

脑电信号中肌电伪差的实时去除方法研究

高军峰, 郑崇勋, 王沛

(西安交通大学生命科学与技术学院, 710049, 西安)

摘要: 为了在线去除脑电信号中的肌电伪差, 使用典型相关分析方法, 分析了大量被肌电干扰和未被干扰的脑电(EEG)信号, 得出了一个合理的自相关阈值. 在时域上, 肌电伪差和一般的噪声信号比较类似, 有比较小的自相关值, 在去除肌电伪差时, 凡自相关值低于此值的分解成分被识别为肌电伪差. 该方法很好地利用了这个特点, 将肌电伪差分量与潜在大脑信号分离, 然后依据剩下的分解成分重建“干净”的 EEG 信号. 实验结果表明, 典型相关分析法在去除肌电伪差时优于独立成分分析法, 结合提出的自相关阈值在有效去除肌电伪差的同时, 又能较好地保持潜在的大脑信号不变.

关键词: 典型相关分析; 独立成分分析; 脑电; 肌电; 伪差去除

中图分类号: R318 **文献标志码:** A **文章编号:** 0253-987X(2010)04-0114-05

Electromyography Artifact Removal from Electroencephalogram
in Real-Time

GAO Junfeng, ZHENG Chongxun, WANG Pei

(School of Life Sciences and Technology, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To remove electromyography (EMG) artifacts from electroencephalogram (EEG) signals real-time, canonical correlation analysis (CCA) is adopted. By analyzing a number of ‘clean’ and contaminated electroencephalogram (EEG) signals using CCA, a reasonable correlation threshold is obtained. The EMG artifacts are similar to the common noise in time domain. Hence, the EMG artifacts components obtained by CCA have relatively lower correlation than non-EMG artifacts. When CCA is used to remove EMG artifacts from EEG signals, the components whose correlation value is lower than the threshold are identified as EMG artifacts, and then the ‘clean’ EEG signals can be reconstructed by the remnant components. The experimental results show that CCA outperforms ICA for removing EMG artifacts. Moreover, combining with the presented threshold, CCA enables to effectively remove EMG artifacts with little distortion of the underlying brain activity signals in real-time.

Keywords: canonical correlation analysis; independent component analysis; EEG; EMG; artifacts removal

脑电(EEG)信号是大脑神经细胞的电生理活动在头皮层的反映, 它的研究对于大脑思维开发和临床诊断具有重要意义. EEG 信号通常混合有各种伪差的干扰, 比如肌电(EMG)和心电, 这些伪差信号的幅度通常是 EEG 信号的几倍甚至几十倍, 而且两者的频域内容往往也混叠在一起, 因此伪差干扰严重影响了 EEG 信号的解释. 最简单的伪差去除方法是离线观察被伪差干扰的信号段, 然后予以去除, 可是对于被频繁干扰的 EEG 信号而言, 该方法会损失大量的 EEG 信号. 近年来, 很多现代信号处理方法都被应用到了脑电伪差的去除中.

基于回归的方法^[1]大都应用于离线分析, 而且

都需要一个可信赖的参考通道.一方面合适的肌电参考通道很难取得;另一方面,由于肌电通道中难免混合了大脑信号,因此回归方法会使得部分大脑潜在信号丢失,从而导致 EEG 信号的错误解释.

近年来,很多作者尝试使用独立成分分析(ICA)方法去除 EEG 信号的伪差,例如文献[2]首先利用 ICA 方法分解 EEG 信号,抽取独立分量的典型特征后,结合流形学习算法进行降维,最后使用支持向量机自动识别眼电伪差分量.总的来说,尤其是在自动伪差去除环境中,肌电伪差比眼电伪差更难去除[3].因为在 ICA 分解 EEG 信号后,研究人员发现,肌电伪差会嵌入到更多的独立分量中[4].比如 Makeig 等[5]指出,ICA 用于眼电伪差的去除效果比较好,而 EEG 信号和肌电伪差在独立分量上混合严重,所以很难将肌电伪差从其他独立分量中分离出来.因此,除非去除比较多的混合有肌电伪差的独立分量,否则肌电伪差很难去除干净,显然这样的操作又会导致大脑信号损失.

以前,少数作者已将典型相关分析(CCA)用于去除肌电伪差[6],不过这些研究都是在离线环境中进行的.对于很多在线的脑电研究,比如在线 BCI 系统的左右手想象运动分析,迫切需要分析系统本身同时具有实时去除伪差的功能.本文对比分析了 ICA 和 CCA 的去除肌电伪差的效果,通过分析大量的 EEG 信号,得到了一个合理的自相关阈值,在 EEG 信号通过 CCA 分解以后,通过该阈值,伪差去除系统可以自动地识别肌电伪差分量,从而可以实时地去除肌电伪差,重建“干净”的 EEG 信号.

1 研究方法

1.1 ICA 原理

ICA 是近年来发展起来的一种多通道盲源分离算法,其基本思想是将观测信号按统计独立原则分解为若干独立信号源成分[7]并引入一个混合矩阵,将观测信号看作是独立的源成分和混合矩阵的线性混合.近年来,很多研究人员都论证了使用 ICA 方法去除伪差,特别是用于去除眼电伪差的有效性[8].该方法不需要专门的 EOG 采集通道,但是通常需要有经验的神经生理专家通过观察独立成分的某些特征,比如功率谱和地形图特征[9],因此一般较难自动地去除伪差,从而限制了此方法的临床使用.

1.2 CCA 原理

CCA 方法[10]的基本原理是在分解信号源时,假定潜在信号源互不相关,同时使得各个信号源最

大自相关,并按照分解的信号源的自相关值进行降序排序.

设 $\mathbf{X}(t)$ 为观测信号,另 $\mathbf{Y}(t)=\mathbf{X}(t-k)$ (本文取 $k=1$).再设一对变量 $u=\mathbf{W}_x^T\mathbf{X}$ 和 $v=\mathbf{W}_y^T\mathbf{Y}$, u 和 v 被称作典型变量,它们的互相关被定义如下

$$\rho(u,v)=\frac{E[uv]}{(E[u^2]E[v^2])^{1/2}}=\frac{\mathbf{W}_x^T\mathbf{C}_{xy}\mathbf{W}_y}{\mathbf{W}_x^T\mathbf{C}_{xx}\mathbf{W}_x(\mathbf{W}_y^T\mathbf{C}_{yy}\mathbf{W}_y)^{1/2}} \tag{1}$$

通过分析可以得知, u 即 v 的延迟信号. CCA 方法可以通过最大化 ρ 值发现一对 $\mathbf{W}_x$ 和 $\mathbf{W}_y$,这个最大化问题可以通过以下方程的特征值分解来求解

$$\left. \begin{aligned} \mathbf{C}_{xx}^{-1}\mathbf{C}_{xy}\mathbf{C}_{yy}^{-1}\mathbf{C}_{yx}\mathbf{W}_x &= \rho^2\mathbf{W}_x \\ \mathbf{C}_{yy}^{-1}\mathbf{C}_{yx}\mathbf{C}_{xx}^{-1}\mathbf{C}_{xy}\mathbf{W}_y &= \rho^2\mathbf{W}_y \end{aligned} \right\} \tag{2}$$

求解出所有特征值后,将它们按照从大到小的顺序排序,算法结果是所有特征值对应的每一对 u 和 v 变量的相关最大.

将 CCA 方法用于去除 EEG 信号的伪差时,是利用伪差信号在时域上有着普通噪声信号的特点,因此伪差信号与其自身的延迟信号之间也应该具有比较小的互相关值,或者简单认为伪差信号具有较小的自相关值.基于此项假定,我们将具有较小自相关值的分解分量看作肌电伪差,然后将它们设置为 0,最后依据剩下的分量重建 EEG 信号,即可得到去除伪差后的“干净”的 EEG 信号.

1.3 阈值分析过程

基于上述分析可以得知,使用 CCA 方法在线去除肌电伪差的关键是确定合适的自相关阈值.若某分解分量的自相关值低于此阈值,就将其设置为肌电伪差,否则被看作是潜在的大脑信号.本文首先应用 CCA 方法分解大量的未受肌电干扰的 EEG 信号,观察并记录这些分解分量的自相关值的最小值,从而得到潜在大脑信号的自相关最低值的分布情况;然后采用 CCA 方法分解被肌电干扰的 EEG 信号,类似地记录这些分解分量的自相关最低值的分布情况;最后通过对比两个信号的分布情况,分析肌电伪差所对应的合理的自相关值,并将该值作为识别肌电伪差分量的阈值.

2 数据采集与处理

2.1 大脑活动 EEG 信号采集

实验挑选了 15 个健康的本校研究生作为受试者,平均年龄 24 岁.电极放置在如下 16 个位置: Fp1, Fp2, F3, Fz, F4, T7, C3, Cz, C4, T8, P3, Pz,

P4,O1,Oz,O2. 采样频率为 250 Hz. 要求试验者平静端坐,可以自由思考,但是尽量不要产生任何肌电伪差. 每人实验时间 3 s,实验结束后可得到 15 个 16×750 维矩阵 $\mathbf{B}$.

2.2 EMG 干扰的 EEG 信号采集

采用同样实验设置,上述受试者做 2 个实验,要求每 3 s 发出一次咬牙和皱眉的动作. 每个实验持续 30 s. 采集的 EEG 数据被 EEGLAB 工具箱^[11]分割为 3 s 的数据段,最后可以得到 300 个 16×750 维矩阵 $\mathbf{K}$.

2.3 合成 EEG 数据

使用 EEGLAB 工具箱中的扩展信息极大化算法(一种典型的 ICA 算法)将上述 300 个矩阵 $\mathbf{K}$ 分解为对应的独立成分. 将分解结果交给一个有经验的神经生理专家,他根据分解的独立分量的特征,比如地形图、功率谱和时域特征,挑选出了 100 个具有典型的肌电特征的分量^[9],然后将每个分量乘以它的头皮分布(该分量对应的混合矩阵的一列),最后得到 100 个 16×750 维分布矩阵 $\mathbf{M}$,它们代表了肌电伪差对头皮的 EEG 信号的分布影响. 挑选出任意一个矩阵 $\mathbf{M}$ 和 2.1 节所述的任意一个矩阵 $\mathbf{B}$,按照下式合成

$$\mathbf{B}_{\text{syn}}(\lambda) = \mathbf{B} + \lambda \mathbf{M} \tag{3}$$

设 R 表示信号的均方根,通过 λ 可改变信噪比

$$S = R(\mathbf{B})/R(\lambda \cdot \mathbf{M}) \tag{4}$$

对于信号 $\mathbf{B}_{\text{syn}}(\lambda)$,使用相应的去伪差方法去除信号中的肌电干扰,重建信号 $\mathbf{B}$. 设 $\hat{\mathbf{B}}$ 代表对信号 $\mathbf{B}$ 的估计(即重建),则通过指标 ϵ 可以评价重建效果,定义该指标如下

$$\epsilon(\mathbf{B},\hat{\mathbf{B}}) = \frac{R(\mathbf{B}-\hat{\mathbf{B}})}{R(\mathbf{B})} \tag{5}$$


3 结 果

3.1 伪差去除结果


当 $\lambda=1$ 时,将式(3)合成的信号 $\mathbf{B}_{\text{syn}}(\lambda)$ 显示在图 1a 中. 采用 CCA 分解该信号,去除了自相关值小于 0.35 的 3 个分量,重建的 EEG 显示在图 1b 中. 从该图可以看出,肌电伪差已被基本去除,尤其是在 FP1、FP2、F3、Fz 和 F4 电极上,伪差去除前后的 EEG 信号的区别最为明显.

为了对比 CCA 和 ICA 两种方法对于去除 EEG 信号伪差的表现,令信噪比 S 从 0.1 到 3 变化,并按照式(3)的规则合成 EEG 信号. 首先使用 CCA 方法去除合成信号中的肌电伪差,重建信号 $\mathbf{B}$;类似地,


使用 ICA 方法去除肌电伪差独立分量,即通过专家观察前述的各种特征^[9],然后重建信号 $\mathbf{B}$;最后根据式(5),可以得到两个方法的各个 S 对应的 ϵ ,对应函数曲线显示在图 1c 中. 图 1c 显示,应用 CCA 方法时,各个 S 对应的 ϵ 都低于使用 ICA 方法的 ϵ ,说明 CCA 方法去除肌电伪差的效果明显好于 ICA 方法.



(a) $\lambda=1$ 时合成脑电信号 $\mathbf{B}_{\text{syn}}(\lambda)$



(b) 采用 CCA 方法去除 $\mathbf{B}_{\text{syn}}(\lambda)$ 中的伪差得到的 EEG 信号



(c) 采用 CCA 和 ICA 方法去除肌电伪差的重建效果对比


图 1 CCA 和 ICA 方法的伪差去除结果对比

3.2 阈值分析结果与在线实现


将 2.2 节的 100 个矩阵 M 和 15 个矩阵 B 按照式(5)合成为 1 500 个 $B_{syn}(\lambda)$ 信号, 然后使用 CCA 方法在不同的自相关阈值下恢复重建大脑潜在信号 B , 计算不同阈值下的 1 500 个 ϵ , 结果如图 2a 所示. 可以看出, 当阈值为 0.35、0.40 和 0.45 时, ϵ 的均值和标准差都较低, 表明肌电伪差基本去除干净. 遗憾的是, 当再次对 3 个阈值(0.35、0.40 和 0.45)的 ϵ 进行配对 t 检验分析后, 结果表明他们之间的 ϵ 值没有显著差异.

除了评价伪差去除是否彻底, 大脑潜在信号是否受到损失也是伪差去除的一个重要评价指标. 因此, 15 个受试者按照 2.1 节的要求做了 2 min 的实验. 实验得到的 EEG 信号基本可以代表正常健康受试者的未干扰 EEG 信号, 将 3 s 作为一个分段数据集, 使用 CCA 方法分解这些数据集, 然后挑出每组 16 个分解成分的最小自相关值, 以每个受试者作为分组, 自相关值的均值和标准差的结果显示在图 2b 中. 从该图可以看出, 绝大部分的大脑潜在信号的最小自相关值大于 0.35.

综合图 2 的分析结果可以看出, 选取 0.35 作为自相关的阈值时, 除了可以重建更“干净”的 EEG 信号, 更为重要的是, 潜在大脑信号的损失也能降到最低程度, 从而实现较佳的伪差去除效果.



(a)取不同自相关阈值时的重建效果



(b)未污染 EEG 信号分解成分的最小自相关值

图 2 阈值分析结果

实际在线去除肌电伪差时, 每采集 3 s 的 EEG 数据后, 进行一次伪差处理. 对于 BCI 系统, 如果一个抽样块是 50 个抽样点(对应的抽样时间是 200 ms), 则每次去除伪差后, 对上次 3 s 的 EEG 数据更新 50 个抽样点的数据, 然后进行新的伪差去除. 通过测试, CCA 方法的伪差去除时间基本控制在 50 ms 以内, 因此提出的方法在时间上完全满足在线应用的要求.

4 讨论

本文对比了 ICA 和 CCA 方法去除肌电伪差的效果, 证明了无论是弱肌电干扰(由于眼动和眨眼引起的肌电干扰)还是强肌电干扰(由于咬牙引起的肌电干扰), CCA 方法的表现均优于 ICA 方法.

ICA 方法假定各个分解的源信号之间互相独立, 在去除伪差时, 能够将地形图固定的伪差分量(例如眼电伪差)很好地分离出来. 但是, 肌电伪差通常包含了比较多的肌肉群的运动, 并没有固定的地形图模式. 更为重要的是, 在肌电伪差强度比较大时, 肌电伪差分量与潜在大脑信号分量混合严重, 此时 ICA 方法分离效果比较差. CCA 方法假定各个分解的源信号之间互不相关, 而且以它们的自相关最大为分解目标. 在时域上肌电伪差和一般的噪声信号比较类似, 即有比较小的自相关值, 在去除肌电伪差时, 可以很好地利用这个特点, 将肌电伪差分量与潜在大脑信号分离. 另外, 实验发现肌电伪差越严重, CCA 方法能发现自相关值越小的分解成分, 显然在此种情况下, 比起 ICA 方法, 更容易分解出伪差分量, 这应该是在强肌电干扰情况下去除肌电伪差时 CCA 方法仍优于 ICA 方法的原因.

将 CCA 方法用于在线环境的关键是研究合适的自相关阈值. 本文将 CCA 方法应用在大量的“干净”的和“污染”的 EEG 信号上, 统计分析了合理的自相关阈值. 实验结果显示, 通过此阈值, 伪差去除系统可以自动去除肌电伪差, 重建“干净”的 EEG 信号, 同时可以保证潜在的大脑信号基本不被破坏.

值得指出的是, 使用时的前提假设条件也许是导致 CCA 方法在去除肌电伪差时效果还不够理想的原因之一, 如何完善该方法的使用也值得进一步探讨.

由于眼电伪差和肌电伪差的特点不同, 使得本方法的使用并不受眼电伪差的影响, 这就为进一步提出一个鲁棒的、全面的伪差去除系统提供了可能, 比如将 CCA 方法首先用于去除肌电, 然后使用去

除眼电伪差效果比较好的方法进一步去除眼电伪差干扰,这也是今后的研究内容之一。

参考文献:

- [1] GRATTON G, COLES M G, DONCHIN E. A new method for off-line removal of ocular artifact[J]. Electroencephalography & Clinical Neurophysiology, 1983, 55(4): 486-484.
 - [2] 高军峰, 郑崇勋, 王沛. 基于独立成分分析和流形学习的眼电伪差去除[J]. 西安交通大学学报, 2010, 44(2): 113-118.
GAO Junfeng, ZHENG Chongxun, WANG Pei. ICA and manifold-based ocular artifacts removal[J]. Journal of Xi'an Jiaotong University, 2010, 44(2): 113-118.
 - [3] URRESTARAZU E, IRIARTE J, ALEGRE M, et al. Independent component analysis removing artifacts in ictal recordings [J]. Epilepsia, 2004, 45(9): 1071-1078.
 - [4] AMARI S, CICHOCKI A, YANG H H. A new learning algorithm for blind signal separation [M]. Cambridge, MA, USA: MIT Press, 1996: 757-763.
 - [5] MAKEIG S, BELL A J, JUNG T P, et al. Independent component analysis of electroencephalographic data [M]. Cambridge, MA, USA: MIT Press, 1996: 145-151.
 - [6] VERGULT A, CLERCQ W D, PALMINI A, et al. Improving the interpretation of ictal scalp EEG: BSS-CCA algorithm for muscle artifact removal [J]. Epilepsia, 2007, 48(5): 950-958.
 - [7] 周仲兴, 明东, 朱誉环, 等. 基于扩展 Informax ICA 的站起想象动作脑电特征提取[J]. 仪器仪表学报, 2009, 30(3): 459-464.
ZHOU Zhongxing, MING Dong, ZHU Yuhuan, et al. EEG feature extraction for imaginary standing up based on extended Informax independent component analysis[J]. Chinese Journal of Scientific Instrument, 2009, 30(3): 459-464.
 - [8] SHAO Shiyun, SHEN Kaiquan, ONG C J, et al. Automatic EEG artifact removal: a weighted support vector machine approach with error correction [J]. IEEE Transactions on Biomedical Engineering, 2009, 56(2): 336-344.
 - [9] JUNG T P, MAKEIG S, HUMPHRIES C et al. Removing electroencephalographic artifacts by blind source separation [J]. Psychophysiology, 2000, 37: 163-178.
 - [10] CLERCQ W D, VERGULT A, VANRUMSTE B, et al. Canonical correlation analysis applied to remove muscle artifacts from the electroencephalogram [J]. IEEE Transactions on Biomedical Engineering, 2006, 53(12): 2583-2587.
 - [11] DELORME A, MAKEIG S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis [J]. Journal of Neuroscience Methods, 2004, 134(1): 9-21.
- (编辑 杜秀杰)
-
- (上接第 51 页)
- [12] HE Xiaofei, CAI Deng, NIYOGI P. Tensor subspace analysis [M] // Advance in Neural Information Processing System 18. Cambridge, MA, USA: MIT, 2006: 249-256.
 - [13] TAO Dacheng, LI Xuehong, WU Xindong, et al. General tensor discriminant analysis and Gabor features for gait recognition [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2007, 29(10): 1700-1715.
 - [14] 王峰, 刑科义, 徐小平. 系统辩识的粒子群优化方法 [J]. 西安交通大学学报, 2009, 43(2): 116-120.
WANG Feng, XING Keyi, XU Xiaoping. A system identification method using particle swarm optimization [J]. Journal of Xi'an Jiaotong University, 2009, 43(2): 116-120.
- (编辑 苗凌)