

# 基于 DIVA 模型的脑电信号去噪方法研究

张少白<sup>1</sup>, 王 勇<sup>1</sup>, 刘友谊<sup>2</sup>

(1.南京邮电大学计算机学院,江苏南京 210003;2.北京师范大学认知神经科学与学习国家重点实验室,北京 100875)

**摘 要:** 脑电信号获取过程中,工频噪声干扰现象往往会使所获取的信息产生多种多形态瞬时结构波形,这种现象影响到 DIVA(Directions Into Velocities of Articulators)模型对语音的正常处理.为此,本文提出了一种面向特征提取的脑电信号结构自适应稀疏分解模型,并在此基础上,通过采用匹配追踪算法求解最佳原子、使用过完备原子库中原子表示原始脑电信号等方法,实现了信号去噪的目的,效果好于传统的小波变换去噪方法.仿真实验表明,本文提出的方法提高了 DIVA 模型语音发音的精度.

**关键词:** DIVA 模型; 脑电信号; 噪声; 稀疏分解

**中图分类号:** TP183

**文献标识码:** A

**文章编号:** 0372-2112 (2015)04-700-08

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2015.04.011

## Research on the Method of EEG Signal Denoising Based on the DIVA Model

ZHANG Shao-bai<sup>1</sup>, WANG Yong<sup>1</sup>, LIU You-yi<sup>2</sup>

(1. Computer Department, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China;

2. State Key Laboratory for Cognitive Neuroscience and Learning, Beijing Normal University, Beijing 100875, China)

**Abstract:** There are power frequency interference and other kinds of noise in the electro encephalo gram (EEG) signal acquisition process. They make the signal show non-stationary and a variety of multi-form waveform in the instantaneous structure. Then such signal will affect the normal processing of the speech in DIVA(Directions Into Velocities of Articulators) model. Therefore, this paper proposes an adaptive sparse decomposition model for the feature extraction of EEG signal structure and makes use of Matching Pursuit algorithm to solve the optimal atom. Then the original EEG signal can be represented by atoms in the complete atomic library. Finally, this model removes noise that exists in the EEG signal and is compared with wavelet transform method. Simulation results show that after we put the denoising EEG signal into the model, the phonetic pronunciation improves.

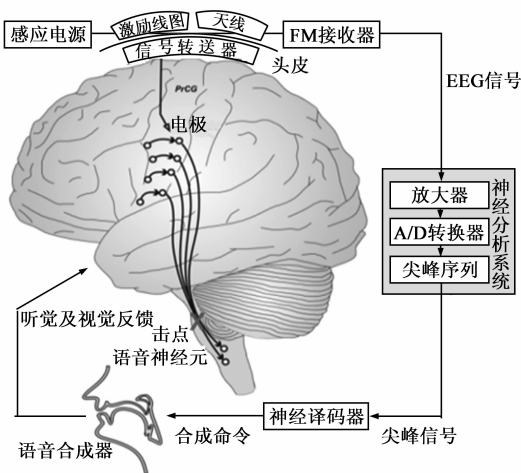
**Key words:** directions into velocities of articulators (DIVA) model; electro encephalo gram (EEG) signal; noise; sparse decomposition

## 1 引言

在神经解剖学和神经心理学层次上仿真和描述大脑中涉及语音生成和理解区域的相关功能,涉及到语音学、控制科学、机器人学以及神经生理学等多个学科.作为近年来人工语音合成系统的主要研究领域,许多学者对语音生成和获取的计算模型进行了深入研究,并取得了丰硕成果.其中,最具有代表性的是由波士顿大学语音实验室冈瑟教授(Frank H Guenther)带领的研究小组研制出的一种称之为“神经分析系统(Neuralynx System)”的仪器<sup>[1]</sup>.这种仪器让使用者只需要简单的想一想自己所希望表达的内容,语音合成系统就能将其直接转换成语音,其原理如图1所示.

图1中,黑圈和箭头分别表示神经元和轴突,主要用于语音运动输出.信号从植入到试验者语音运动皮层的电极中收集放大,并通过FM无线信号予以发送.之后,该信号被传输到电生理学记录系统中进行模/数转换和神经元尖峰电位分类(spike sorting).最后由系统将分类后的神经元峰值送到神经解码器并转换成语音合成系统的相关命令.此时,系统就可以将音频信号反馈到实时对象之中了(图中“PrCG”表示脑组织中的中央前回).

该神经分析系统由两部分组成:“脑—计算机”接口(BCI, Brain computer interface)和语音合成系统DIVA(Directions Into Velocities of Articulators)模型.其中,BCI是一种通过脑电信号来实现人脑与计算机或其他电子设备

图1 实时语音生成合成系统脑--机接口原理图<sup>[1]</sup>

进行通讯的系统.该系统通过将无线神经电极<sup>[1,2]</sup>长期植入患者大脑皮层的方式来产生脑电信号,进而驱动语音合成器的连续“运动”,为患者提供实时的语音输出;DIVA模型则是一种具有生物学意义的关于语音生成和获取的神经网络<sup>[3]</sup>,其目的就是通过学习控制模拟声道的运动来生成音素(Phoneme)串.

作为 DIVA 模型输入信号的脑电信号,其采集过程需要经过信号调理、采样、量化、编码、传输等步骤.在这个过程中,脑电信号具有非平稳性,极易受到各种噪声干扰,特别是工频干扰.如果把这样的脑电信号输入到 DIVA 模型中,势必会影响到模型对语音的正常处理.因此有必要消除原始脑电数据中的噪声.

目前,脑电信号的去噪方法主要有陷波滤波器、自适应滤波器、小波变换等.陷波滤波器方法参数与信号的采样频率直接相关,当频率发生改变时,其陷波滤波器参数也相应改变,从而易造成脑电波形失真<sup>[4]</sup>.自适应滤波器能够自动跟踪工频干扰的频率变化且能最大限度地减少有用信息的损失,但是其频率跟踪范围很窄<sup>[5]</sup>.上述所说的方法都是在傅里叶变换的基础之上提出来的,而应用最为广泛的小波变换也存在一定的缺陷,例如计算过程较为复杂,小波基的选择、小波阈值的设定都需要一定的先验知识等<sup>[6]</sup>.

Mallat 等于 1993 年提出了基于过完备原子库(over-complete dictionary)的稀疏分解(Sparse decomposition)思想<sup>[7]</sup>.这种方法能够根据信号自身特点,自适应地选择合适的基函数,从而完成信号的分解.在此过程中,过完备原子库起着决定性的作用.沿着这样一种思路,本文通过对脑电信号本身结构特点进行分析,提出了一种专门适用于脑电信号结构的过完备原子库构建方法,并采用匹配追踪算法<sup>[7,8]</sup>(MP, Matching Pursuit)对信号进行稀疏分解再重构.经过这样一个过程,脑电信号的稀疏性被增强,从而达到去噪目的,提高了 DIVA 模

型语音处理的能力.

## 2 DIVA 模型

DIVA 模型是一种自适应神经网络模型,可以用来描述语音获取与生成的相关处理过程,并通过模拟声道的控制来生成语音<sup>[9,10]</sup>.模型主要依据有关语音生成及感知心理物理学实验的行为数据、fMRI (functional magnetic resonance imaging) 和 PET (Positron Emission computed Tomography) 实验的神经成像数据以及对动物所做的运动控制实验的神经生理学数据等而建立,其原理如图 2 所示<sup>[3]</sup>.

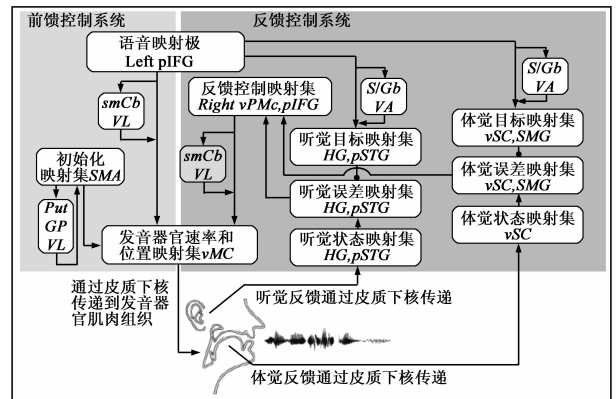


图2 DIVA模型工作流程图

由图 2 可以看到,模型由前馈控制子系统、反馈控制子系统以及前田(Maeda)模拟声道所组成.图中,每个方框代表构成某一神经表述的神经元集合.方框中英文缩写代表集合所对应的大脑皮层区域<sup>[3]</sup>;箭头则表示一种神经元表述到另一种表述之间的映射(变换),而且这种映射被假定是某一集合中所选中的细胞活跃度(activation)通过突触映射到另一集合的过程.突触权值是在模型中两个阶段之一的呀呀学语阶段所获得的.发音器官的随机运动提供触觉、本体感受(proprioceptive)以及听觉反馈信号,并通过这些信号学习不同神经元表述之间的相互关系.

训练中,模型通过某种规则在以语音作为输入的同时,产生一个发音速度以及器官位置变化的时变序列.应用这个序列,系统就可以得到所需要的理想发音.前馈控制系统负责语音生成过程,反馈控制系统负责语音学习过程.前馈控制系统中,音素或音节的产生始于与生成的音素或音节相对应的语音映射集细胞的激活,每一个语音映射细胞对应于一个唯一的音素或音节.

冈瑟教授曾对 DIVA 模型中各个组件所对应的神经解剖学映射关系进行过详细描述,并对这些映射位置进行了严格的实验论证<sup>[11]</sup>.如图 3 所示, DIVA 模型中的各个组件在应用统计参数图(Statistical Parametric

Mapping, SPM)所描述的大脑外表面所对应的位置上被一一确定. 其中 IM 表示启动映射集, Resp 表示呼吸运动细胞集,  $\dot{M}$  表示发音器官速率映射集,  $M$  表示发音器官位置映射集,  $S$  表示体觉状态映射集,  $T_s$  表示体觉目标映射集,  $\Delta S$  表示体觉误差映射集,  $T_{Au}$  表示听觉目标映射集,  $\Delta Au$  表示听觉误差映射集,  $Au$  表示听觉状态映射集,  $SSM$  表示语音映射集,  $Lat Cbm$  表示外侧小脑,  $FBM$  表示反馈控制映射集.




图3 DIVA模型的神经解剖学映射关系示意图

DIVA 模型与 fMRI 之间的联系非常紧密<sup>[12]</sup>. 由 DIVA 模型所设定的各种假设可以应用 fMRI 相应的实验来加以测试和论证; 由 fMRI 所获得的数据也可以由 DIVA 模型加以分析和解释. 这样, DIVA 模型实际上就构成了一个用以解释来自各种研究的相关数据以及对关于语音神经处理过程进行一致性描述的基本框架.

### 3 信号稀疏分解

信号稀疏分解的基本思想是: 将信号在过完备库上进行分解, 分解时用来表示信号的基函数可以自适应的根据信号结构特点灵活选取, 而将信号进行分解后得到的相关系数中只有少数值不为零, 此即稀疏表示, 这个过程就称为稀疏分解. 信号稀疏分解已经被成功应用于信号处理的多个方面, 如信号检测、信号识别、图像去噪. 至今已经发展了多种稀疏分解算法. 常用的稀疏分解算法有匹配追踪 (Matching pursuit, MP) 算法<sup>[7,8]</sup>、基追踪 (Basis Pursuit, BP) 算法<sup>[8]</sup>、BOB (Basis Orthogonal Best) 算法<sup>[13]</sup>、正交匹配追踪算法<sup>[14]</sup> (orthogonal matching pursuit, OMP). BP 算法, 尤其 MP 算法是目前最常用的两种算法.

#### 3.1 MP 算法

匹配追踪算法 (简称 MP 算法) 是 Mallet 和 Zhang 在前人研究的基础上于 1993 年提出的一种信号分析方法, 它是一种贪婪算法. 贪婪算法是一种可以使求最优解问题变得更简单、更迅速的技术, 非常适用于求解稀疏分解问题.

其基本思想是在信号分解的库 (即过完备原子库) 中选取相关系数最大的分量, 通过多次迭代分解, 得到信号的稀疏表示<sup>[15,16]</sup>. 其实现过程可描述如下:

首先选定一个过完备原子库, 用  $D = \{g_r, r = 1, 2, \dots, M\}$  这样一个集合表示, 集合中的元素称为原子, 每个原子都能够充分代表信号的特点. 同时各原子之间保持了过完备特性. 所谓过完备性, 就是不同原子间的内积  $\langle g_i, g_j \rangle \neq 0$ , 其中  $i \neq j$ .

在 MP 算法中, 以信号  $f$  和过完备原子库中原子的内积最大作为贪婪算法的最优化原则<sup>[7]</sup>.

首先从完备库  $D$  中选出最佳原子  $g_i$ , 需要满足以下条件

$$|\langle f, g_i \rangle| = \sup_{j \in M} |\langle f, g_j \rangle| \quad (1)$$

其中,  $|\langle f, g_i \rangle|$  是信号  $f$  和原子  $g_i$  的内积.

选出  $g_i$  后, 信号  $f$  就被分解为

$$f = \langle f, g_i \rangle g_i + R^1 f \quad (2)$$

其中  $\langle f, g_i \rangle$  是信号  $f$  在原子  $g_i$  上投影后得到的值, 而  $R^1 f$  是信号  $f$  在  $g_i$  上投影后的剩余值, 我们可以称其为残差量.

然后从初始的过完备原子库中删除原子  $g_i$ . 在后面的查找匹配原子的过程中, 不会使用到它, 如此就减少了计算量. 接着, 再对信号  $f$  的残差量进行分解, 在修改后的过完备原子库中再次寻找最佳原子, 用公式可表示为

$$R^1 f = \langle R^1 f, g_k \rangle g_k + R^2 f \quad (3)$$

当然, 此时的  $g_k$  作为最佳原子, 仍然需要满足

$$|\langle R^1 f, g_k \rangle| = \sup_{j \in M} |\langle R^1 f, g_j \rangle| \quad (4)$$

按照这种方式进行迭代处理后, 信号  $f$  可被分解为:

$$f = \sum_{l=0}^{L-1} \langle R^l f, g_l \rangle g_l + R^L f \quad (5)$$

由于 Mallet 已经证明了,  $\|R^L f\|$  的值会随着  $L$  的增大呈指数级收敛. 因此, 信号  $f$  可被近似分解为:

$$f = \sum_{l=0}^{L-1} \langle R^l f, g_l \rangle g_l \quad (6)$$

以上步骤见图 4.

#### 3.2 过完备原子库的构造

匹配追踪算法是将信号在过完备库中进行分解, 因此过完备库的构造是整个稀疏分解的关键. 过完备库的构造非常灵活, 不同的分析对象和处理目的对应不同的过完备库<sup>[17]</sup>, 在实际应用中应该依据需求进行构造.

本文计划根据 EEG 信号特有的内在结构, 构造出专门适用于 EEG 信号的过完备原子库.

前文已经述及在采集脑电信号的过程中, 往往会受到工频干扰等噪声的干扰. 而这种干扰使得 EEG 信号表现出非平稳性, 且具有多种多形态瞬时结构波形. 因此, 单一结构类型的原子并不能有效匹配 EEG 信号中的多种瞬时波形. 为了有效匹配多种瞬时结构波形,

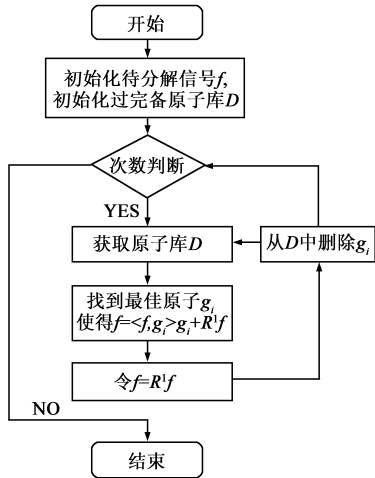


图4 MP算法的简要流程图

原子库中应包含多种结构类型的原子. 文献<sup>[18]</sup>已经提出了一种面向特征抽取的 EEG 信号结构自适应稀疏分解 (Structure Adaptive Sparse Decomposition Model; SSDM) 模型, 并对该模型的构造原理和过程作了详细说明. 其理论依据如下:

由原子库的构造理论可知, 所有原子都是特征波生成函数经过伸缩、平移、旋转得到的. 因此面向特征抽取的 EEG 信号结构自适应稀疏分解 (SSDM) 的关键是如何构建与 EEG 信号不同奇异性结构相匹配的神经元响应函数, 进而构建级联的原子库. 由于应用最为广泛的 Gabor 原子库使用高斯函数作为原子库的生成函数, 考虑到高斯小波作为高斯函数的一阶导数在信号的多尺度分解中具有的重要作用, 吴敏博士将高斯函数、高斯小波作为原子的生成函数, 设计出一种新的多成分原子库来对 EEG 信号进行自适应的时频分析<sup>[18]</sup>.

$$\varphi_r^1(t) = K_1(r) \exp\left\{-\frac{(t-u)^2}{2s^2}\right\} \quad (7)$$

$$\varphi_r^2(t) = K_2(r) \left(\frac{t-u}{s}\right) \exp\left\{-\frac{(t-u)^2}{2s^2}\right\}$$

其中,  $K_1(r)$ 、 $K_2(r)$  为规范化因子, 使原子具有单位化范数;  $\varphi_r^1(r)$ 、 $\varphi_r^2(r)$  分别为高斯函数及其一阶导数; 参数集合  $r = \{u, s\}$  分别表明了原子的位置、尺度特性, 通过平移、伸缩等变换调制生成函数中的自由变量  $u, s$  可生成一系列原子以组成一个冗余的能够有效匹配多种瞬时结构的多成分原子库.

实际应用中, 为了对离散的数字信号进行稀疏分解, 需要采样各种自由参数形成离散的原子库. 离散化后的原子可以表示为:

$$\varphi_r^1[n] = K_1(r) \exp\left\{-\frac{(n-p)^2}{2(a^i)^2}\right\} \quad (8)$$

$$\varphi_r^2[n] = K_2(r) \left(\frac{n-p}{a^i}\right) \exp\left\{-\frac{(n-p)^2}{2(a^i)^2}\right\}$$

其中,  $p, i$  为整数, 离散化参数集合  $r = \{p, a^i\}$ , 取值范围为  $p \in [0, N-1]$ ,  $i \in [0, \log_a N]$ ,  $N$  为待分解离散信号的维数. 一般来说, 可取  $a = 2$ .

在 EEG 信号时频分析中, 稀疏分解获取的信号时频结构参数应该能够同人工视觉分析标准建立直接的联系, 并应用这些时频结构参数与先验参数进行比对后可直接判定是否为 EEG 信号的特征波形. 通过该方法设计的离散原子库具有显式的形态结构参数, 如位置、度、幅度等.

## 4 仿真实验

### 4.1 去噪原理

通过对信号的稀疏分解, 根据相关系数是否为零, 可以把信号分为原始信号和噪声信号. 设原始的含噪 EEG 信号为:  $f = E + N$ ; 其中,  $E$  是原始的无噪信号,  $N$  是独立分布的随机噪声信号. 在原子库上进行 MP 算法时, 由于原子库是根据 EEG 信号的结构特点构造的, 因此原子本身的结构必定只与 EEG 信号有关, 而与噪声无关. 原子和原始信号的内积一定大于原子和噪声的内积, 因此稀疏分解后的系数集中表示了无噪的原始信号, 同时因为没有原子能够表示噪声信号, 噪声就无法被提取出来. 用公式的方式来表达:

$$f = \sum_{l=0}^{L-1} \langle f, g_l \rangle g_l + R^l f \quad (9)$$

可以认为第一部分就是原始的 EEG 信号, 而第二部分就是挑选出 EEG 信号后的残差, 即噪声信号. 用公式表示则为:

$$E = \sum_{l=0}^{L-1} \langle R^l f, g_l \rangle g_l \quad (10)$$

$$N = R^L f$$

### 4.2 实验过程及结果分析

#### 4.2.1 实验设计与信号采集

本实验的实验数据由合作单位北京师范大学认知神经科学与学习国家重点实验室提供.

实验对象为 1 名身体健康男性, 实验对象具有一定的脑电信号采集实验的经验, 本次实验采用脑电扫描仪和具有 128 个电极的扫描帽来记录脑电信号 (图 5), 所有电极的阻抗都低于 5000 欧, 信号的采样频率为 1000Hz. 在进行脑电信号采集时, 被试者意识清晰, 坐在普通的椅子上, 进行 100 次英文“happy”的发音任务, 每次发音任务持续时间为 2s, 实验对象在发音任务开始 1s 后进行发音, 本次实验在一天时间内完成.

#### 4.2.2 实验工具

本次实验使用 MATLAB 环境下的 EEGLab 工具箱读取实验过程中采集到的脑电信号. EEGLab 工具箱是一个针对脑电信号数据的处理工具, 其功能丰富并可以




图5 实验采用脑电扫描帽上的电极位置

读取采集到的信号波形。


#### 4.2.3 实验数据的预处理

因为使用无创方式进行脑电信号采集时,眼电和肌动会对信号产生较大的影响,所以在对脑电信号进行进一步的分析之前,我们通过 EEGLab 工具箱自带的 ICA(Independent Component Analysis)功能提取出了采集到的脑电信号中的有效独立主成分,实现了对夹杂在其中的眼电和肌动信号的初步去除。

#### 4.2.4 SSDM 原子库的构造和信号重构

根据上述原子库的构造方法,可以得到在信号稀疏分解中使用的较一般的原子。图6是其中两个原子的形状示意图,原子长度为1024。从图中我们可以看出,它们的能量集中在原子的中央,而原子的其他地方能量为零。这是两个具有代表性的原子,所得其它原子能量

可能更加集中或分散。这种状况与文献[7]所述相一致。

图6 SSDM库中其中两个原子的形状( $N=1024$ )

下面验证使用 SSDM 原子库的信号重建效果,同时也与 Gabor 原子库做了对比。首先我们从北京师范大学脑科学国家重点实验室提供的脑电数据库中截取一段经过滤波处理后汉语元音/a/的正常脑电信号。

图7(a)是汉语元音/a/的正常脑电波形,由图可以看出正常情况下的脑电波形较平滑;图7(b)是经过 Gabor 原子库重构的元音/a/的波形,而图7(c)则是由 SSDM 原子库重构后的波形图。不难发现,以高斯函数及其一阶导数为原子的生成函数通过变换生成函数中尺度、位置参数构建的 SSDM 原子库相较 Gabor 原子库,对脑电信号的分解重构效果更好。

同时,由于 SSDM 中的原子形态结构更加匹配 EEG 信号中每一分离的瞬时结构,其原子数量与 Gabor 字典相比较少,从而提高了稀疏分解效率。表一是二者进行重构时,信号达到最佳效果时的平均运行时间。从表1可以看出 SSDM 的计算时间大大减少,速度得到了较大的提高。




图7

表1 两种原子库的时间比较

原子库	Gabor	SSDM
平均运行时间/s	218.32	120.76

#### 4.2.5 去噪效果比较

借助 EEGLab 工具,可以得到发音期间的整体波形图,周期为2次发音,如图8所示。(图8由北京师范大学认知神经科学与学习国家重点实验室提供)。我们截取其中一次发音,以英文单词/happy/为例,由于采样频率为1000Hz,一次发音的持续时间为2s,因此共有2000个采样点,如图9(a)所示。然后我们分别对其施加信噪





图8 EEGLab处理示意图

比分别为 10dB、5dB、-5dB、-10dB 的 50Hz 工频干扰,形成原始含噪信号.图 9(b)(c)分别是使用 SSDM 原子库和传统的小波变换方法处理含噪信号后的波形图.

从中不难看出,小波变换方法将 EEG 信号中的有效成分当做噪音去除了.



而使用 SSDM 原子库去噪得到的波形图,较好的保持了原有波形成分.为了评估二者去噪效果的优劣,采用均方根误差 RMSE、信噪比 SNR 进行衡量.计算公式为:

隶属于 DIVA 模型接口中控制模块部分.仿真实验时,要通过这个模块输入相关信息,并修改输入端口参数.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_1(n) - X_2(n))^2} \quad (12)$$

$$SNR = 10 \log_{10} \left[ \frac{\sum_{n=0}^{N-1} X_1^2(n)}{\sum_{n=0}^{N-1} (X_1(n) - X_2(n))^2} \right]$$

其中,  $X_1(n)$  为输入信号,  $X_2(n)$  为输出信号,  $N$  为信号的维数.表二是其比较结果,将 SSDM 方法去噪后得到的信号的信噪比记为 SNR1,均方根误差记为 RMSE1;小波变换方法去噪后得到的信号的信噪比记为 SNR2,均方根误差记为 RMSE2.

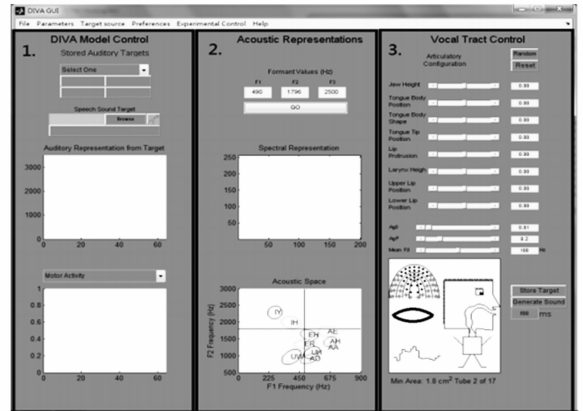
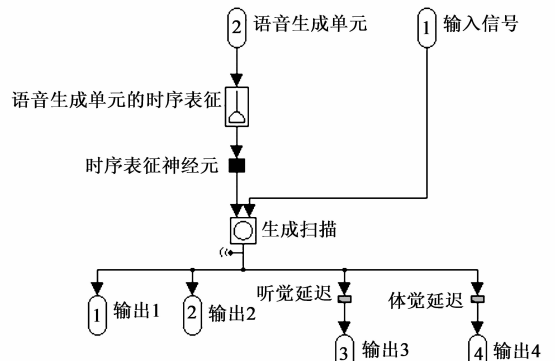


表 2 SSDM 和小波变换的 SNR 和 RMSE 对比

图 10 DIVA模型的用户接口

	SNR1	SNR2	RMSE1	RMSE2
10dB	18.9209	14.1826	0.0015	0.0181
5dB	20.7410	15.1293	0.0014	0.0192
-5dB	23.3201	14.0291	0.0016	0.0314
-10dB	18.4029	16.1082	0.0025	0.0532



从表 2 中可以看出,对于不同信噪比的噪声,用 SSDM 原子库去噪后信噪比都提高了,且高于小波变换去噪方法,达到的去噪效果更好.且通过 SSDM 原子库去噪后信号的均方根误差降低了,即恢复出的脑电信号与原脑电信号相差无几.

图 11 DIVA模型的语音映射集模块

#### 4.2.6 改进后 DIVA 模型的语音处理能力

##### 4.2.6.3 精度结果比较

##### 4.2.6.1 DIVA 模型接口

应用 DIVA 模型执行发音功能时,系统会呈现一个 DIVA 模型的用户接口,其功能为方便用户控制 DIVA 模型的发音机制,如图 10 所示.该接口可分为三个部分:DIVA 模型控制模块、声学表征空间模块和声道控制模块.

将不同难度的去噪前和去噪后的语音学习样本通过模型接口输入到如图 11 所示的 DIVA 模型语音映射集中,可以得到语音发音精度比较图(如图 12 所示).整体上来说,相比去噪前的信号,使用去噪后的信号 DIVA 模型的语音发音精度更高.例如,对于正常难度的学习样本,把含噪信号输入到模型时,发音精度平均在 80%

##### 4.2.6.2 DIVA 语音映射集模块流程图

图 11 是 DIVA 模型中语音映射集模块流程图,它

左右;而把去噪后的信号输入到模型,语音发音精度可以达到 90%。可见 EEG 信号中存在的噪声确实影响了 DIVA 模型对语音发音的处理能力。

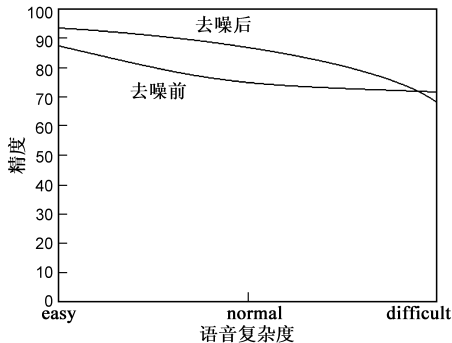


图12 去噪前和去噪后语音发音精度比较

## 5 结语

本文在 DIVA 模型的基础上,针对 EEG 信号自身的结构特征,提出了一种面向特征提取的 EEG 信号结构自适应稀疏分解模型(SSDM),从而构造出一种适用于 EEG 信号的过完备原子库,并运用 MP 算法在这样的原子库中求解最佳原子。仿真实验结果表明,该方法去除了大部分的噪声,并能够较好地保留脑电信号的有效成分,去噪效果优于传统的小波变换方法。同时,把去噪后的信号输入到 DIVA 模型中,提高了模型的学习精度。但是在仿真过程中,也发现了稀疏分解的一定缺点,即利用 MP 算法求解最佳原子时的计算量过大<sup>[19]</sup>,这也为以后的工作提供了方向。本文研究的方法对提高 DIVA 模型的语音处理能力,从而更好地在神经解剖学和神经心理学层次上仿真和描述大脑中涉及语音生成和理解区域的相关功能奠定了良好的基础。

## 参考文献

[1] Guenther FH, Brumberg JS, Wright EJ, Nieto Castanon. A wireless brain-machine interface for real-time speech synthesis [J]. *PLoS ONE*, 2009, 4(12): e8218.

[2] Brumberg JS, Nieto Castanon A, Kennedy PR, Guenther FH. Brain-computer interfaces for speech communication [J]. *Speech Communication*, 2010, 52(4): 367 – 379.

[3] Tourville JT, Guenther FH. The DIVA model: a neural theory of speech acquisition and production [J]. *Language and Cognitive Processes*, 2011, 25(7): 952 – 981.

[4] 杜晓燕,等. 脑电信号伪迹去除的研究进展 [J]. *生物医学工程学杂志*, 2008, 25(2): 464 – 471.

Du Xiaoyan, et al. Removal of artifacts from EEG signal [J]. *Journal of Biomedical Engineering*, 2008, 25(2): 464 – 471. (in Chinese)

[5] 于霞,刘建昌,李鸿儒. 一种变步长凸组合自适应滤波器

及其均方性能分析 [J]. *电子学报*, 2010, 38(2): 480 – 484.

Yu Xia, Liu Jian-chang, Li Hong-ru. A convex combination of variable step-size adaptive filter and its mean-square performance analysis [J]. *Acta Electronica Sinica*, 2010, 38(2): 480 – 484. (in Chinese)

[6] 徐宝国,宋爱国,费树岷. 在线脑机接口中脑电信号的特征提取与分类方法 [J]. *电子学报*, 2011, 38(5): 1025 – 1035.

Xu Bao-guo, Song Ai-guo, Fei Shu-min. Feature extraction and classification of EEG in online brain-computer interface [J]. *Acta Electronica Sinica*, 2011, 38(5): 1025 – 1035. (in Chinese)

[7] Stepphanc Mallat, Zhifeng Zhang. Matching pursuit with time-frequency dictionaries dictionaries [J]. *IEEE Trans on Signal Processing*, 1993, 41(12): 3397 – 3415.

[8] Chen S, Donoho D, Saunders M. Atomic decomposition by basis pursuit [J]. *SIAM Journal on Scientific Computing*, 1998, 20: 33 – 61.

[9] Shaobai zhang, Xin zhang. An improved phonetic learning algorithm based on the DIVA model [J]. *Lecture Notes in Electrical Engineering*, 2011, 123(12): 495 – 500.

[10] Shaobai zhang, Liqin gao. Application of feedforward and feedback control strategy in the speech acquisition and production model [J]. *Lecture Notes in Electrical Engineering*, 2011, 123(2): 489 – 494.

[11] Guenther FH. Cortical interactions underlying the production of speech sounds [J]. *Journal of Communication Disorders*, 2006, 39(5): 350 – 365.

[12] Bohland JW, Guenther FH. An fMRI investigation of syllable sequence production [J]. *NeuroImage*, 2006, 32(2): 821 – 841.

[13] Coifman R, Wickerhauser M. Entropy-based algorithms for best basis selection [J]. *IEEE Transactions on Information Theory*, 1992, 38: 713 – 718.

[14] Cai T Tony, Wang Lie. Orthogonal matching pursuit for sparse signal recovery with noise [J]. *IEEE Transactions on Information Theory*, 2011, 57(7): 4680-4688.

[15] 张春梅,尹忠科,肖明霞. 基于冗余字典的信号过完备表示与稀疏分解 [J]. *科学通报*, 2006, 51(6): 628 – 633.

Zhang chunmei, Yin zhongke, Xiao Mingxia. Over complete representation and sparse decomposition of signal based on the redundant dictionary had [J]. *Chinese Science Bulletin*, 2006, 51(6): 628 – 633. (in Chinese)

[16] Davis G, Mallat S, Avellaneda M. Adaptive greedy approximation [J]. *Constr Approx*, 1997, 13(1): 57 – 98.

[17] Donoho, X Huo. Uncertainty principles and ideal atomic decomposition [J]. *IEEE Trans Information Theory*, 2001, 47(7): 2845 – 2862.

[18] 吴敏. 基于稀疏表示模型的 EEG 信号棘波自检测技术

与应用系统研究[D]. 江苏南京:南京理工大学,2010.8.  
Wu min. Automatic detection of epileptic characteristics in EEG signals based on sparse representation and the design of an application system[D]. Nanjing, Jiangsu: Nanjing University of Science and Technology, 2010.8. (in Chinese)

[19] Mor Etai, Azoulay Amnon, Aladjem Mayer. A matching pursuit method for approximating overlapping ultrasonic echoes [J]. IEEE Trans Ultrason Ferroelectr Freq Control, 2010, 57 (9): 1996 – 2004.

#### 作者简介



张少白 男,1953 年生于湖北武汉,博士研究生学历,南京邮电大学计算机学院教授.研究方向为模式识别与智能系统、智能信息处理以及计算机应用等.

E-mail: adzsb@163.com



王 勇 男,1990 年生,硕士研究生,研究方向:模式识别与智能系统.