

doi : 10. 3969/j. issn. 1005 - 3026. 2016. 08. 008

# 基于盲反卷积的脑电信号盲分离研究

黄璐<sup>1,2</sup>,王宏<sup>3</sup>

( 1. 东北大学 中荷生物医学与信息工程学院,辽宁 沈阳 110167 ;2. 大连海洋大学 信息工程学院,辽宁 大连 116023 ;  
3. 东北大学 机械工程与自动化学院,辽宁 沈阳 110819 )

**摘 要 :**采用卷积混合模型描述观测脑电信号( electroencephalogram ,EEG ),提出一种基于盲反卷积的 EEG 盲分离方法. 结合 EEG 源成分的独立性确定代价函数,并采用共轭梯度法进行迭代寻优. 针对 EEG 仿真实验数据进行方法验证,采用分离信号与源信号之间的相关系数作为验证指标. 实验结果表明,本文方法可以较好地实现 EEG 盲分离,为 EEG 信号处理和其他生理信号处理分析提供理论和方法借鉴.

**关 键 词 :**生理信号;脑电信号;信号处理;盲分离;盲反卷积

中图分类号: R 318      文献标志码: A      文章编号: 1005 - 3026( 2016 )08 - 1100 - 04

## Blind Separation of EEG Based on Blind Deconvolution

HUANG Lu<sup>1,2</sup>, WANG Hong<sup>3</sup>

( 1. Sino-Dutch Biomedical and Information Engineering School, Northeastern University, Shenyang 110167, China ;2. College of Information Engineering, Dalian Ocean University, Dalian 116023, China ;3. School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China. Corresponding author : WANG Hong, E-mail : hongwang@ mail. neu. edu. cn )

**Abstract :** The convolution mixture model was adopted to describe the as-observed EEG signals , and then a method for the blind separation of EEG based on blind deconvolution was put forward. The cost function was established based on the independence of EEG sources , and iteration was carried out using conjugate gradient method. The verification was implemented with simulation experiment , adopting the correlation coefficients between separated signals and source signals as the verification indexes. Experimental results show that the method proposed can achieve blind separation of EEG successfully , providing a theoretical and practical reference for the processing of EEG and other physiological signals.

**Key words :** physiological signal ; electroencephalogram ; signal processing ; blind separation ; blind deconvolution

在脑电( electroencephalogram ,EEG )信号的测量与分析中,头皮处得到的观测 EEG 是由大脑皮层产生的源信号经组织液、头骨等容积导体传输到头皮处产生的混合信号,并在传输期间混有工频干扰和高斯噪声等外部信源. 描述信号系统混合过程的模型有瞬时混合和卷积混合两种,相应的信号盲分离方法为瞬时盲分离和盲反卷积. 考虑到 EEG 传输的时延性及多向性,卷积混合模型更符合其物理意义,因此,EEG 盲分离应采用盲反卷积.

目前大多数研究中的 EEG 盲分离步骤均采用瞬时盲分离<sup>[1-3]</sup>,采用盲反卷积的研究较少. Abutaleb 等<sup>[4]</sup>使用随机微积分的方法对观测 EEG 信号进行盲反卷积,取得了较好效果,但该方法只能针对 3 个观测信号分离出 2 个源信号,即假设观测信号仅有 2 个源信号混合而成. Dyrholm 等<sup>[5]</sup>提出一种基于极大似然估计的盲反卷积算法,对观测 EEG 进行盲分离. 该方法可以分离出多个源信号,但需要针对所有观测 EEG 信号首先进行 Informax ICA,然后在得到的分量中

选取若干个分量进行盲反卷积;其不足在于 Informax ICA 步骤会造成数据损失,且分量挑选是否合适直接影响最终分离结果.

针对上述情况,本文提出一种基于盲反卷积的 EEG 盲分离方法,结合脑电源成分的独立性确定代价函数,并采用共轭梯度法进行迭代寻优.利用 EEG 仿真实验进行方法验证,结果表明,本文方法可以有效进行观测 EEG 盲分离.

## 1 盲反卷积算法

### 1.1 EEG 的混合模型描述

设  $m$  维观测 EEG 信号  $x_i(i=1,2,\dots,m)$  是由  $n$  维源信号  $s_j(j=1,2,\dots,n)$  卷积混合而成,则混合模型可以表示如下:

$$x_i(t)=\sum_{j=1}^n\sum_{p=0}^{l-1}h_{ij}(p)s_j(t-p). \tag{1}$$

式中  $t$  为采样点,  $h_{ij}(\cdot)$  为第  $j$  个源信号传输到第  $i$  个观测点的卷积混合过程,用 FIR 滤波器表示;  $l$  为 FIR 滤波器阶数.通常将卷积混合模型转化成瞬时混合模型进行求解,具体转化方法如下<sup>[6]</sup>:

设置长度为  $w$  的时间窗,令  $mw\geq n(w+l-1)$ ,则窗内第  $i$  个观测 EEG 为  $x_i(t)=[x_i(t),x_i(t-1),\dots,x_i(t-w+1)]^T$ ,定义矢量  $x(t)=[x_1^T(t)x_2^T(t)\dots x_m^T(t)]^T$ ,则公式 (1) 可重写为

$$x(t)=Ax(t). \tag{2}$$

式中  $x(t)=[s_1^T(t)s_2^T(t)\dots s_n^T(t)]^T$  为加窗处理后的 EEG 源信号矢量,  $s_j(t)=[s_j(t),s_j(t-1),\dots,s_j(t-w-l+2)]^T$ ;  $A=(A_{ij})$  ( $i=1,2,\dots,m$ ,  $j=1,2,\dots,n$ ) 是一个分块矩阵,其中每个分块均是  $w\times(w+l-1)$  维 Toeplitz 矩阵:

$$A_{ij}=\begin{bmatrix} h_{ij}(0) & \dots & h_{ij}(l-1) & 0 & \dots & 0 \\ 0 & h_{ij}(0) & \dots & h_{ij}(l-1) & 0 & \\ & 0 & \ddots & & \ddots & 0 \\ 0 & \dots & 0 & h_{ij}(0) & \dots & h_{ij}(l-1) \end{bmatrix}. \tag{3}$$

由此,式 (1) 卷积混合模型就转化为式 (2) 瞬时混合模型.

### 1.2 代价函数

脑电源信号之间是互相独立的,且短时间内是平稳的,其自相关矩阵的非对角块部分等于零,符合 JBD 原理.所以,基于 JBD 确定代价函数,具体方法如下<sup>[7]</sup>.

由于构成矢量  $x(t)$  的 EEG 源信号互相独立,

且同一源信号在不同时延情况下是相关的,因此,  $s(t)$  的自相关矩阵  $R_s(\tau)=E\{s(t)s^H(t-\tau)\}=\text{bdiag}\{\mathbb{E}[R_{s_1}(\tau)R_{s_2}(\tau)\dots R_{s_n}(\tau)]\}$  为分块对角矩阵,其中  $R_{s_j}(\tau)=E\{s_j(t)s_j^H(t-\tau)\}$ . 对式 (2) 求自相关,可得

$$R_x(\tau)=AR_s(\tau)A^H. \tag{4}$$

设矩阵  $W$  为  $A$  的逆矩阵,即 EEG 解混矩阵,可得

$$WR_x(\tau)W^H=R_s(\tau). \tag{5}$$

根据联合块对角化原理,取多个时延  $\tau_q$ ,  $q=1,\dots,Q$ ,得到多个  $R_x(\tau_q)$ ,同时进行分块对角化,令  $WR_x(\tau_q)W^H$  的非对角块部分尽量等于零,从而得到如下代价函数:

$$\min J(W)=\sum_{q=1}^Q\|\text{offbdiag}(WR_x(\tau_q)W^H)\|_F^2. \tag{6}$$

式中:  $\|\cdot\|_F$  为矩阵的 Frobenius 范数;  $\text{offbdiag}(\cdot)$  表示矩阵的非对角块部分.求得对  $W$  的估计  $\hat{W}$  后,通过计算  $\hat{s}(t)=\hat{W}x(t)$  即可求得对 EEG 源信号的估计.

### 1.3 迭代算法

采用共轭梯度法对式 (6) 进行迭代寻优:

$$W_{k+1}=W_k+\alpha_k d_k, \tag{7}$$

$$\beta_k=\frac{g_{k+1}^H g_{k+1}}{g_k^H g_k}, \tag{8}$$

$$d_{k+1}=-g_{k+1}+\beta_k d_k. \tag{9}$$

式中  $\alpha_k$  为步长因子,采用强 Wolfe 不精确线性搜索方法产生  $g_k=\nabla J(W_k)$ ,计算公式为<sup>[8]</sup>

$$g_k=2\sum_{q=1}^Q\{\|\text{offbdiag}(W_kR_x(\tau_q)W_k^H)W_kR_x^H(\tau_q)\|+(\text{offbdiag}(W_kR_x(\tau_q)W_k^H))^H W_kR_x(\tau_q)\}. \tag{10}$$

具体迭代步骤如下:

①白化观测 EEG 信号.对 EEG 的零时延自相关矩阵  $R_x(0)$  进行特征值分解,得到  $R_x(0)=VDV^H$ .式中,  $V$  为特征向量矩阵,  $D$  为特征值矩阵,  $D$  中所有特征值以降序排列.构造白化矩阵  $A=D^{-\frac{1}{2}}V^H$ ,以此矩阵对观测 EEG 信号  $x(t)$  进行白化.

②给出解混矩阵的初始值  $W_0$  并对其进行标准化,同时给出算法的终止阈值  $\epsilon(\epsilon>0)$ ,令  $k=0$ .

③依据式 (10) 计算  $g_0=\nabla J(W_0)$ ,令  $d_0=-g_0$ .

④采用强 Wolfe 不精确线性搜索方法计算

$\alpha_k$  依据式 ( 7 ) 计算  $W_{k+1}$  , 并进行标准化  $W_{k+1} = W_{k+1} / \| W_{k+1} \|_F$  .

⑤如果  $\| W_{k+1} - W_k \|_F \leq \varepsilon$  , 算法停止 , 输出  $\widehat{W} = W_{k+1}$  .

⑥令  $n_{\text{dim}}$  为  $W$  的维数 , 如果  $k = n_{\text{dim}}$  , 则令  $W_0 = W_{k+1}$  转到步骤③.

⑦依据式 ( 10 ) 计算  $g_{k+1}$  , 依据式 ( 8 ) , 式 ( 9 ) 计算  $d_{k+1}$  , 令  $k = k + 1$  转到步骤④.

1.4 收敛性分析

由于在共轭梯度法寻优中 , 采用强 Wolfe 不精确线性搜索产生  $\alpha_k$  时 , 方向  $d_k$  肯定是下降方向<sup>[ 9 ]</sup> , 即  $J(W_{k+1}) - J(W_k) \leq 0$  . 同时 , 由式 ( 6 ) 可以看出 , 代价函数的值是基于多个矩阵 Frobenius 范数的平方和计算的 , 因此该代价函数是非负的 , 存在一个下界 0 . 则对于  $\forall \varepsilon > 0$  , 总存在  $K$  , 使得  $k > K$  时 ,  $| J(W_{k+1}) - J(W_k) | < \varepsilon$  , 因此 , 算法收敛.

2 仿真实验数据

给出 3 个时域信号  $s_1$   $s_2$   $s_3$  , 作为  $n = 3$  的三维源信号.  $s_1$  为 Cz 导联 1s 时间段静息 EEG 信号 , 采集设备使用 Neuroscan 4.3 系统 , 采样频率 1 000 Hz , 记录带宽 0.1 ~ 100 Hz , 皮肤阻抗  $\leq 5 \text{ k}\Omega$  .  $s_2$  为频率 50 Hz 的正弦信号 , 用来模拟工频干扰 ,  $s_3$  表示测量过程中混入的高斯噪声.

设观测 EEG 的维数  $m = 4$  , 传输路径 FIR 滤波器阶数  $l = 3$  , 滤波器系数随机生成 , 具体如下 :

$$H = ( H_{ij} )_{4 \times 3} .$$

其中  $H_{ij} = a_{ij} + b_{ij}z^{-1} + c_{ij}z^{-2}$  .

源信号及混合信号分别如图 1 和图 2 所示.




图 1 源信号  
Fig. 1 Source signals  
( a )—EEG 信号 ; ( b )—工频干扰 ; ( c )—噪声.




图 2 混合信号  
Fig. 2 Mixed signals  
( a )—混合信号 1 ; ( b )—混合信号 2 ;  
( c )—混合信号 3 ; ( d )—混合信号 4 .

3 实验结果分析

取时间窗长度  $w = 6$  , 时延数  $Q = 20$  , 阈值  $\varepsilon = 0.01$  , 使用本文方法和文献 [ 5 ] 方法得到的对源信号的估计分别如图 3 和图 4 所示.




图 3 本文方法得到的分离信号  
Fig. 3 Signals obtained with the method proposed  
( a )—EEG 信号估计 ; ( b )—工频干扰估计 ;  
( c )—噪声估计.




图 4 文献 [ 5 ] 方法得到的分离信号  
Fig. 4 Signals obtained with the method in document [ 5 ]  
( a )—工频干扰估计 ; ( b )—EEG 信号估计 ;  
( c )—噪声估计.

为了验证方法的有效性,采用相关系数衡量实验结果,结果如表 1 所示.可以看出,与文献[5]相比,本文方法得到的分离信号与源信号之间具有更大的相关程度,说明了本文方法的有效性.

表 1 两种方法得到的相关系数对比

Table 1 Comparison of correlation coefficients

信号类别	本文方法	文献[5]方法
EEG 信号	0.971 3	0.939 5
工频干扰	0.986 0	0.952 4
噪声	0.945 1	0.920 8
平均	0.967 5	0.937 6

盲分离算法应用于生理信号的有效性与算法假设条件和生理信号之间的适应性有关.本文考虑源信号传输过程中的时延性和多向性,用卷积混合模型描述观测 EEG,直接进行盲反卷积,得到较好的分离效果.而文献[5]则需要结合使用瞬时盲分离和盲反卷积,这可能是导致丢失部分有用信息、分离效果受到影响的原因.

## 4 结 语

本文提出一种基于盲反卷积的 EEG 盲分离方法,并通过仿真实验进行验证.结果表明,该方法可有效进行 EEG 盲分离,为针对 EEG 信号和其他生理信号的盲分离处理提供了借鉴和思路.

### 参考文献：

[ 1 ] Sardouie S H ,Shamsollahi M B ,Albera L ,et al. Denoising of ictal EEG data using semi-blind source separation methods

[ 5 ] Allis L V ,van den Herik H J ,Huntjens M P H. Go-Moku solved by new search techniques [ J ]. *Computational Intelligence* ,1996 ,12 ( 1 ) :7 – 23.

[ 6 ] Wu I C ,Lin H H ,Sun D J ,et al. Job-level proof-number search for connect6 [ C ]// *Computer Games*. Berlin : Springer-Verlag 2011 :11 – 22.

[ 7 ] Kishimoto A ,Winands M ,Müller M ,et al. Game-tree search using proof numbers :the first twenty years [ J ]. *ICGA*

based on time-frequency priors [ J ]. *IEEE Journal of Biomedical and Health Informatics* 2015 ,19 ( 3 ) :839 – 847.

[ 2 ] Selvan S ,George S ,Balakrishnan R. Range-based ICA using a nonsmooth quasi-Newton optimizer for electroencephalographic source localization in focal epilepsy [ J ]. *Neural Computation* 2015 27 ( 3 ) :628 – 671.

[ 3 ] Hamaneh M B ,Chitravas N ,Kaiboriboon K ,et al. Automated removal of EKG artifact from EEG data using independent component analysis and continuous wavelet transformation [ J ]. *IEEE Transactions on Biomedical Engineering* 2014 61 ( 6 ) :1634 – 1641.

[ 4 ] Abutaleb A ,Fawzy A ,Sayed K. Blind deconvolution of EEG signals using the stochastic calculus [ C ]// *Proceedings of 2012 Cairo International Biomedical Engineering Conference*. Giza 2012 :175 – 178.

[ 5 ] Dyrholm M ,Makeig S ,Hansen L K. Model selection for convolutive ICA with an application to spatiotemporal analysis of EEG [ J ]. *Neural Computation* ,2007 ,19 ( 4 ) :934 – 955.

[ 6 ] Bousbia-Salah H ,Belouchrani A ,Abed-Meraim K. Blind separation of convolutive mixtures using joint block diagonalization [ C ]// *Proceedings of the Sixth International Symposium on Signal Processing and Its Applications*. Kuala Lumpur 2001 :13 – 16.

[ 7 ] Ghennioui H ,Fadaili E M ,Thirion-Moreau N ,et al. A nonunitary joint block diagonalization algorithm for blind separation of convolutive mixtures of sources [ J ]. *IEEE Signal Processing Letters* 2007 ,14 ( 11 ) :860 – 863.

[ 8 ] Ghennioui H ,Thirion-Moreau N ,Moreau E ,et al. Gradient-based joint block diagonalization algorithms :application to blind separation of FIR convolutive mixtures [ J ]. *Signal Processing* 2010 90 ( 6 ) :1836 – 1849.

[ 9 ] 孙文瑜 ,徐成贤 ,朱德通. 最优化方法 [ M ]. 2 版. 北京 :高等教育出版社 2010 :149 – 158.

( Sun Wen-yu , Xu Cheng-xian , Zhu De-tong. The optimization method [ M ]. 2nd ed. Beijing :Higher Education Press 2010 :149 – 158. )

( 上接第 1074 页 )

*Journal* 2012 35 ( 3 ) :131 – 156.

[ 8 ] Xu C M ,Ma Z M ,Tao J ,et al. Enhancements of proof number search in connect6 [ C ]// *Control and Decision Conference*. New York :IEEE 2009 :4525 – 4529.

[ 9 ] Yoshizoe K ,Kishimoto A ,Müller M. Lambda depth-first proof number search and its application to go [ C ]// *20th International Joint Conference on Artificial Intelligence*. San Francisco :Morgan Kaufmann 2007 :2404 – 2409.