传感加速度数据压缩编码传输, 减少数据传输量, 同时利用多传感数据的时空相关性, 实现多传感数据联合重构。基于上述思路, 提出了一种基于分布式压缩感知的多传感加速度数据联合重构系统框架, 如图 1 所示。其基本思路是: 首先, 利用分布式信源编码技术对各传感节点压缩编码, 将压缩编码数据传输至协调器节点进行数据融合; 然后, 利用 MBSBL 算法联合重构压缩数据, 即对编码数据进行解码, 恢复原始多传感数据, 为后续诊断、治疗等提供可靠数据。本文着重探讨多传感加速度数据的压缩和联合重构问题, 下面简要介绍分布式压缩感知技术。




图 1 基于分布式压缩感知的体域网多传感器数据联合重构系统框架

Fig. 1 The DCS-based joint reconstruction system framework of multi-sensor data of BAN

2.1 分布式压缩感知理论

分布式压缩感知是传统压缩感知理论的推广技术^[4], 该技术将分布式信源编码(Distributed Source Coding, DSC)技术和传统压缩感知技术相结合, 利用数据时空相关性, 降低数据间冗余

信息, 有效解决分布式数据压缩和重构问题。其技术实现包括: 数据稀疏表示、分布式压缩编码和联合重构三个部分。数据可稀疏表示为

$$\mathbf{x}_j = \Psi \cdot \boldsymbol{\theta}_j, j \in \{1, 2, \dots, J\} \quad (1)$$

其中, $\mathbf{x}_j \in \mathbb{R}^N$; $\boldsymbol{\theta}_j \in \mathbb{R}^N$; $\Psi \in \mathbb{R}^{N \times N}$; $\boldsymbol{\theta}_j$ 为表示稀疏系数的向量, 其非零元素位置相同, 但取值不同。数据结构表示为 $\Omega \subset \{1, 2, \dots, N\}$, 若 $|\Omega| = K$, 则称分布式数据具有相同的 K 稀疏特性, 即联合稀疏性, 是分布式压缩感知理论的先验性。

DCS 分布式压缩编码主要采用不同的测量矩阵 $\Phi_j \in \mathbb{R}^{M_j \times N}$ ($M_j < N$) 对每个数据 \mathbf{x}_j 进行压缩采样, 即

$$\mathbf{y}_j = \Phi_j \mathbf{x}_j = \Phi_j \Psi \boldsymbol{\theta}_j \quad (2)$$

其中, 测量矩阵 Φ_j 满足 RIP (Restricted Isometry Property) 性质。常用的测量矩阵为: 独立同分布的随机高斯矩阵, 伯努利矩阵, 稀疏二进制矩阵等。

联合重构算法的设计是 DCS 技术的核心部分, 也是一个解码过程, 即通过已知压缩编码数据 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J] \in \mathbb{R}^{M \times J}$ 和测量矩阵 $\Phi \in \mathbb{R}^{M \times N}$, 求解稀疏信号 $\boldsymbol{\theta} = [\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_J] \in \mathbb{R}^{N \times J}$, 然后利用得到 $\boldsymbol{\theta}$ 和稀疏基 Ψ , 获得重构后的分布式数据 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_J] \in \mathbb{R}^{N \times J}$ 。通常通过下列最优化问题求解稀疏系数 $\boldsymbol{\theta}$:

$$\arg \min \|\boldsymbol{\theta}\|_0, \text{ s.t. } \mathbf{Y} = \Phi \Psi \boldsymbol{\theta} = \mathbf{A} \boldsymbol{\theta} \quad (3)$$

其中, $\mathbf{A} \in \mathbb{R}^{M \times N}$ 为感知矩阵; $\|\boldsymbol{\theta}\|_0$ 是 $\boldsymbol{\theta}$ 的零范数。由于该问题是一个 NP-Hard 问题, 通常将式 (3) 求解转为 l_1 范数求解问题, 即

$$\arg \min \|\boldsymbol{\theta}\|_1, \text{ s.t. } \mathbf{Y} = \Phi \Psi \boldsymbol{\theta} \quad (4)$$

当考虑系统含有噪声时, 式 (3) 可表示为

$$\arg \min \|\boldsymbol{\theta}\|_0, \text{ s.t. } \mathbf{Y} = \mathbf{A} \boldsymbol{\theta} + \mathbf{Z} \quad (5)$$

其中, $\mathbf{Z} \in \mathbb{R}^{M \times N}$ 表示观测噪声。

2.2 块稀疏贝叶斯学习联合重构算法

分布式压缩感知联合重构主要依据数据联合稀疏性 (如 JSM-1、JSM-2、JSM-3 联合稀疏模型) 来实现。考虑到无线体域网在医疗环境获取的生物医学数据的非稀疏性, 本文基于 MMV 模

型构建块稀疏贝叶斯学习联合重构算法, 来解决无线体域网多传感非稀疏性数据重构问题。其基本思路就是依据块稀疏性, 在预先无需确定数据稀疏度的情况下, 采用贝叶斯学习算法最优估计稀疏系数 $\boldsymbol{\theta}_j$, 能够比传统 MMV 重构算法获得最优重构性能。本文所提联合重构算法如下:

对于 J 个传感器数据 $\mathbf{X} = [\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^J]$, $\mathbf{x}^i \in \mathbb{R}^{N \times 1}$ 为第 i 个传感器采集数据的列向量, 则基本的 MMV 模型可描述为:

$$\mathbf{Y} = \mathbf{A} \mathbf{X} + \mathbf{V} \quad (6)$$

其中, \mathbf{A} 为 $M \times N$ 维感知矩阵; \mathbf{Y} 为 $M \times J$ 维压缩数据; \mathbf{X} 为 $N \times J$ 维稀疏信号; \mathbf{V} 为 $M \times J$ 维未知测量噪声。

块稀疏贝叶斯学习联合重构算法在 MMV 模型的基础上通过引入块稀疏结构信息, 将数据矩阵 \mathbf{X} 划分为 g 块, 且每块 $\mathbf{X}_i \in \mathbb{R}^{d_i \times J}$ (d_i 表示第 i 块长度), $N = g d_i$ (N 表示原始加速度信号长度)。

在该算法中, 假设数据块 \mathbf{X}_i 满足多元高斯分布, 且数据块间相互独立:

$$p(\mathbf{X}_i; \gamma_i) = MN(\mathbf{X}_i; \mathbf{0}, \gamma_i \mathbf{I}_{d_i}, \mathbf{I}_J), i = 1, \dots, g \quad (7)$$

式 (7) 可改写为

$$p(\text{vec}(\mathbf{X}_i); \gamma_i) = N(\text{vec}(\mathbf{X}_i); \mathbf{0}, \gamma_i \mathbf{I}_{d_i \cdot J}) \quad (8)$$

其中, γ_i 为控制块 \mathbf{X}_i 关联性的可变参数, 当 $\gamma_i = 0$, 其对应数据块 $\mathbf{X}_i = \mathbf{0}$ 。利用 $\gamma_i \mathbf{I}_{d_i \cdot J} = \mathbf{I}_J \otimes \gamma_i \mathbf{I}_{d_i}$, 将式 (7) 表示为:

$$p(\mathbf{X}; \{\gamma_i\}) = MN(\mathbf{X}; \mathbf{0}, \boldsymbol{\Gamma}, \mathbf{I}_J) \quad (9)$$

其中, $\boldsymbol{\Gamma}$ 为一个以 $\gamma_i \mathbf{I}_{d_i}$ 为对角线上元素的块对角矩阵。同时假设测量噪声 \mathbf{V} 满足独立同分布的高斯分布, 则压缩数据 \mathbf{Y} 满足:

$$p(\mathbf{Y} | \mathbf{X}; \boldsymbol{\beta}) = MN(\mathbf{Y} | \mathbf{A} \mathbf{X}; \boldsymbol{\beta}^{-1} \mathbf{I}_M, \mathbf{I}_J) \quad (10)$$

采用 (9) 和 (10), 可得到 \mathbf{X} 的后验概率分布:

$$p(\mathbf{X} | \mathbf{Y}; \{\gamma_i\}, \boldsymbol{\beta}) = MN(\mathbf{X}; \boldsymbol{\mu}, \boldsymbol{\Sigma}, \mathbf{I}_J) \quad (11)$$

其中, 均值 $\boldsymbol{\mu} = \boldsymbol{\beta} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \mathbf{Y}$; 协方差矩阵 $\boldsymbol{\Sigma} = (\boldsymbol{\Gamma}^{-1} + \boldsymbol{\beta} \mathbf{A}^T \mathbf{A})^{-1}$ 。

然后采用第二类最大似然估计方法 (Type II

maximum likelihood method) 可估计参数 $\{\gamma_i\}$ 和 β 。通常采用以下代价函数:

$$L(\{\gamma_i\}, \beta) = -2 \log p(\mathbf{Y}; \{\gamma_i\}, \beta) \\ = N \log |\mathbf{C}| + \text{Tr}[\mathbf{Y}^T \mathbf{C}^{-1} \mathbf{Y}] \quad (12)$$

其中, $\mathbf{C} = \beta^{-1} \mathbf{I}_M + \mathbf{A} \mathbf{\Gamma} \mathbf{A}^T$ 。

为提高算法运算速度, 采用快速边缘似然最大化 (Fast Marginalized Likelihood Maximization) 方法优化式 (12) 的代价函数。令 $\mathbf{A}_i \in \mathbb{R}^{M \times d_i}$ 为感知矩阵中的第 i 列块矩阵, 则式 (12) 中的函数 \mathbf{C} 可表示为:

$$\mathbf{C} = \beta^{-1} \mathbf{I} + \sum_{m \neq i} \mathbf{A}_m \gamma_m \mathbf{A}_m^T + \mathbf{A}_i \gamma_i \mathbf{A}_i^T = \mathbf{C}_{-i} + \mathbf{A}_i \gamma_i \mathbf{A}_i^T \quad (13)$$

其中, $\mathbf{C}_{-i} \triangleq \beta^{-1} \mathbf{I} + \sum_{m \neq i} \mathbf{A}_m \gamma_m \mathbf{A}_m^T$ 。

根据 Wood-bury 矩阵恒等式, 可将代价函数 L 表示为:

$$L = N \log |\mathbf{C}_{-i}| + \text{Tr}[\mathbf{Y}^T \mathbf{C}_{-i}^{-1} \mathbf{Y}] + N \log |\mathbf{I}_{d_i} + \\ \gamma_i \mathbf{s}_i | - \text{Tr}[\mathbf{q}_i^T (\gamma_i^{-1} \mathbf{I}_{d_i} + \mathbf{s}_i)^{-1} \mathbf{q}_i] \quad (14) \\ = L(-i) + L(i)$$

其中, $\mathbf{s}_i = \mathbf{A}_i^T \mathbf{C}_{-i}^{-1} \mathbf{A}_i$, $\mathbf{q}_i = \mathbf{A}_i^T \mathbf{C}_{-i}^{-1} \mathbf{Y}$ 。

通过优化代价函数 $L(i)$ 可得参数 γ_i 的学习规则为:

$$\gamma_i = \frac{1}{d_i} \text{Tr}[\mathbf{s}_i^{-1} (\mathbf{q}_i \mathbf{q}_i^T - \mathbf{s}_i) \mathbf{s}_i^{-1}] \quad (15)$$

针对无线体域网多传感加速度数据联合重构问题, 采用基于 BSBL 框架的快速边缘化最大似然估计方法, 即 MBSBL-FM 算法, 其算法步骤详见 Liu 等^[14]和 Yang 等^[15]的研究。

为此, 本文所提分布式压缩感知多传感加速度数据联合重构算法步骤如下所示:

(1) 根据公式 (2), 将多传感加速度数据 \mathbf{x}_j ($j=1, 2, \dots, J$) 进行独立压缩编码, 获得压缩数据 $\mathbf{y}_j = \Phi_j \mathbf{x}_j$ ($j=1, 2, \dots, J$);

(2) 在协调节点将各传感节点所测的压缩数据进行数据融合, 即 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J]$;

(3) 在远程服务器, 基于稀疏基矩阵 Ψ , 压缩数据 \mathbf{Y} , 测量矩阵 Φ , 利用 MBSBL-FM 算法

求解多传感数据块稀疏系数 θ ;

(4) 利用估计求解得到的块稀疏系数 θ , 通过公式 (1) 重构多传感加速度数据 $\hat{\mathbf{X}} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_J]$ 。

3 实验结果及分析

3.1 实验数据集

采用美国加州伯克利大学可穿戴式传感器的动作识别数据库 (Wearable Action Recognition Database, WARD)^[15] 进行仿真实验。在采集过程中, 通过 5 个传感节点 (2 个节点放置在手腕, 2 个节点放置在脚踝处, 1 个节点放置在腰部) 分别对 20 名不同年龄、身高、体重的健康受试者 (其中 13 名男性, 7 名女性) 进行人体运动数据采集, 主要包括 13 动作: 站、坐、躺、向前走、逆时针走、顺时针走、向左转、向右转、上楼、下楼、慢跑、跳、推轮椅。每种动作重复实验 5 次。共收集到 1 300 个动作样本, 其中每个样本包含一个 3 轴加速度数据和一个 2 轴陀螺仪数据, 数据采样率设置为 20 Hz。本文仅考虑处理加速度数据集。

3.2 重构性能指标

采用常用的均方误差和百分比均方根误差作为重构性能指标^[13-15], 有效评价联合重构性能。

(1) 相对均方根误差

$$mse = \frac{\|\hat{\mathbf{x}} - \mathbf{x}\|_2^2}{\|\mathbf{x}\|_2^2} \quad (16)$$

$$MSE = \frac{\|\hat{\mathbf{X}} - \mathbf{X}\|_2^2}{\|\mathbf{X}\|_2^2} \quad (17)$$

其中, $\hat{\mathbf{x}}$ 、 $\hat{\mathbf{X}}$ 均表示重构后数据; 式 (16) 为针对 SMV 模型的重构误差; 式 (17) 为针对 MMV 模型的联合重构误差。

(2) 百分比均方根误差

$$PRD = 100 \times \frac{\|\mathbf{x} - \hat{\mathbf{x}}\|_2}{\|\mathbf{x}\|_2} \quad (18)$$

其中, \mathbf{x} 为原始数据; $\hat{\mathbf{x}}$ 为重构数据。

(3) 数据采样率

$$R = M / N \quad (19)$$

其中, M 、 N 分别表示压缩数据和原始数据的长度。

3.3 实验结果

实验中, 分别截取人体向前行走模式 x 轴传感节点的加速度数据, 数据长度为 256 个采样点, 按 24 个点长均匀分块; 测量矩阵选取 128×256 的稀疏二进制矩阵, 其中每列包含 12 个非零元素; 稀疏基选用 DCT 基。为验证本文所提算法性能, 选取基于 MMV 模型传统重构算法(如 TMSBL 算法^[10]和 tMFOCUSS^[18]算法)进行对比, 根据相应文献设置该算法实验参数, 所有测试重复实验 500 次, 结果取平均值。仿真实

验以 MATLAB7.0 为工具, 运行环境为 Intel(R) Core(TM) i5-3470 3.20GHz CPU 和 4.00 GB RAM。

上述算法重构结果如图 2 所示(采样率 R 为 0.5)。其中, 图 2(a) 为原始加速度数据; 图 2(b)、(c)、(d) 分别为采用 TMSBL 算法, tMFOCUSS 算法和 MBSBL-FM 算法重构结果。

为客观比较上述基于 MMV 模型算法重构算法性能, 基于不同采样率, 采用相对均方根误差作为评价指标进行重构性能比较, 实验结果如图 3 所示。从图 3 可知, 当采样率为 0.5 时, MBSBL-FM 算法均方误差仅为 0.005 9, 明显低于其他两种重构算法的均方误差; 当采样率接近 0.4 时, MBSBL-FM 算法的均方误差为 0.012,

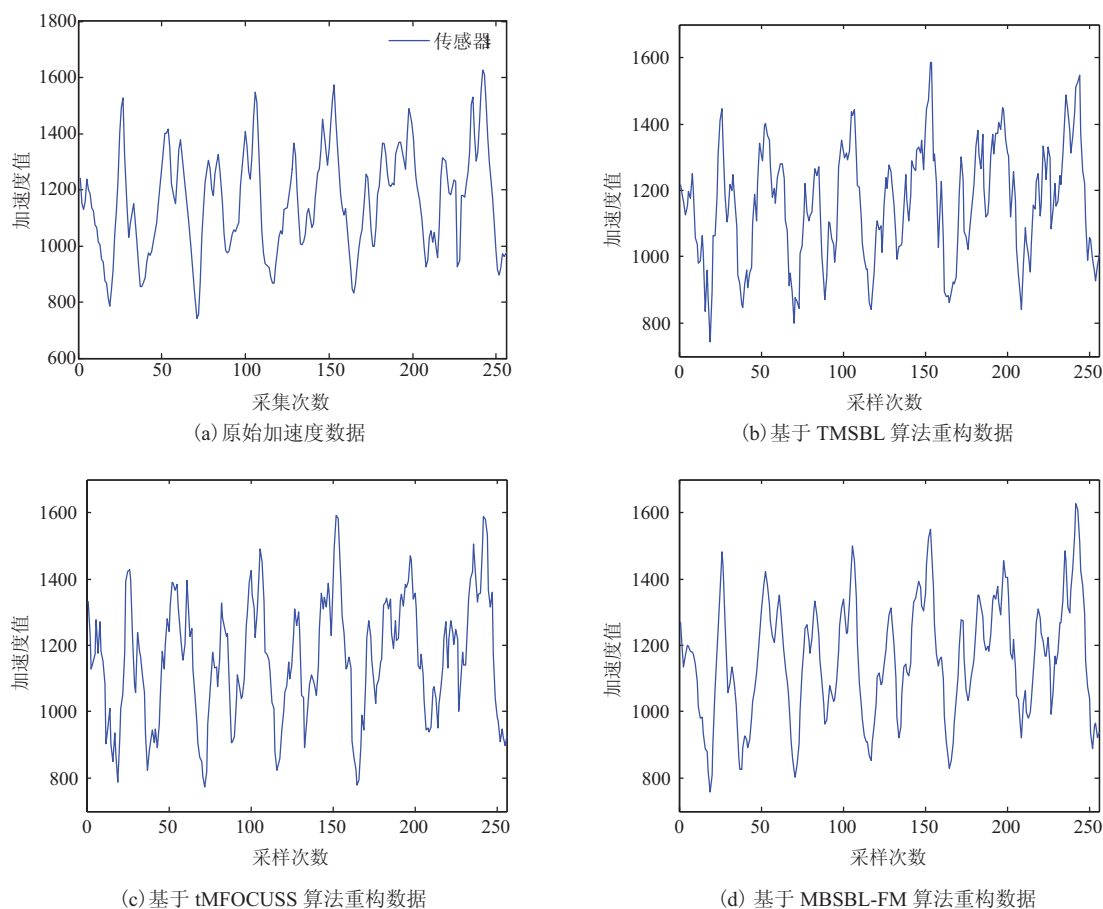


图 2 三种 MMV 模型重构算法结果

Fig. 2 The acceleration signal reconstruction result of different MMV model algorithms

仍可保持较好的重构性能。此外,在无噪声的情况下,三种算法的均方根误差均随采样率增加而降低。上述结果表明,本文所提算法能够利用加速度信号的块稀疏性,获取多传感数据内在时空相关性信息,克服传统 MMV 模型重构算法仅依赖于数据稀疏性先验知识,难以获取非稀疏数据内在时空相关性的不足,可有效提高多传感非稀疏性加速度数据联合重构性能。

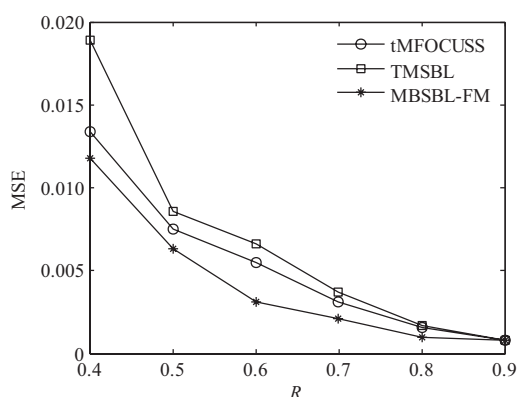


图3 不同采样率下三种算法的重构性能对比

Fig. 3 The acceleration signal reconstruction performance comparison of different algorithms with different sampling rate

此外,为进一步评价本文所提算法有效利用多传感加速度数据时空相关性特点,将本文基于 MMV 模型的联合重构算法(MBSBL-FM)与基于 SMV 模型的重构算法(BSBL-FM)的性能相比较。实验中,传感加速度数据长度为 256,联合稀疏数据个数为 3。以百分比均方根误差作为性能评价指标,结果如图 4 所示。由图 4 可知,基于 MMV 模型联合重构算法重构性能明显优于基于 SMV 模型重构算法性能,并且在相同重构误差时,分布式压缩感知技术比传统压缩感知技术需要更低的采样率,也就是所需的压缩测量维数更小,有助于降低体域网传感节点功耗。结果表明,基于 MMV 模型的分布式压缩感知联合重构算法能够有效利用传感数据内自相关性和传感数据之间的互相关性,减少数据冗余性。更重要的是,该算法能够在少量压缩数据情况下,取得优

异的联合重构性能,对于构建低功耗无线体域网远程运动监测系统具有重要意义。

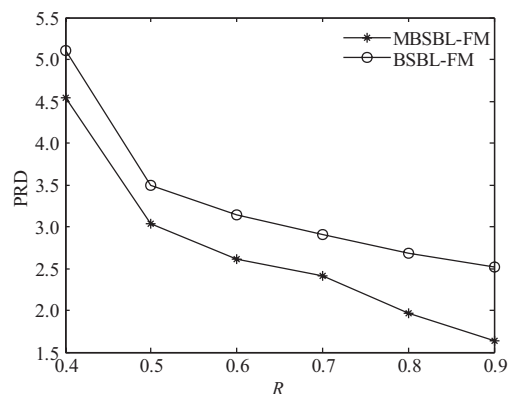


图4 基于 MMV 和 SMV 的重构性能比较

Fig. 4 The acceleration signal reconstruction performance comparison of MMV-based and SMV-based model algorithms

4 结论

本文提出了一种基于分布式压缩感知的可穿戴无线体域网多传感加速度数据联合重构的新方法。该方法能够对多传感加速度数据压缩编码,融合多传感数据,降低传感节点功耗;同时基于 MMV 模型构建块稀疏贝叶斯学习算法,充分利用多传感加速度数据间的时空相关性,减少数据冗余度,实现多传感非稀疏性加速度数据的联合重构,有望为远程监测生理数据信息提供一个新的技术平台。

参考文献

- [1] Mo LF, Liu SP, Gao RX, et al. Wireless design of a multisensor system for physical activity monitoring [J]. IEEE Transactions on Biomedical Engineering, 2012, 59(11): 3230-3237.
- [2] Candes EJ, Wakin WB. An introduction to compressive sampling [J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [3] Li SC, Xu LD, Wang XH. A continuous biomedical signal

- acquisition system based on compressed sensing in body sensor networks [J]. *IEEE Transactions on Industrial Informatics*, 2013, 9(3): 1764-1771.
- [4] Duarte MF, Sarvotham S, Baron D, et al. Distributed compressed sensing of jointly sparse signals [C] // *Proceedings of the 2005 Asilomar Conference on Signals, System and Computers*, 2005: 1537-1541.
- [5] Luo HY, Pottie G. Routing explicit side information for data compression in wireless sensor networks [M] // *Distributed Computing in Sensor Systems*. Springer-Verlag Berlin Heidelberg, 2005: 75-88.
- [6] Wagner R, Choi H, Baraniuk R, et al. Distributed wavelet transform for irregular sensor network grids [C] // *2005 IEEE/SP 13th Workshop on Statistical Signal Processing*, 2005: 1196-1201.
- [7] Yin HP, Li JX, Chai Y, et al. A survey on distributed compressed sensing: theory and applications [J]. *Frontiers of Computer Science*, 2014, 8(6): 893-904.
- [8] 王法松, 张林让, 周宇. 压缩感知的多重测量向量模型与算法分析 [J]. *信号处理*, 2012, 28(6): 781-792.
- [9] 练秋生, 刘芳, 陈书贞. 基于块 A^* 正交匹配追踪的多传感器数据联合重构算法 [J]. *电子与信息学报*, 2013, 35(3): 721-727.
- [10] Zhang ZL, Rao BD. Sparse signal recovery with temporally correlated source vectors using sparse Bayesian learning [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(5): 912-926.
- [11] Zhang ZL, Jung TP, Makeig S, et al. Compressed sensing for energy-efficient wireless telemonitoring of noninvasive fetal ECG via Block Sparse Bayesian Learning [J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(2): 300-309.
- [12] Zhang ZL, Jung TP, Makeig S, et al. Compressed sensing of EEG for wireless telemonitoring with low energy consumption and inexpensive hardware [J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(1): 221-224.
- [13] Liu BY, Zhang ZL, Gary X, et al. Energy efficient telemonitoring of physiological signals via compressed sensing: a fast algorithm and power consumption evaluation [J]. *Biomedical Signal Processing and Control*, 2014, 11: 80-88.
- [14] Liu BY, Zhang ZL, Fan HQ, et al. Compression via compressive sensing: a low-power framework for the telemonitoring of multi-channel physiological signals [C] // *IEEE International Conference on Bioinformatics and Biomedicine*, 2013: 9-12.
- [15] Yang AY, Jafari R, Sastry SS, et al. Distributed recognition of human actions using wearable motion sensor networks [J]. *Journal of Ambient Intelligence and Smart Environments*, 2009, 1(2): 103-115.