

# 新的独立成分分析算法实现功能磁共振 成像信号的盲分离

武振华<sup>1</sup>, 史振威<sup>1</sup>, 唐焕文<sup>1</sup>, 唐一源<sup>2,3,4</sup>

(1. 大连理工大学计算生物学和生物信息学研究所, 大连 116023; 2. 大连理工大学神经信息学研究所, 大连 116023;  
3. 中国科学院生物物理研究所视觉信息加工实验室, 北京 100101;  
4. 中国科学院心理研究所心理健康重点实验室, 北京 100101)

**摘要:** 采用独立成分分析 (independent component analysis, ICA) 的一种新的牛顿型算法来提取功能磁共振成像 (functional magnetic resonance imaging, fMRI) 信号中的各种独立成分 (包括与实验设计相关的成分以及各种噪声)。与fastICA相比, 该算法减少了运算量, 提高了运算速度, 而且能够很好地分离出各个独立成分。结果表明该算法是一种有效的fMRI信号分析手段。

**关键词:** 牛顿型算法; 独立成分分析; 功能磁共振成像; 盲源分离

**中图分类号:** Q332, Q189

## 1 引言

独立成分分析 (ICA) [1-3] 是一种全新的数据分析工具, 1986年由Herault和Jutten第一次提出。1998年McKeown等[4]第一次把它用到fMRI信号处理中, 并有效地提取出各种独立成分 (包括与实验设计相关的成分以及头动、呼吸、心跳等各种噪声)。此后, ICA在fMRI中的应用一直是一个研究热点。

ICA对于观察到的多元数据集定义了一个生成模型, 假设观察到的数据是由一些未知隐藏变量的线性或非线性混合得到, 而混合系统也是未知的, 且这些隐藏变量服从非高斯分布, 并且各分量相互独立。这些隐藏变量就被称为观察数据集的独立成分, 它们可以通过ICA来找到。

设 $\mathbf{x}=(x_1, x_2, \dots, x_N)^T$ 为观察信号,  $\mathbf{s}=(s_1, s_2, \dots, s_M)^T$ 为独立的源信号且各分量呈非高斯分布,  $\mathbf{A}$ 是 $N \times M$ 阶混合矩阵。则标准的线性ICA模型为

$$\mathbf{x}=\mathbf{A}\mathbf{s} \quad (1)$$

ICA的目的就是在仅知道 $\mathbf{x}$ 的情况下, 寻找 $M \times N$ 阶解混矩阵 (demixing matrix)  $\mathbf{W}$ , 使 $\mathbf{y}=\mathbf{W}\mathbf{x}$ , 其中 $\mathbf{y}=(y_1, y_2, \dots, y_M)^T$ , 且 $\mathbf{y}$ 的各分量尽可能地相互独立, 则 $\mathbf{y}$ 就逼近 $\mathbf{s}$ , 从而得到源信号 $\mathbf{s}$ 。以下我们只考虑标准的线性ICA, 且假设随机向量的均值为零。

在脑功能成像中常用“广义线性模型” $\mathbf{x}=\mathbf{H}\boldsymbol{\beta}+\mathbf{e}$ , 这里 $\mathbf{x}$ 是观察到的数据,  $\mathbf{H}$ 是“设计矩阵”, 即假设成分的时间序列;  $\boldsymbol{\beta}$ 是假设成分的象素值构成

的矩阵;  $\mathbf{e}$ 是模型的残余误差。去掉 $\mathbf{e}$ , 就是上述无噪声的线性ICA随机模型。在fMRI信号分析中, 各种噪声被看成相互独立的成分, 因此可以用独立成分分析来提取出fMRI信号中的独立成分, 从而得到跟设计方波一致的独立成分以及心跳、呼吸、头动等各种噪声。

本文采用独立成分分析的一种新的牛顿型算法来提取fMRI信号中的各种独立成分, 该算法没有通常求解约束优化问题的Lagrange乘子项, 形式较简单, 简化了优化问题的求解过程, 减少了运算量, 提高了运算速度。

## 2 新的独立成分分析算法简介

### 2.1 ICA的优化模型

在ICA算法中, 首先对观察信号 $\mathbf{x}$ 进行白化处理, 即进行线性变换

$$\mathbf{z}=\mathbf{V}\mathbf{x}=\mathbf{V}\mathbf{A}\mathbf{s} \quad (2)$$

使 $\mathbf{z}$ 的相关矩阵为单位阵:  $E\{\mathbf{z}\mathbf{z}^T\}=\mathbf{I}$ 。这一步可以通过主成分分析 (PCA) 来完成。数据经过白化处理以后, 只需要在正交空间中寻找解混矩阵。

要求解模型(1), 还需要寻找一个度量随机向量

收稿日期: 2003-07-14

基金项目: 国家自然科学基金项目(90103033, 30170321)、

国家科技部973前期专项(2001CCA00700)

通讯作者: 唐一源, 电话: (0411)4706046,

E-mail: yy2100@163.net

的独立性的量, 这里用负熵 (negentropy) 来度量随机向量的独立性, 也就是寻找一个向量  $\mathbf{w}$ , 使  $\mathbf{w}^T \mathbf{z}$  的非高斯性最大。这样基于负熵的独立成分分析模型就等价于下面的优化问题<sup>[8]</sup>:

$$\begin{aligned} \max \{G(\mathbf{w}^T \mathbf{z})\} \\ \text{s.t. } \|\mathbf{w}\|^2 = 1 \end{aligned} \quad (3)$$

$G$ 是为了估计负熵而引入的任意的非二次函数, 为了获得稳定的估计, 一般选择增长不是太快的 $G$ , 文献[8]给出了 $G$ 的几个稳定的估计量。

## 2.2 算法

对于标准的ICA问题, 前人已经给出了多种算法, 包括H-J算法<sup>[9]</sup>、B-S算法<sup>[10]</sup>、非线性的PCA算法等<sup>[6]</sup>, 通常这些算法都是基于梯度下降法的自适应算法。在实际应用中, 它们的收敛速度较慢, 且收敛很大程度上取决于步长序列的选择。随后, Hyvärinen提出了著名的fastICA算法<sup>[7,8]</sup>, 运算速度要比前面几种方法快。

我们对优化问题(3)进行分析, 给出了一种新的牛顿型算法。它采用如下的求解策略: 该问题的约束是等式且较简单, 可采用在约束集上投影的方法, 也就是先用算法求解相应的无约束优化问题, 在每一步迭代后, 该解被投影在约束集上以满足约束。针对问题(3), 先用牛顿法来求解相应的无约束优化问题, 在迭代的每一步后, 将向量 $\mathbf{w}$ 投影到单位球面上, 这样得到以下算法:

$$\mathbf{w} \leftarrow \mathbf{w} - [E\{\mathbf{z}\mathbf{z}^T g'(\mathbf{w}^T \mathbf{z})\}]^{-1} [E\{\mathbf{z}g'(\mathbf{w}^T \mathbf{z})\}] \quad (4)$$

$$\mathbf{w} \leftarrow \mathbf{w} / \|\mathbf{w}\|$$

这里函数 $g$ 是模型(3)中函数 $G$ 的一阶导数, 函数 $g'$ 是函数 $g$ 的一阶导数, 值得注意的是, 算法(4)没有通常求解约束优化问题的Lagrange乘子项, 这就简化了优化问题的求解过程, 节省了运算量, 提高了运算速度。为了增强算法的稳定性, 可以添加一个步长因子 $\mu$ , 并采用如下估计式:

$$E\{\mathbf{x}\mathbf{x}^T g'(\mathbf{w}^T \mathbf{x})\} \approx E\{\mathbf{x}\mathbf{x}^T\} E\{g'(\mathbf{w}^T \mathbf{x})\} = E\{g'(\mathbf{w}^T \mathbf{x})\} \mathbf{I} \quad (5)$$

算法(4)就可以写成:

$$\mathbf{w} \leftarrow \mathbf{w} - \mu E\{\mathbf{z}g'(\mathbf{w}^T \mathbf{z})\} / E\{g'(\mathbf{w}^T \mathbf{z})\} \quad (6)$$

$$\mathbf{w} \leftarrow \mathbf{w} / \|\mathbf{w}\|$$

算法(6)用来提取一个独立成分, 如果要提取 $N$ 个独立成分, 就把(6)写成矩阵的形式:

$$\mathbf{W} \leftarrow \mathbf{W} + \mu \text{diag}(a_i) E\{\vec{g}(\mathbf{u})\mathbf{u}^T\} \mathbf{W} \quad (7)$$

$$\mathbf{W}_i \leftarrow \mathbf{W}_i / \|\mathbf{W}_i\| \quad (i=1, 2, \dots, N)$$

其中 $\mathbf{W}_i$ 是矩阵 $\mathbf{W}$ 的第 $i$ 行所表示的列向量,  $a_i$ 定义为 $-1/E\{g'(\mathbf{W}_i^T \mathbf{x})\}$  ( $i=1, 2, \dots, N$ ),  $\vec{g}(\mathbf{u})=(g(\mathbf{W}_i^T \mathbf{x}))$ ,

$g(\mathbf{W}_2^T \mathbf{x}), \dots, g(\mathbf{W}_N^T \mathbf{x})^T$ 且 $\mathbf{u}=\mathbf{W}\mathbf{x}$ 。同时, 为了避免算法(7)收敛到相同的独立成分, 在算法迭代的每一步, 矩阵 $\mathbf{W}$ 需要一个对称正交化的过程:

$$\mathbf{W} \leftarrow (\mathbf{W}\mathbf{W}^T)^{-1/2} \mathbf{W}$$

## 3 材料和方法

**fMRI技术和参数:**实验采用GE公司Signa Horizon 1.5T超导型磁共振成像系统。实验时, 功能成像采用回波平面成像梯度回波序列, 其扫描参数如下:  $TR=2000$  ms,  $TE=40$  ms,  $FOV=24$  cm  $\times$   $24$  cm, 层厚6 mm, 间距1 mm, 矩阵为 $64 \times 64$ ,  $FA=90^\circ$ , 共取14层。

**设计与材料:**实验采用组块设计 (block-design) 或方波设计。共有4个组块, 每个组块60 s, 其中包含30 s的控制字符“+”和30 s内10个字刺激, 实验持续时间为240 s。实验任务是动词联想任务, 如看到“饭”联想“吃” (注意必须



Fig.1 Block design

是动词), 控制条件是放松被动看“+”字, 不做任何联想活动。实验的具体模式如下:

**被试:**被试为一名健康大学生, 经标准化问卷调查确认为右利手, 视力正常, 实验前无任何不适感。

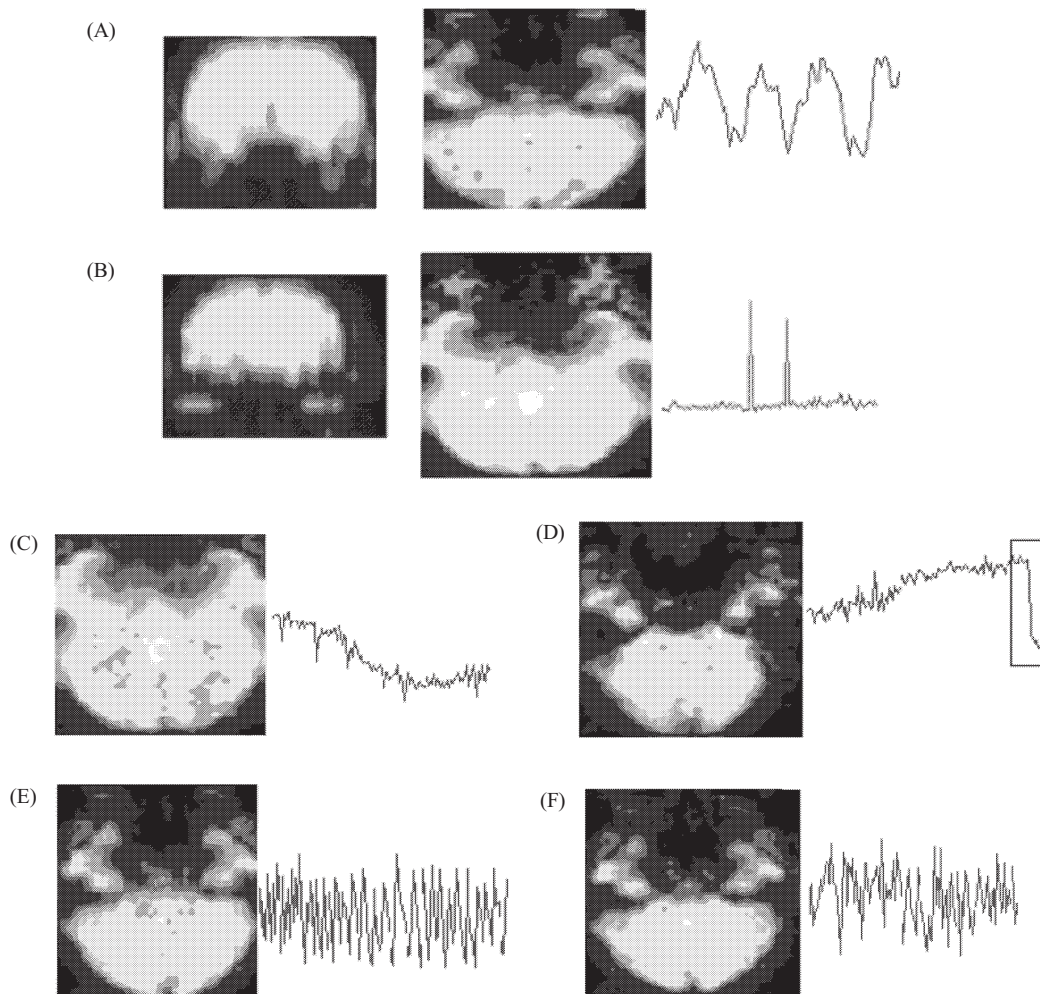
## 4 结果

通过fMRI实验, 得到120帧/层的脑功能磁共振成像数据(取14层)。把同一帧的14层数据看成一个独立成分, 总共是120个独立成分。结合无噪声线性模型 $\mathbf{X}=\mathbf{H}\boldsymbol{\beta}$ , 首先对数据进行中心化处理, 再用主成分分析对数据进行白化, 然后用算法(7)计算独立成分(取 $\mu=0.9$ )。从120个独立成分中选择有代表性的成分(成分的判定可以参考文献[4]): 任务相关信号成分、眼动信号成分、头动信号成分、拟周期性信号成分、噪声信号成分。通过选取合适的阈值 ( $|z|>2$ ), 用脑功能成像处理软件SPM (Statistical Parametric Mapping) 显示各个独立成分所对应的激活图(图2)。

在得到的120个成分的时间序列里, 我们发现

类似于实验的方波设计、并且跟实验设计的时间序列相关系数大于0.5的有一个(为0.7966),把它单独视为一类。与眼动相似的成分共有3个,其时间序列不一样,但是都有明显的跳跃,激活区域基本相同,可以归为一类;跟缓慢头动相似的成分有两

个;突然头动信号独立成分有一个;拟周期性信号在分离出来的独立成分中有多个,激活区域也基本一致,可以把它们归为一类。噪声信号有多个,而且它们引起的激活呈随机分布。取上述有代表性的独立成分,用SPM给出各自的激活图:



**Fig.2** Independent components and respective time course ( $|z| > 2$ ). (A) Task-related independent component and time course; (B) Eye movement and time course; (C) Slow head movement and time course; (D) Abrupt head movement and time course; (E) Quasi-periodic signal and time course; (F) Noise signal and time course

任务相关独立成分(图2A):由图可以看出激活区包括枕叶、颞叶、额叶、小脑。这跟文献[9]、[10]的结果相符,实验的独立成分的时间序列跟实验设计的时间序列的相关性达到0.7966,这个相关系数略低于文献[9]的结果,但是好于文献[10]中相关性分析和主成分分析得到的结果。

眼动信号独立成分(图2B):可以看出该成分引起的激活区主要集中在眼睛附近,而且在时间序列上有两个突然的跳跃,可以认为是由眨眼引起的

激活。

头动信号独立成分(图2C、2D):由于该实验时间较长,被试可能由于疲劳导致头部缓慢的移动,可以看出,激活区主要集中在脑的轮廓线上,而且其时间序列从高到低缓慢变化,可以认为是缓慢头动所致。被试也可能在短时间内有大幅度的头动(平移或者转动),激活区主要出现在脑的轮廓线上,其时间序列有一个从高到低的突然变化。

拟周期信号独立成分(图2E):激活的时间序列



在实验中呈现近似于周期性的变化,但这个周期不同于任务和控制的交替周期,可以认为是心跳或者呼吸等产生的信号在起作用。

噪声信号独立成分(图2F):在所有的独立成分中,我们分离出多个噪声信号,这里给出了一个噪声信号的独立成分例子,它所引起的激活散布在整个大脑中,其时间序列也呈一种随机分布,没有任何的规律性。

## 5 讨 论

在数据处理中,我们发现该算法具有较快的收敛速度:在主频为2G的Interl pentium 4计算机上,分别采用本文所给算法和国际上著名的fastICA<sup>[7,8]</sup>算法([http://www.cishut.fi/projects/ica/fastica/code/FastICA\\_2.1.zip](http://www.cishut.fi/projects/ica/fastica/code/FastICA_2.1.zip)),对同一次实验的多个fMRI信号实现盲分离,并记录程序运行时间,然后取其平均值,结果发现用fastICA算法实现单个fMRI信号分离时程序要运行75 min,而该算法只需65 min,可见该算法提高了运算速度。这在数据量庞大的fMRI信号处理中是很重要的,而且该算法也取得很好的分离结果,能够有效地分离出跟实验设计相关的独立成分和心跳、呼吸、头动等各种噪声。

值得注意的是,由于独立成分分析算法本身的原因,分离出来的独立成分是不分先后顺序的,因此独立成分的排序是一个值得研究的问题。

在分离出来的每个独立成分中,象素值超过一定的阈值被认为是激活,当阈值较大时,激活区域少,阈值较小时,激活区域多。但实际应用中阈值的选取需要根据心理学的需要来选择,在心理学有意义的范围内来选择阈值,进而确定激活区域。

得到独立成分以后,还需要对独立成分进行生理学、心理学上的分析和解释。单个fMRI信号分离的结果,对个体的研究有重要意义,但是缺乏统

计意义,从而使生理学、心理学上的分析和解释缺乏普遍性。这样就有研究fMRI组信号的必要,通过fMRI组信号的研究可以寻找到个体间的异同,得到具有普遍意义的结论。Calhoun<sup>[11]</sup>做了初步的尝试,但是,由于运算量太大,实际操作中存在不少困难,有待进一步探索。

## 参考文献:

- [1] Comon P. Independent component analysis——A new concept. *Signal Processing*, 1994,36:287~314
- [2] Bell A, Sejnowski T. An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, 1995,7:1129~1159
- [3] Hyvärinen A, Oja E. A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 1997, 9(7):1483~1492
- [4] McKeown MJ, Makeig S, Brown GG, Jung TP, Kindermann SS, Bell AJ, Sejnowski T. Analysis of fMRI data by blind separation into independent spatial components. *Human Brain Mapping*, 1998,6:160~188
- [5] Jutten C, Herault J. Blind separation of sources, Part I: an adaptive algorithm based on neuromimetic architecture. *Signal Processing*, 1991,24:1~10
- [6] Oja E. The nonlinear PCA learning rule in independent component analysis. *Neurocomputing*, 1997,17(1):25~46
- [7] Hyvärinen A. Fast and robust fixed-pointed algorithms for independent component analysis. *IEEE Transactions on Neural Networks*, 1999,10(3):626~634
- [8] Hyvärinen A, Oja E. Independent component analysis: algorithms and applications. *Neural Network*, 2000,13:411~430
- [9] 范丽伟,唐焕文,唐一源. 空间独立成分分析在fMRI数据分析中的应用. 大连理工大学学报, 2003,43(4):399~402
- [10] 钟明军,唐焕文,唐一源. 空间独立成分分析实现fMRI信号的盲源分离. 生物物理学报, 2003,19(1):79~83
- [11] Callhoun VD, Adali T, Pearlson GD, Pekar JJ. A method for making group inferences from functional MRI data using independent component analysis. *Human Brain Mapping*, 2001,14:140~151

## BLIND SOURCE SEPARATION FOR FMRI SIGNALS USING A NEW INDEPENDENT COMPONENT ANALYSIS ALGORITHM

WU Zhen-hua<sup>1</sup>, SHI Zhen-wei<sup>1</sup>, TANG Huan-wen<sup>1</sup>, TANG Yi-yuan<sup>2,3,4</sup>

*(1. Institute of Computational Biology and Bioinformatics, Dalian University of Technology, Dalian 116023, China;*

*2. Institute of Neuroinformatics, Dalian University of Technology, Dalian 116023, China;*

*3. Laboratory of Visual Information Processing, The Chinese Academy of Sciences, Beijing 100101, China;*

*4. Key Lab for Mental Health, The Chinese Academy of Sciences, Beijing 100101, China)*

**Abstract:** In order to separate independent components (task-related signal and other noises) from functional magnetic resonance imaging (fMRI) signals, a new independent component analysis algorithm was used. In contrast to fastICA, the algorithm reduced computation and raised speed of operation. It also separated independent components from fMRI signals very well.

**Key Words:** Newton algorithm; Independent component analysis; Functional magnetic resonance imaging; Blind source separation