

## 基于过完备字典稀疏表示的多通道脑电信号压缩感知联合重构

吴建宁<sup>\*①</sup> 徐海东<sup>①</sup> 王珏<sup>②</sup>

<sup>①</sup>(福建师范大学数学与计算机科学学院 福州 350007)

<sup>②</sup>(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:** 该文基于多通道脑电信号时空特性构建非正交变换过完备字典, 准确稀疏表示蕴含时空相关性信息的多通道脑电信号, 提高基于时空稀疏贝叶斯学习模型的多通道脑电信号压缩感知联合重构算法性能。实验选用 eegmmidb 脑电数据库的多通道脑电信号验证所提算法有效性。结果表明, 基于过完备字典稀疏表示的多通道脑电信号, 能够为多通道脑电信号压缩感知重构算法提供更多的时空相关性信息, 比传统多通道脑电信号压缩感知重构算法所得的信噪比值提高近 12 dB, 重构时间减少 0.75 s, 显著提高多通道脑电信号联合重构性能。

**关键词:** 脑电信号稀疏表示; 过完备字典; 联合重构; 时空稀疏贝叶斯学习; 压缩感知

中图分类号: R741.044; TP393

文献标识码: A

文章编号: 1009-5896(2016)07-1666-08

DOI: 10.11999/JEIT151079

## A New Joint Reconstruction Algorithm of Compressed Sensing for Multichannel EEG Signals Based on Over-complete Dictionary Approach

WU Jianning<sup>①</sup> XU Haidong<sup>①</sup> WANG Jue<sup>②</sup>

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

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

**Abstract:** In this paper, the over-complete dictionary with nonorthogonal factor is firstly gained from Electro Encephalo Graph (EEG) signal with spatio-temporal characteristics, and then it is used to sparsely represent multichannel EEG signal for containing the information of spatio-temporal correlation. This contributes to enhance the performance of the joint reconstruction of multi-channel EEG signal using the Spatio-Temporal Sparse Bayesian Learning (STSBL) algorithm. The multi-channel EEG signal from the open eegmmidb database are selected to evaluate the effectiveness of the proposed algorithm. The experimental results show that the designed over-complete dictionary can provide more valuable information about the spatio-temporal characteristics in multichannel EEG signal for STSBL algorithm. When compared to the existing conventional compressed sensing technique for reconstruction multi-channel EEG signal, the signal-noise ratio of the proposed method increases by 12 dB and the reconstruction time decreases by 0.75 s, which significantly improve the performance of joint reconstruction of multichannel EEG signal.

**Key words:** Sparse representation of EEG signal; Over-complete dictionary; Joint reconstruction; Spatio-temporal sparse Bayesian learning; Compressed Sensing (CS)

### 1 引言

近年来, 基于大脑皮质解剖学分区构建体域网

(Wireless Body Sensor Network, WBSN)多通道脑电信号采集系统在脑电信号远程监测、脑机接口等领域受到高度关注和应用<sup>[1,2]</sup>。目前, 多通道脑电信号体域网采集系统高功耗是困扰其在实际应用的主要因素。近年相关研究较多尝试采用新兴压缩感知技术(Compressed Sensing, CS)<sup>[3]</sup>高压采集脑电数据, 大量减少脑电数据传输量, 降低采集系统功耗, 然后基于重构算法恢复压缩脑电数据<sup>[4,5]</sup>。目前研究难点仍集中于如何在高压率状况下, 准确重构多通道脑电数据<sup>[6-8]</sup>。

单测量向量(Single Measurement Vector, SMV)模型<sup>[9]</sup>压缩感知框架较早被用来探讨多通道脑电信

收稿日期: 2015-09-21; 改回日期: 2016-04-29; 网络出版: 2016-05-31

\*通信作者: 吴建宁 jianmingwu@fjnu.edu.cn

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), 福建师范大学创新创业教育改革研究项目(D201503005)

Foundation Items: The National Science and Technology Supporting Project (2012BAI33B01), The Natural Science Foundation of Fujian Province (2013J01220), The Teaching Reform Project of University of Fujian Province (JAS14674), The Project of Education of Entrepreneurship and Innovation of Fujian Normal University (D201503005)

号压缩重构可行性, 相关研究大多采用离散余弦变换基近似稀疏表示脑电信号, 满足压缩感知理论的数据稀疏性, 基于 SMV 模型对单通道脑电信号逐个重构实现多通道脑电信号的压缩重构。常用的压缩感知重构算法主要有正交匹配追踪(Orthogonal Matching Pursuit, OMP)<sup>[10]</sup>、子空间追踪(Subspace Pursuit, SP)<sup>[11]</sup>、平滑 L0-范数(Smoothed L0-norm, SL0)<sup>[12]</sup>算法等。然而, 上述算法仅能恢复脑电信号中显著非零元素, 未能有效利用脑电信号电生理活动时空相关性, 导致重构性能较差。近年来, 文献[13]尝试采用块稀疏贝叶斯学习算法(Block Sparse Bayesian Learning, BSBL)充分利用单通道脑电信号时间相关性和块稀疏性, 来改善单通道脑电信号重构性能<sup>[14,15]</sup>。但该算法逐个重构单通道脑电信号的计算负荷仍随通道数量增加而呈线性增大, 不利于多通道脑电信号远程同步实时监测。

近年来, 多测量向量(Multiple Measurement Vectors, MMV)模型<sup>[16,17]</sup>压缩感知框架在多通道脑电信号压缩重构研究中受到广泛关注, 相继提出了一些基于 MMV 模型的多通道脑电信号压缩联合重构算法, 诸如 T-MSBL(Temporal-Sparse Bayesian Learning for MMV model)算法等<sup>[18]</sup>、基于时空稀疏贝叶斯学习(Spatio-Temporal Sparse Bayesian Learning, STSBL)模型的多测量向量压缩感知重构算法<sup>[19]</sup>等, 提高多通道脑电信号联合重构性能。然而, 目前相关研究大多采用基于正交变换的离散余弦变换(Discrete Cosine Transform, DCT)基近似稀疏表示多通道脑电信号, 未能充分考虑脑电信号非平稳性、非线性、随机性等特点, 难以准确稀疏表示多通道脑电信号时空特性, 影响多通道脑电信号压缩感知联合重构性能。如何准确稀疏表示多通道脑电信号, 提高其联合重构性能是目前相关研究探讨的热点问题。

目前相关研究尝试基于优化学习算法构建满足信号特征的非正交过完备字典, 准确稀疏表示时域非稀疏生理信号, 提高其压缩感知重构性能<sup>[20]</sup>。一些研究探讨了尝试采用 K-SVD 优化学习算法从相关生理信号(诸如, 体域网心电信号、语音信号、核磁共振图像等)获得过完备字典, 有效提高其压缩感知重构性能<sup>[21-23]</sup>。然而, 目前鲜有研究探讨基于过完备字典优化稀疏表示多通道脑电信号, 来准确刻画多通道脑电信号时空特性, 提高其压缩感知联合重构性能。

为此, 本文提出一种基于过完备字典优化稀疏表示的多通道脑电信号压缩感知联合重构方法, 尝试基于 K-SVD 优化学习算法构建蕴含多通道脑电

信号时空特性的最优过完备字典, 准确稀疏表示多通道脑电信号, 有效提高基于时空稀疏贝叶斯学习模型的多通道脑电信号压缩感知联合重构性能。研究选用 eegmmidb 数据库多通道脑电数据验证本文方法的有效性。

## 2 基于 MMV 模型的压缩感知方法

压缩感知理论依据数据稀疏性, 通过设计一个与稀疏基最大不相干的测量矩阵实现数据压缩和重构。通常采用 SMV 模型或 MMV 模型, 实现单信号或多信号的压缩和重构。实质上, MMV 模型是 SMV 模型压缩感知方法的推广, 旨在解决具有相同稀疏支撑集的多信号压缩和重构问题, 为多通道脑电数据压缩重构奠定理论基础。

SMV 模型假设信号  $\mathbf{x} \in \mathbb{R}^{N \times 1}$  时域稀疏表示为

$$\mathbf{x} = \sum_{i=1}^N \psi_i \alpha_i = \Psi \boldsymbol{\alpha} \quad (1)$$

式中,  $\Psi$  为稀疏基,  $\boldsymbol{\alpha} \in \mathbb{R}^{N \times 1}$  为信号  $\mathbf{x}$  的稀疏表示系数。信号  $\mathbf{x}$  稀疏性依赖于  $\boldsymbol{\alpha}$  中非零系数个数, 最多非零系数个数  $T$  表示为信号  $\mathbf{x}$  的稀疏度。该模型通过优化设计测量矩阵和简单线性投影法实现单信号压缩, 即

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

式中,  $\Phi \in \mathbb{R}^{M \times N}$  ( $M \ll N$ ) 为测量矩阵,  $\mathbf{y} \in \mathbb{R}^{M \times 1}$  为压缩数据。

SMV 模型基于数据稀疏性将数据重构问题转化为求解  $l_0$  范数极小化问题, 通过估计稀疏系数  $\hat{\boldsymbol{\alpha}}$  来重构原始信号  $\mathbf{x} \approx \hat{\mathbf{x}} = \Psi \hat{\boldsymbol{\alpha}}$ , 即

$$\hat{\boldsymbol{\alpha}} = \arg \min \|\boldsymbol{\alpha}\|_0, \text{ s.t. } \mathbf{y} = \Phi \Psi \boldsymbol{\alpha} \quad (3)$$

式中,  $\|\cdot\|_0$  为稀疏系数  $\boldsymbol{\alpha}$  的  $l_0$  范数,  $\|\cdot\|_0 \leq T$ 。

而 MMV 模型假设含有相同稀疏基  $\Psi$  表示的多个信号  $\mathbf{x}_j \in \mathbb{R}^{N \times 1}, j = 1, 2, \dots, J$  ( $J$  为信号个数) 表示为信号矩阵  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_J] \in \mathbb{R}^{N \times J}$ , MMV 模型压缩感知方法根据测量矩阵  $\Phi \in \mathbb{R}^{M \times N}$  ( $\text{rank}(\Phi) = M$ ) 和线性投影算法, 实现多信号同步压缩, 即

$$\mathbf{Y} = \Phi \mathbf{X} \quad (4)$$

式中,  $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J], \mathbf{y}_j \in \mathbb{R}^{M \times 1}, \mathbf{Y} \in \mathbb{R}^{M \times J}$  表示多个压缩信号。

同样, MMV 模型压缩感知联合重构问题可转化为求解  $l_0$  范数极小化问题, 通过求解稀疏系数矩阵  $\boldsymbol{\alpha}_M = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_J] \in \mathbb{R}^{N \times J}$ , 即

$$\hat{\boldsymbol{\alpha}}_M = \arg \min \|\boldsymbol{\alpha}_M\|_0, \text{ s.t. } \mathbf{Y} = \Phi \boldsymbol{\alpha}_M \quad (5)$$

实现多信号联合重构:

$$\hat{\mathbf{X}} = \Psi \hat{\boldsymbol{\alpha}}_M \quad (6)$$

但 MMV 模型不同于 SMV 模型可有效求解  $l_1$  范数极小化问题, 常采用凸优化算法、贪婪算法和考

考虑源信号时序结构的稀疏贝叶斯算法等进行求解。

若多信号  $\mathbf{X}$  时域非稀疏, 可采用字典矩阵  $\mathbf{D} \in \mathbb{R}^{N \times K}$  ( $N < K$ ) 变换方法近似稀疏表示信号  $\mathbf{X}$ , 即  $\mathbf{X} = \mathbf{D}\boldsymbol{\theta}_M$ ,  $\boldsymbol{\theta}_M \in \mathbb{R}^{K \times J}$ 。同样其联合重构可通过转化  $l_0$  范数极小化问题求解稀疏系数矩阵  $\boldsymbol{\theta}_M$ , 即

$$\hat{\boldsymbol{\theta}}_M = \arg \min \|\boldsymbol{\theta}_M\|_0, \text{ s.t. } \mathbf{Y} = \boldsymbol{\Phi}\mathbf{D}\boldsymbol{\theta}_M \quad (7)$$

从而实现多信号联合重构:

$$\hat{\mathbf{X}} = \mathbf{D}\hat{\boldsymbol{\theta}}_M \quad (8)$$

由上述可知, 字典矩阵  $\mathbf{D}$  能否准确稀疏表示信号, 影响多信号压缩感知联合重构算法性能。

### 3 基于过完备字典优化稀疏的多通道脑电信号压缩感知联合重构算法

为准确稀疏表示多通道脑电信号, 提高其压缩感知联合重构性能, 本文提出了一种基于过完备字典优化稀疏的多通道脑电信号压缩感知联合重构算法, 其算法流程如图 1 所示。首先基于 MMV 模型同步压缩原始采集多通道脑电信号  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_J]$ , 获得多通道压缩信号  $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J]$ ; 然后基于 K-SVD 优化学习算法从原始正交变换字典中获得准确稀疏表示多通道脑电信号的过完备字典, 准确揭示多通道脑电信号时空特性, 提高多通道脑电信号时空稀疏贝叶斯学习算法重构性能, 准确重构原始多通道脑电信号  $\hat{\mathbf{X}} = [\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_J]$ 。

#### 3.1 基于 K-SVD 优化学习算法的脑电信号过完备字典设计

实质上, K-SVD 算法<sup>[24]</sup>是一种 K 奇异值分解算法, 若将多信号中每一个信号仅用一个原子表示时, 可转化为 K 均值聚类算法。考虑到多通道脑电信号 MMV 模型在压缩感知框架中的联合稀疏性, 本研究将多脑电信号中的每个脑电信号仅用一个原子近似稀疏表示, 基于 K-SVD 优化学习算法设计一种从

多通道脑电信号中获取过完备字典的贪婪算法, 其优化训练学习的目标方程为

$$\min_{\mathbf{D}, \mathbf{Z}} \{\|\mathbf{S} - \mathbf{D}\mathbf{Z}\|_F^2\}, \text{ s.t. } \forall i, \|z_i\|_0 \leq T_0 \quad (9)$$

式中,  $\mathbf{S} = \{\mathbf{s}_i\}_{i=1}^n \in \mathbb{R}^{N \times n}$  为  $n$  个待稀疏表示的脑电信号集合,  $N$  为信号长度,  $\mathbf{D} \in \mathbb{R}^{N \times K}$  为 K-SVD 过完备字典,  $\mathbf{Z} = \{z_i\}_{i=1}^n \in \mathbb{R}^{K \times n}$  为  $\mathbf{S}$  的解向量集合,  $T_0$  为脑电信号稀疏表示系数  $\mathbf{Z}$  中非零元素个数的上限。其求解迭代思路主要是选用 MP, OMP 或 BP 等算法获取信号  $\mathbf{S}$  在初始字典  $\mathbf{D}$  上的稀疏系数矩阵  $\mathbf{Z}$ , 然后根据 K-SVD 算法训练迭代误差, 交替更新字典  $\mathbf{D}$ , 找到最优稀疏系数矩阵  $\mathbf{Z}$ , 构建最优过完备字典  $\mathbf{D}$ 。其具体算法步骤如下:

步骤 1 选取多通道脑电信号构造初始脑电信号字典  $\mathbf{D}$ , 待稀疏表示的脑电信号样本集合  $\mathbf{S} = \{\mathbf{s}_i\}_{i=1}^n$ 。

步骤 2 确定初始字典的原子长度  $N$  和数量  $K$ , 稀疏表示脑电信号所需最多原子个数  $L$ , K-SVD 算法的训练迭代误差  $\delta$  和样本集合  $\mathbf{S}$  的原子数  $n$ 。

步骤 3 依据初始字典原子长度  $N$ , 分割所选取脑电信号, 随机选取其中  $K$  个原子构成初始字典  $\mathbf{D}$ , 选取  $n$  个原子构成脑电信号样本集合  $\mathbf{S}$ , 然后采用 OMP 算法获得脑电信号初始字典下的稀疏系数矩阵  $\mathbf{Z}$ 。

步骤 4 根据 K-SVD 算法训练迭代误差  $\delta$ , 不断更新初始字典原子。若满足误差  $\delta$ , 即找到最优稀疏系数矩阵  $\mathbf{Z}$ , 从而构建符合多通道脑电信号时空特性的最优过完备字典  $\mathbf{D}$ 。

#### 3.2 基于时空稀疏贝叶斯学习模型的多通道脑电信号压缩感知联合重构算法

为充分利用多通道脑电信号时空相关性, 本文




图 1 基于过完备优化稀疏的多通道脑电信号压缩感知联合重构算法框图

提出基于 STSBL 模型构建多通道脑电信号压缩感知联合重构算法,其基本思路是将基于时空稀疏贝叶斯学习模型的多通道脑电信号压缩感知重构框架假设为多个单通道脑电信号 BSBL 框架集合,有效利用单通道脑电信号内在时间相关性和多通道脑电信号间的空间相关性,提高多通道脑电信号压缩感知联合重构性能。

假设原始多通道脑电信号  $\mathbf{X} \in \mathbb{R}^{N \times J}$  ( $N$  为每一通道信号长度,  $J$  为多通道个数), 矩阵  $\mathbf{X}$  中的每一列向量  $\mathbf{X}_{:,i} \in \mathbb{R}^{N \times 1}$  ( $i \in \{1, 2, \dots, J\}$ ) 表示单通道信号。基于过完备字典  $\mathbf{D}$  和 MMV 模型压缩感知算法, 可将原始多通道脑电信号  $\mathbf{X} \in \mathbb{R}^{N \times J}$  压缩为

$$\mathbf{Y} = \Phi \mathbf{X} + \mathbf{V} = \Phi \mathbf{D} \Theta + \mathbf{V} = \Omega \Theta + \mathbf{V} \quad (10)$$

式中,  $\mathbf{Y} \in \mathbb{R}^{M \times J}$  为压缩信号矩阵,  $\Omega = \Phi \mathbf{D} \in \mathbb{R}^{M \times K}$  为传感矩阵,  $\mathbf{V} \in \mathbb{R}^{M \times J}$  为噪声矩阵,  $\Theta \in \mathbb{R}^{N \times J}$  为多通道脑电信号联合重构稀疏系数矩阵。

准确求解稀疏系数  $\Theta$  是重构恢复原始信号  $\mathbf{X}$  的关键环节, 本文基于 STSBL 模型求解多通道脑电信号联合重构稀疏系数矩阵  $\Theta$ , 首先假设信号  $\mathbf{X}$  可划分为式(11)所示块结构:

$$\mathbf{X} = [\mathbf{X}_{[1]}, \mathbf{X}_{[2]}, \dots, \mathbf{X}_{[h]}]^T \quad (11)$$

式中,  $\mathbf{X}_{[i]} \in \mathbb{R}^{d_i \times J}$  为  $\mathbf{X}$  的第  $i$  块,  $N = \sum_{i=1}^h d_i$ ,  $d$  为块内元素值,  $h$  为划分块数。

由式(10)和式(11)可知, 可假设联合重构稀疏系数  $\Theta$  与  $\mathbf{X}$  具有相同块结构:

$$\Theta = [\Theta_{[1]}, \Theta_{[2]}, \dots, \Theta_{[h]}]^T \quad (12)$$

式中,  $\Theta_{[i]} \in \mathbb{R}^{d_i \times J}$  为  $\Theta$  的第  $i$  块稀疏系数。联合稀疏系数块  $\Theta_{[i]}$  保持同样时空相关性, 即  $\Theta_{[i]}$  每列元素保持时间相关性, 且每行元素保持空间相关性。假设稀疏系数块  $\Theta_{[i]}$  满足式(13)所示多参数高斯分布:

$$p(\text{vec}(\Theta_{[i]}^T); \gamma_i, \mathbf{B}, \mathbf{A}_i) = N(0, (\gamma_i \mathbf{A}_i) \otimes \mathbf{B}) \quad (13)$$

式中,  $\mathbf{B} \in \mathbb{R}^{J \times J}$  为一未知正定矩阵, 用于捕捉  $\Theta_{[i]}$  中每行元素间的空间相关性;  $\mathbf{A}_i \in \mathbb{R}^{d_i \times d_i}$  为一未知正定矩阵, 用于捕捉  $\Theta_{[i]}$  中每列元素间的时间相关性;  $\gamma_i$  为一未知非负参数, 用于控制  $\Theta_{[i]}$  稀疏性, 若  $\gamma_i = 0$  时, 相对应块内元素值均为零。通过优化学习控制  $\gamma_i$  趋近于 0, 能有效提高解向量块稀疏性。

此外, 假设稀疏系数块  $\Theta_{[i]}$  间保持相互独立, 则  $\Theta$  需满足式(14)所示分布:

$$p(\text{vec}(\Theta^T); \mathbf{B}, \{\gamma_i \mathbf{A}_i\}_i) = N(0, \mathbf{\Pi} \otimes \mathbf{B}) \quad (14)$$

式中,  $\mathbf{\Pi}$  被定义为一个以  $\gamma_i \mathbf{A}_i$  为对角线上元素的块对角矩阵。噪声矩阵  $\mathbf{V}$  满足式(15)所示分布:

$$p(\text{vec}(\mathbf{V}^T); \lambda, \mathbf{B}) = N(0, \lambda \mathbf{I} \otimes \mathbf{B}) \quad (15)$$

为快速求解  $\mathbf{A}, \mathbf{B}, \lambda$  等参数, 本文采用一种分别将矩阵  $\mathbf{B}$  和  $\mathbf{A}_i$  处理为空间和时间白化模型矩阵的交替学习算法(alternating-learning approach), 也就是通过空间白化模型来估计参数  $\{\gamma_i, \mathbf{A}_i\}_{i=1}^h$ , 通过时间白化模型来估计参数  $\mathbf{B}$ ; 在优化学习过程中, 将上述时间-空间白化模型相互交替学习, 直到学习算法收敛, 估计出  $\mathbf{A}, \mathbf{B}, \lambda$  等最优参数, 其优化算法详细求解过程详见文献[19]。

### 3.3 基于过完备字典优化稀疏表示的多通道脑电信号压缩感知联合重构算法实现步骤

步骤 1 从 eegmmidb 脑电数据库中提取多通道脑电信号, 其中一部分用于获取多通道脑电信号过完备字典  $\mathbf{D}$ , 另一部分用于 MMV 模型压缩感知框架压缩重构多通道脑电信号。

步骤 2 选用稀疏二进制矩阵作为测量矩阵  $\Phi$ , 根据式(4)压缩原始多通道脑电信号矩阵  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_J]$ , 可得到多通道脑电信号压缩信号矩阵  $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J]$ 。

步骤 3 选用 DCT 正交基构造多通道脑电信号初始字典  $\mathbf{D}$ , 从脑电数据库提取数据构建训练样本集合  $\mathbf{S}$ , 基于 K-SVD 优化学习训练规则和 OMP 算法, 获得多通道脑电信号过完备字典  $\mathbf{D}$ 。

步骤 4 根据式(10)基于 STSBL 模型压缩感知重构算法获得多通道脑电信号联合稀疏系数  $\Theta$ , 准确重构多通道脑电信号  $\hat{\mathbf{X}} = \mathbf{D}\Theta$ 。

## 4 实验与讨论

### 4.1 多通道脑电信号数据

选用 eegmmidb 脑电信号数据库 ([www.physionet.org/physiobank/database/eegmmidb/](http://www.physionet.org/physiobank/database/eegmmidb/))<sup>[25]</sup> 的多通道脑电信号验证本文算法有效性。eegmmidb 脑电数据库基于 BCI2000 系统(采样频率 160 Hz, 采集时间 3 min), 采集了 109 名受试者分别在睁眼、闭眼、视觉诱发、动作想象等 14 个不同动作状态的 64 通道脑电信号数据。eegmmidb 脑电数据库分别用编号 1, 2 表示睁眼、闭眼两种状态脑电数据集, 用编号 3, 4, 7, 8, 11, 12 表示向左或向右方向状态脑电数据集; 用编号 5, 6, 9, 10, 13, 14 表示向上或向下方向状态脑电数据集。本文实验选用睁眼、闭眼状态下的多通道脑电信号数据集验证本文算法有效性。

### 4.2 算法性能评价

选用压缩率和信噪比客观评价本文所提算法重构性能, 其定义如下:

(1) 压缩率(Compression Rate, CR): 压缩率旨在客观评价本文所提算法在多通道脑电信号高压缩

比状况下的压缩感知联合重构性能, 其定义为

$$CR = \frac{N - M}{N} \times 100\% \quad (16)$$

式中,  $N$  为原始脑电数据长度,  $M$  为压缩脑电数据长度。

(2)信噪比(Signal to Noise Ratio, SNR): 信噪比旨在量化评价原始脑电信号与联合重构脑电信号的差异, 其定义为

$$SNR = 20 \lg \frac{\|\mathbf{X}\|_2^2}{\|\mathbf{X} - \hat{\mathbf{X}}\|_2^2} \quad (17)$$

式中,  $\mathbf{X}$  为原始多通道脑电数据,  $\hat{\mathbf{X}}$  为联合重构脑电数据。信噪比越大, 信号重构误差越小, 重构性能越优。

### 4.3 实验结果与分析

实验首先选用受试者第 1~60 通道脑电数据构建训练样本集合  $\mathbf{S}$  和初始离散余弦变换字典  $\mathbf{D}$ , 并基于 K-SVD 算法进行优化学习, 获取过完备离散余弦变换字典, 训练过程相关参数设置如下: 初始字典长度和原子个数分别选取为 160 和 300; 样本集合原子个数为 600, 待分解信号稀疏表示时最多使用的原子个数为 40, 算法迭代次数为 30。采用相同受试者第 61~64 通道脑电数据来评估本文算法重构性能。实验中, 选用稀疏二进制矩阵作为测量矩阵(每列包含 2 个非 0 元素), 采用 STSBL 期望最大化(STSBL-EM)算法作为多通道脑电信号联合重构算法。为了进行比较, 选用 BP, BSBL-BO 算法作为单通道脑电信号重构算法, STSBL-EM, BSBL-BO 两种重构算法中的块长度设为 20。上述实验均在台式 PC 机(3.2 GHz Intel Core i5 CPU, 4.0 GB RAM)和 MATLAB R2013a 中实现。

图 2 给出了在不同压缩率状况下, 分别基于初始离散余弦字典和过完备字典的多通道脑电信号联合重构性能比较结果。从图 2 可知, 基于过完备离散余弦字典的 3 种重构算法性能均明显优于基于初始离散余弦字典的重构算法性能, 相比较而言, 本文所提重构算法(即 KSVD STSBL-EM)性能最优, BSBL-BO 算法性能次之, 表明本文算法能够比 BSBL-BO 算法提供更多的脑电信号时空相关性信息, 提高多通道脑电信号压缩感知联合重构性能。当压缩率小于 75% 时, 基于 DCT 稀疏基的 STSBL-EM 算法重构性能优于基于 KSVD 过完备字典的 BP 算法重构性能, 这可能是由于 BP 算法未能有效捕获多通道脑电信号时空相关性信息, 难以提高多通道脑电信号联合重构性能。此外, 当压缩率大于 80% 时, 各种重构算法得到的信噪比值急剧下降, 这可能由于较高压缩率破坏了多通道脑电信号压缩




图 2 基于不同离散余弦字典的多通道脑电信号联合重构算法性能比较

感知中稀疏基与测量矩阵之间最大非相干性, 导致重构算法性能恶化。表 1 给出了采用本文所提重构算法在压缩率为 75% 时的第 61~64 通道脑电信号重构结果。从表 1 可以看到, 对于每一通道脑电信号, 基于过完备离散余弦字典的重构算法性能均明显优于基于初始离散余弦字典重构算法性能。图 3 给出了第 64 通道脑电信号基于初始离散余弦字典和过完备离散余弦字典的重构结果, 直观显示单个通道脑电信号基于不同离散余弦字典重构算法性能差异。结果表明, 训练得到的 KSVD 过完备字典能够准确稀疏表示多通道脑电信号, 为 STSBL-EM 算法提供更多满足多通道脑电信号电生理活动时空特征信息, 弥补了 BP 算法和 BSBL-BO 重构算法仅能利用多通道脑电信号局部特征信息的局限, 有效提高 MMV 模型多通道脑电信号压缩感知框架在高压压缩率状况下的联合重构算法性能。

表 1 基于不同离散余弦字典的每一通道脑电信号重构的 SNR(dB)

算法	通道号	基于初始离散余弦字典的 SNR	基于过完备离散余弦字典的 SNR
STSBL-EM	61	16.3241	22.5054
STSBL-EM	62	11.6938	18.7442
STSBL-EM	63	11.5981	14.4952
STSBL-EM	64	9.2829	12.5341

此外, 实验评估了多通道脑电信号通道数对本文所提多通道脑电信号联合重构算法性能的影响。实验中, 分别选取多通道脑电信号通道数为 1, 2, 4, 8, 16, 不同通道数在压缩率变化情况下的联合重构性能, 实验结果如图 4 所示。从图 4 可以看到, 本文所提重构算法获得的信噪比值随着通道数量的增加而增加, 当通道个数达到一定数目时, 重构算法所获得的信噪比值趋于保持一致状态, 明显高于单通道所获得的信噪比, 但不同通道数所获得的信噪比值均随着压缩率增大而降低。当压缩率保持在 50%~60% 时, 通道数为 4, 8, 16 的信噪比值保持在




图 3 基于不同离散余弦字典的脑电信号重构算法结果

20~23 dB, 明显大于通道数为 1 时的信噪比值(仅为 10~15 dB); 当压缩率大于 70%时, 来自不同通道数的信噪比值急剧下降。结果表明, 本文所提重构算法在保持高压缩率状况下, 能够捕获多通道脑电信号时空相关性信息, 改善多通道脑电信号联合重构性能。

为进一步验证本文算法在实际应用中的有效性, 实验评估了 3 种重构算法 BP, BSBL-BO 和 STSBL-EM 在不同脑电信号通道数和压缩率状况下的运行时间对比, 实验结果如图 5 所示。如图 5 所示, 3 种重构算法运行时间均随脑电信号通道数的增大而增大, 但随压缩率增大呈现稍微下降趋势。相比较而言, 随着脑电信号通道数增大, 本文所提重构算法运行时间保持较稳定, 平均时间仅为 0.05 s。而 BP, BSBL-BO 重构算法均明显高于本文所提算法运行时间, 特别是, BSBL-BO 重构算法运行时间随着脑电信号通道数的增加而显著增大, 从平均 0.45 s 上升至 0.65 s, 明显高于本文所提重构算法运行时间。这主要是由于当通道数量小于信号测量维

数时, STSBL-EM 算法总体计算复杂度仅为  $O(M^3 + 2M^2N)$ , 有效降低算法运行时间。BP 算法和 BSBL-BO 算法虽然在单通道脑电信号重构时的计算复杂度仅为  $O(M^3)$ ,  $O(M^3 + 2M^2N)$ , 但当重构  $J$  个多通道脑电信号时, 两种算法均仅能逐个通道依次重构, 总体算法复杂度将随脑电信号通道数量倍数增加, 即  $J \times O(M^3)$  与  $J \times O(M^3 + 2M^2N)$ 。结果表明, 本文算法能够以较低的计算复杂度和稳健的运算速度联合重构多通道脑电信号, 有望为体域网多通道脑电信号远程监测数据分析与评估需求提供一个新的技术手段。

### 5 结论

本文提出了一种基于过完备字典优化稀疏表示的多通道脑电信号压缩感知联合重构算法, 该算法基于 K-SVD 优化学习算法构建多通道脑电数据过完备离散余弦字典, 准确稀疏表示多通道脑电信号电生理时空特性, 为时空稀疏贝叶斯学习模型提供准确的多通道脑电信号时空特性信息, 有效提高多




图 4 基于不同压缩率和通道数对多通道脑电信号联合重构影响结果

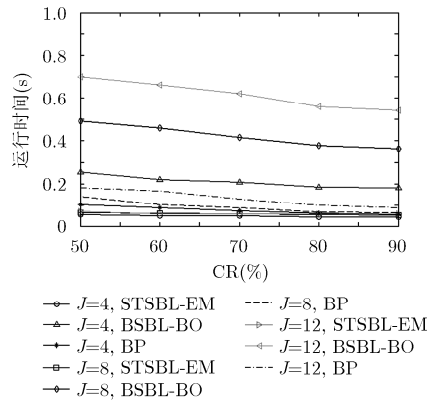


图 5 不同重构算法在不同脑电信号通道数和压缩率状况下的运行时间对比结果

通道脑电信号在高压缩率状况下的压缩感知联合重构算法性能, 具有联合重构精度高、运行时间短等优点, 有望为构建低功耗体域网脑电远程监测系统提供新的思路和方案。

### 参考文献

- [1] WESTOVER M B, SHAFI M, BIANCHI M T, *et al.* The probability of seizures during EEG monitoring in critically ill adults[J]. *Clinical Neurophysiology Official Journal of the International Federation of Clinical Neurophysiology*, 2015, 126(3): 463-471. doi: 10.1016/J.clinph.2014.05.037.
- [2] KIM Y and LEE S K. Energy-efficient wireless hospital sensor networking for remote patient monitoring[J]. *Information Sciences*, 2014, 282: 332-349. doi: 10.1016/j.ins.2014.05.056.
- [3] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306. doi: 10.1109/TIT.2006.871582.
- [4] FAUVEL S and WARD R K. An energy efficient compressed sensing framework for the compression of Electroencephalogram signals[J]. *Sensors*, 2014, 14(1): 1474-1496. doi: 10.3390/s140101474.
- [5] LIU B, ZHANG Z, XU G, *et al.* Energy efficient telemonitoring of physiological signals via compressed sensing: a fast algorithm and power consumption evaluation[J]. *IEEE Transactions on Biomedical Signal Processing and Control*, 2013, 11(1): 80-88. doi: 10.1016/j.bspc.2014.02.010.
- [6] CLIFTON L, CLIFTON D A, PIMENTEL M A, *et al.* Predictive monitoring of mobile patients by combining clinical observations with data from wearable sensor[J]. *IEEE Journal of Biomedical and Health Informatics*, 2014, 18(3): 722-730. doi: 10.1109/JBHI.2013.2293059.
- [7] ZHANG Z, JUNG T P, 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. doi: 10.1109/TBME.2012.2217959.
- [8] DAI Y, WANG X, LI X, *et al.* Sparse EEG compressive sensing for web-enabled person identification[J]. *Measurement*, 2015, 74: 11-20. doi: 10.1016/j.measurement.2015.07.008.
- [9] BARANIUK R G, CEVHER V, DUARTE M F, *et al.* Model-based compressive sensing[J]. *IEEE Transactions on Information Theory*, 2010, 56(4): 1982-2001. doi: 10.1109/TIT.2010.2040894.
- [10] TROPP J A and GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666. doi: 10.1109/TIT.2007.909108.
- [11] DAI W and MILENKOVIC O. Subspace pursuit for compressive sensing signal reconstruction[J]. *IEEE Transactions on Information Theory*, 2009, 55(5): 2230-2249. doi: 10.1109/TIT.2009.2016006.
- [12] MOHIMANI H, BABAIE-ZADEH M, and JUTTEN C. A fast approach for overcomplete sparse decomposition based on smoothed  $l_0$  norm[J]. *IEEE Transactions on Signal Processing*. 2009, 57(1): 289-301. doi: 10.1109/TSP.2008.2007606.
- [13] ZHANG Z, JUNG T P, 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. doi: 10.1109/TBME.2012.2226175.
- [14] 孙洪, 张智林, 余磊. 从稀疏到结构化稀疏: 贝叶斯方法[J]. *信号处理*, 2012, 28(6): 759-773. doi: 10.16798/j.issn.1003-0530.2016.02.005.  
SUN Hong, ZHANG Zhilin, and YU Lei. From sparsity to structured sparsity: Bayesian perspective[J]. *Signal Processing*, 2012, 28(6): 759-773. doi: 10.16798/j.issn.1003-0530.2016.02.005.
- [15] ZHANG Z and RAO B D. Extension of SBL algorithms for the recovery of block sparse signals with intra-block correlation[J]. *IEEE Transactions on Signal Processing*, 2013, 61(8): 2009-2015. doi: 10.1109/TSP.2013.2241055.
- [16] COTTER S F, RAO B D, ENGAN K, *et al.* Sparse solutions to linear inverse problems with multiple measurement vectors [J]. *IEEE Transactions on Signal Processing*, 2005, 53(7): 2477-2488. doi: 10.1109/TSP.2005.849172.
- [17] ELDAR Y C and RAUHUT H. Average case analysis of multichannel sparse recovery using convex relaxation[J]. *IEEE Transactions on Information Theory*, 2010, 56(1): 505-519. doi: 10.1109/TIT.2009.2034789.
- [18] ZHANG Z and RAO B D. 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. doi: 10.1109/JSTSP.2011.2159773.
- [19] ZHANG Z, JUNG T P, and MAKEIG S. Spatiotemporal sparse Bayesian learning with applications to compressed sensing of multichannel physiological signals[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 22(6): 1186-1197. doi: 10.1109/TNSRE.2014.2319334.
- [20] LEE S J, LUAN J, and CHOU P H. ECG signal reconstruction from undersampled measurement using a trained overcomplete dictionary[J]. *Contemporary Engineering Science*, 2014, 7(29): 1625-1632. doi: http://dx.doi.org/10.12988/ces.2014.41121.

- [21] 彭向东, 张华, 刘继忠. 基于过完备字典的体域网压缩感知心电图重构[J]. 自动化学报, 2014, 40(7): 1421-1432. doi: 10.3724/SP.J.1004.2014.01421.  
PENG Xiangdong, ZHANG Hua, and LIU Jizhong. ECG reconstruction of body sensor network using compressed sensing based on overcomplete dictionary[J]. *Acta Automatica Sinica*, 2014, 40(7): 1421-1432. doi: 10.3724/SP.J.1004.2014.01421.
- [22] 孙林慧, 杨震, 季云云, 等. 基于过完备线性预测字典的压缩感知语音重构[J]. 仪器仪表学报, 2012, 33(4): 743-749. doi: 10.3969/j.issn.0254-3087.2012.04.004.  
SUN Linhui, YANG Zhen, JI Yunyun, *et al.* Reconstruction of compressed speech sensing based on overcomplete linear prediction dictionary[J]. *Chinese Journal of Scientific Instrument*, 2012, 33(4): 743-749. doi: 10.3969/j.issn.0254-3087.2012.04.004.
- [23] DONEVA M, BORNERT P, EGGERS H, *et al.* Compressed sensing reconstruction for magnetic resonance parameter mapping[J]. *Magnetic Resonance in Medicine*, 2010, 64(4): 1114-1120. doi: 10.1002/mrm.22483.
- [24] AHARON M, ELAD M, and BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322. doi: 10.1109/TSP.2006.881199.
- [25] SCHALLK G, MCFARLAND D J, HINTERBERGER T, *et al.* BCI2000: a general-purpose Brain-Computer Interface (BCI) system[J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51(6): 1034-1043. doi: 10.1109/TBME.2004.827072.
- 吴建宁: 男, 1969年生, 副教授, 研究方向为生物医学信号处理、无线传感网与医学应用.
- 徐海东: 男, 1991年生, 硕士生, 研究方向为无线传感网技术及其应用.
- 王 珏: 女, 1955年生, 教授, 研究方向为脑功能障碍发病机制、干预策略和方法、脑-机接口技术及康复诊疗设备、远程康复技术等.