

低密度脑电自适应去噪方法

陈贺^{1,2}, 张昊¹, 柴一帆¹, 李小俚¹

(1. 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; 2. 北京师范大学系统科学学院, 北京 100875)

摘要: 便携式和可穿戴设备的低密度脑电图更便于实际使用, 但会受到多种不可预知的噪声影响, 给去噪带来极大的困难。脑活动成分较为相似, 在特征空间分布较为紧密, 而噪声成分与脑电成分不同, 差异性大, 在特征空间分布较为分散。本文提出了一种低密度脑电自适应去噪方法, 采用小波分解和盲源分离方法提取潜在成分, 并基于脑电和噪声成分在特征空间的分布特性, 采用单类支持向量机识别并去除远离成分分布中心的异常成分。仿真数据的定量分析结果表明, 提出的方法在肌电、眼电和工频等噪声抑制方面均优于现有方法; 通过对真实脑电数据的成分簇可视化分析, 直观展示了低密度脑电噪声有效去除的原因。结合盲源分离和异常检测的思路进行低密度脑电去噪, 不需要设定特定噪声相关的特征参数, 能够自适应地去除多种类型噪声同时有效保留脑活动成分, 具有优良的性能和实用性。

关键词: 低密度脑电; 异常检测; 去噪; 盲源分离; 聚类

中图分类号: R318 **文献标志码:** A

An Adaptive Denoising Algorithm for Few-Channel EEG

CHEN He^{1,2}, ZHANG Hao¹, CHAI Yifan¹, LI Xiaoli¹

(1. State Key Laboratory of Cognitive Neuroscience and Learning, Beijing Normal University, Beijing 100875, China; 2. School of Systems Science, Beijing Normal University, Beijing 100875, China)

Abstract: Few-channel electroencephalogram (EEG) is more suitable and affordable for practical use as a portable or wearable device, but it is subject to a variety of unpredictable artifacts, making removal of artifacts extremely difficult. In the feature space, the artifact-related components are dispersed while the components related to brain activities are closely distributed. We propose an outlier detection-based method for artifact removal under the few-channel condition. The underlying components (sources) are extracted using wavelet decomposition and blind source separation methods, and the artifact-related components far from the center of distribution of all components are considered as outliers and are identified using one-class support vector machine. In the quantitative analyses with semi-simulated data, the proposed method outperforms the threshold-based methods for various artifacts, including EMG, electro-oculogram (EOG) and power line noise. The visualization of the clusters of components demonstrates the effectiveness of the hypothesis. This study innovatively combines the ideas of blind source separation and outlier detection, without setting artifact-specific parameters, and is capable of adaptively removing various artifacts while effectively retaining brain activities, showing excellent performance and usability.

Key words: few-channel EEG; outlier detection; artifact removal; blind source separation; cluster

引 言

脑电(Electroencephalogram, EEG)测量神经元群体活动的同步电活动^[1],具有时间分辨率高、成本低、无创等优点,已被广泛用于神经系统疾病的诊断^[2-3]、脑机接口^[4-6]、神经反馈^[7-8]等。脑电的缺点是很容易被各种噪声污染,包括电生理噪声,如眼电(Electro-oculogram, EOG)、肌电(Electromyogram, EMG),以及机械振动和工频噪声^[9]等。便携式和可穿戴设备的低密度脑电图(3~8通道)更便于实际使用,但会受到多种不可预知的噪声影响,给去噪带来了极大的困难,一直是脑电技术应用的瓶颈问题。

盲源分离(Blind source separation, BSS)从混合的脑电信号中提取潜在的源成分,包括脑活动和噪声成分,常用方法包括独立成分分析(Independent component analysis, ICA)和典型相关分析(Canonical correlation analysis, CCA)。各种与噪声相关的IC可以根据其频率和头皮分布特性进行识别,典型的方法包括ICLabel^[10]、MARA^[11]。与ICA相比,CCA方法的约束条件更弱,但运算速度快并且输出确定性结果。目前基于自相关系数阈值的CCA方法多应用于去除肌电噪声^[12-13];然而,如Janani等^[14]研究显示,模拟脑活动分量的自相关系数在0.4~1之间变化,如果阈值CCA方法拒绝低于0.4以下的成分,将过度去除有效脑电成分;此外,工频噪声的自相关值在0.8以上,无法通过设定阈值去除。

由于低密度脑电不能满足BSS方法分解条件,因此BSS方法不适合低密度脑电的噪声去除。为此,现有研究常采用信号分解方法来满足BSS方法对脑电通道数量的要求,如小波分解^[15]、变分模态分解^[16]、经验模式分解(Empirical mode decomposition, EMD)^[17]和多变量经验模式分解(Multivariate EMD, MEMD)^[12]。分解-盲源分离(DEC-BSS)是目前常用的脑电去噪方案,已有多种技术方法的组合,包括EMD-ICA^[18]、MEMD-CCA^[19]、小波分解-ICA^[20]以及小波分解-CCA^[21]等。然而,大多数是基于阈值的识别和剔除噪声,导致对脑电过度抑制,且可能无法去除特定的噪声^[13]。

综上所述,低密度脑电更便于实际使用,但会受到各种噪声的影响,去噪较为困难,而目前常见的DEC-BSS去噪方案的参数设定复杂,有效性较低。因此,本文提出了一种基于异常检测的低密度脑电自适应去噪方法。

1 基于异常检测的低密度脑电自适应去噪方法

实践发现:不同脑电活动之间差异不大,多个与脑电活动相关的成分分布紧密;大部分噪声与脑电活动之间差异显著,在特征空间上噪声成分与脑电成分分布分散;不同噪声之间也存在较大的差异,如肌电噪声与工频噪声,多种噪声相关的成分在特征空间上也呈现分散分布。本文提出一种基于异常检测的脑电去噪方法,称为MRA-CCA-OD,方法的完整流程如图1所示,包含4个步骤:信号分解与盲源分离、特征提取、异常源成分检测和信号重建。其中信号分解部分采用多分辨率分析将低密度脑电分

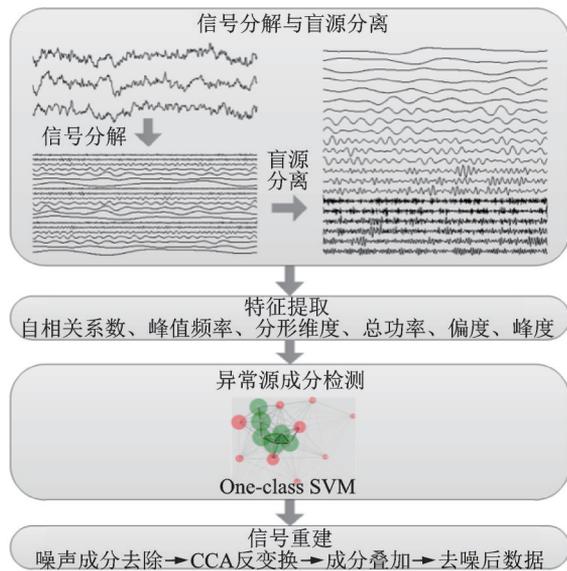


图1 MRA-CCA-OD方法流程

Fig.1 Workflow of MRA-CCA-OD

解为各个子频带成分,并采用CCA方法计算源成分;特征提取部分提取每个成分的多个特征;异常检测部分采用基于径向基函数的单类支持向量机识别异常成分;信号重建则在去除噪声成分后,对上述步骤进行反变换,获得去噪后的干净脑电。

信号分解部分,本方法提出采用基于小波分解的多分辨率分析,来替换常用的MEMD,以加快海量信号的处理。现有研究主要使用MEMD对少通道脑电进行分解。但主要局限是时域迭代计算的计算成本很高。启发于MEMD二元滤波器组的性质^[22],离散小波变换可用于信号分解,同时为保持平移不变性,最大重叠小波变换的多分辨率分析(Maximal overlap wavelet transform based multi-resolution analysis, MODWTMRA)用于分解脑电数据。在离散小波变换(Discrete wavelet transform, DWT)中,使 $\{h_{j,l}; l=0, 1, \dots, L-1\}$ 和 $\{g_{j,l}; l=0, 1, \dots, L-1\}$ 为第 j 层的长度为 L 的小波和尺度滤波器,信号 X 通过这两个滤波器产生近似和细节系数,随后进行2进制降采样并进入下一层的计算中。但是由于降采样操作导致DWT并不是平移不变的,而最大重叠小波变换(Maximal overlap wavelet transform, MODWT)^[23-24]则表现出平移不变性,且能够保持分解系数与输入数据的同等长度。MODWT的小波和尺度滤波器定义为DWT滤波器的归一化

$$\tilde{h}_{j,l} = \frac{h_{j,l}}{2^{\frac{j}{2}}}, \quad \tilde{g}_{j,l} = \frac{g_{j,l}}{2^{\frac{j}{2}}} \quad (1)$$

在第 j_0 层的DWT要求信号长度必须为2的幂次,而MODWT则对于任意长度数据都适用,具有适合多种长度脑电数据的优势。第 j_0 层包含了 j_0+1 个向量 $\tilde{W}_1, \tilde{W}_2, \dots, \tilde{W}_{j_0}$ 和 \tilde{V}_{j_0} ,并且均为输入数据的长度 N 。当 N 等于2的幂次(及其整数倍)时,可以得到

$$\tilde{W}_{j,t} = \sum_{l=0}^{L_j-1} \tilde{h}_{j,l} X_{\text{mod}(t-l, N)}, \quad \tilde{V}_{j,t} = \sum_{l=0}^{L_j-1} \tilde{g}_{j,l} X_{\text{mod}(t-l, N)} \quad (2)$$

其中,若 $j_0 \geq 1$ 和 $N \geq 1$,则 $\|X\|^2 = \sum_{j=1}^{j_0} \|\tilde{W}_j\|^2 + \|\tilde{V}_{j_0}\|^2$ 。上述公式写作矩阵的形式,即 $\tilde{W}_j = \tilde{\mathcal{W}}_j X$,其

中 $\tilde{\mathcal{W}}_j$ 为 $N \times N$ 的矩阵,那么反变换 $\tilde{\mathcal{D}}_j = \tilde{\mathcal{W}}_j^T \tilde{W}_j$ 和 $\tilde{\mathcal{S}}_j = \tilde{\mathcal{V}}_j^T \tilde{V}_j$ 可以得到细节系数 $\tilde{\mathcal{D}}_j$ 和近似系数 $\tilde{\mathcal{S}}_{j_0}$ 。最终,输入信号 X 在第 j_0 层的多分辨率分析(MODWTMRA)为

$$X = \sum_{j=1}^{j_0} \tilde{\mathcal{D}}_j + \tilde{\mathcal{S}}_{j_0} \quad (3)$$

值得注意的是,MODWTMRA是信号的零相位滤波,也就是说 $\tilde{\mathcal{D}}_j$ 和 $\tilde{\mathcal{S}}_{j_0}$ 与输入信号是时间对齐的。

在本方法中,考虑到噪声去除和脑活动重建的时频定位需求,选用Symlets(消失矩为4)作为小波母函数^[25-27];MODWTMRA分解层数为最接近 $\log_2(N)$ 的整数, N 为信号长度。MODWTMRA将单通道脑电时间序列分解为多层细节系数和近似系数,从而完成脑电时间序列通道数的提升。相较于时域迭代分解的MEMD,采用式(2)进行频谱分解的MODWTMRA方法具有明显的性能优势,并且可以根据信号时频特征选择合适的母函数及分解层级,更为灵活。

盲源分离部分,相较于ICA等方法,CCA采用矩阵运算,分解速度要快一个数量级以上,并且输出的结果是确定性的,能够进一步保证结果的稳定性。CCA采用二阶统计(Second-order statistics, SOS),使得变换后对应位置变量互相关性最大化,而不同位置间变量互相关性最小。设 $S_x =$

(x_1, x_2, \dots, x_n) 及 $S_y = (y_1, y_2, \dots, y_n)$ 。CCA 计算 w_x 和 w_y , 使得相关性最大化, 即 $\rho = \max_{w_x, w_y} \text{corr}(S_x w_x, S_y w_y)$ 。 ρ 也可以写为

$$\rho = \frac{w_x^T C_{xy} w_y^T}{\sqrt{w_x^T C_{xx} w_x w_y^T C_{yy} w_y}} \quad (4)$$

式中: C_{xx} 和 C_{yy} 分别为组内方差; C_{xy} 为组间协方差矩阵。当式(4)中对 w_x 和 w_y 导数为零时, 得到 ρ 的最大值, 此时

$$\begin{aligned} C_{xx}^{-1} C_{xy} C_{yy}^{-1} C_{yx}^T \hat{w}_x &= \rho^2 \hat{w}_x \\ C_{yy}^{-1} C_{yx} C_{xx}^{-1} C_{xy}^T \hat{w}_y &= \rho^2 \hat{w}_y \end{aligned} \quad (5)$$

通过计算 $C_{xx}^{-1} C_{xy} C_{yy}^{-1} C_{yx}^T$ 和 $C_{yy}^{-1} C_{yx} C_{xx}^{-1} C_{xy}^T$ 的特征向量, 得到 w_x 和 w_y 作为混合矩阵; 其特征值 ρ^2 按照递减的顺序排列, 是互相关性的平方^[28]。在本研究中, 使用 MODWTMRA 将脑电信号分解为子频段时间序列, 将分解后的子频带成分及其延迟 1 个点的成分作为输入进行 CCA 分析, 即可提取到最大化自相关、最小化互相关的潜在信号源成分。

特征提取部分, 为构造一个合理的特征空间, 以同时容纳脑活动成分和噪声成分, 并突出噪声识别和去除的合理性, 本方法选择了噪声和脑活动所共有的特征, 或者有明确的证据表明有特定的来源特征, 共计 6 种: 自相关系数、总功率、分形维度、偏度、峰度以及峰值频率。自相关系数由 CCA 得到; 总功率定义为成分的平方和; 分形维度用于量化复杂度; 偏度和峰度在时域计算成分的分布特性; 峰值频率定义为成分功率谱达到最大值的频率点。

异常源成分检测部分, 采用核函数为径向基函数的单类支持向量机 (One-class support vector machine, OCSVM), 优势在于能够以较少参数实现非线性映射, 从而保证噪声成分与脑电成分在高位空间线性可分, 同时 OCSVM 相较于其他异常检测算法, 运行速度较快, 能够缓解本研究中源成分数据过多导致的运算速度问题。支持向量机 (Support vector machine, SVM) 是一种用于二元分类问题的监督机器学习算法^[29]。它构建了一个高维超平面 $w^T x + b = 0$, 这个超平面通过最大化超平面和支持向量 (离超平面最近的数据点) 之间的间隙将数据点分成两类, SVM 的优化目标为

$$\min_{w, b, \xi_i} \frac{\|w\|^2}{2} + C \sum_{i=1}^n \xi_i \quad (6)$$

式中: ξ_i 为松弛变量, C 为平衡参数, 两者用于允许少量支持向量落在决策平面边缘。当数据点在该空间中不可线性分离时, 采用核函数 $K(x, x_i) = \phi(x)^T \phi(x_i)$ 将有限维空间的数据映射到一个高维甚至是无限维的空间中, 在这个空间中, 数据点是可以线性分离的, 这样 SVM 就可以对这类数据进行分类, 而不需要明确计算在新空间中数据点的坐标^[30]。单类 SVM 试图构造一个最小的超平面, 这个平面集中了大部分的训练数据点, 而边界上的数据点是支持向量^[31]。

本研究中, 采用径向基函数作为核函数

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (7)$$

式中: $\|x - x'\|^2$ 度量了两个特征向量间的平方欧式距离, σ^2 为自由参数, 一般设置为特征的数量。本研究将 MRA-CCA 得到的成分特征输入 OCSVM, 根据对脑电数据中污染程度的初步估计, 异常成分的比例设置为 20%。此外, 为确保每个被拒绝的成分与噪声相关, 被拒绝的成分需满足以下条件之一: 成分的平均自相关维数或平均分形维度小于平均值, 平均偏度或平均峰度的绝对值大于平均值。

信号重建部分, 使用上述方法去除异常 CCA 源成分, 随后进行 CCA 反变换将信号还原至各个通道对应的多层细节系数和近似系数, 将每个通道的子频带时域波形进行累加即获得去噪后的少通道脑电

数据。

本方法中,采用小波分解和典型成分分析方法实现源成分的分离,并构造合理特征空间容纳脑活动和噪声成分,同时采用单类支持向量机识别和去除噪声成分,所选用方法均考虑到了低密度脑电成分的时频特性以及海量数据的运算速度需求,保证了本方法的性能和有效性;同时,本方法创新提出将盲源分离与异常检测算法结合,根据所有成分总体分布识别和去除远离分布中心的异常成分,不需设定特定噪声的参数阈值,单次过程可以自适应地去除多种噪声,保证了方法的实用性。

2 实验和分析

2.1 实验数据采集和生成

2.1.1 真实脑电数据

所有数据采集均经北京师范大学认知神经科学与学习国家重点实验室伦理委员会批准。招募了32名大学生或研究生(右利手,15名男性,年龄24~31岁)并签署了知情同意书。使用8通道脑电系统(Jielian Co. Ltd)进行数据采集,Ag/AgCl电极放置在8个位置:F3、F4、C3、C4、T3、T4、O1、O2,所有脑电通道均以C_z电极作为物理参考,阻抗保持在5 kΩ以下;两个水平眼电电极放置左眼和右眼的外眼角1 cm处;垂直眼电的两个电极放置在左眼上方1 cm和下方1 cm处。脑电和眼电均以1 kHz采样率和16位分辨率进行数字采样。

采集过程中,指导被试产生各种类型的噪声,包括眨眼、咀嚼、皱眉、眼球运动和头部运动。收集的脑电和眼电数据使用巴特沃兹滤波器(0.5 Hz,零相位)进行滤波。从发出指令的时间到之后2 s的时间,数据切分为2 s的数据段。基线数据也被切分为2 s的数据段,段之间没有重叠,选取每名被试前30段的静息数据。经过6个数据采集周期,收集了32名被试,每人360个数据段。

2.1.2 半仿真脑电数据

从第一个数据集中挑选了600段干净的数据作为基准,生成各种仿真噪声,以20%的概率随机添加至干净数据中,生成了半仿真脑电数据。噪信比(Noise-to-signal ratio, NSR)定义为噪声数据的均方根(Root mean square, RMS)与脑电数据的均方根之比。设置了4种噪声强度:NSR=1, 2, 4, 8。每段数据长为2 000点,MODWTMRA的level=10。

肌电噪声通过对白噪声进行随机20~60 Hz高通滤波生成^[32],产生了8个肌电源 S_{EMG} ,肌电污染的脑电数据: $EEG_{sim} = EEG_{clean} + A * S_{EMG}$,其中 A 代表肌电源在头皮的地形分布^[32],设置为0~1的随机值。为了进一步引入肌电源的空间结构,将 A 的随机的3列设置为0,使得每个独立的肌电源同时污染5个脑电通道。

脑电活动在头皮的传播途径不同,眼电对不同的脑电通道有不同的影响,传播因子为脑电和眼电之间的多重线性相关系数: $A_{corr} = \text{Corr}(EEG, EOG)$ 。从真实数据集中选取了600段眨眼数据,其中包括8个脑电通道和2个眼电通道。脑电和眼电经过了截止频率7.5 Hz的低通滤波^[33],使用最小二乘法计算多重相关系数 A_{corr} , $EOG_{sim} = A_{corr} * EOG$; EOG_{sim} 中有8个通道,表示从眼电通道到脑电所有通道传播的噪声,眼电污染数据可以模拟为 $EEG_{sim} = EEG_{clean} + EOG_{sim}$ 。

工频噪声使用50 Hz的正弦波来仿真,对每个脑电通道添加了相同的正弦波,每段数据中所添加的正弦波的起始相位是随机的。工频噪声可能是间断性的,为了测试提出的方法对非稳定的工频噪声的有效性,工频噪声随机两处长为0.2 s的段设置为0。

2.1.3 ERP数据

本研究采集持续表现任务(Continuous performance task, CPT)的脑电^[34],共招募了12名大学生或研究生(右手,6名男性,年龄在20~26岁)。使用Neuroscan Q-cap AgCl-62 cap(Neuroscan Inc., El

Paso, TX, USA)在62个头皮位置记录了脑电,所有的脑电通道物理参考设置为C_z电极,阻抗保持在5 kΩ以下。脑电62个通道都被重参考为平均参考,降采样至250 Hz。脑电数据根据刺激出现的前后1 000 ms切分为2 s的段,并进行z分数归一化,每名被试共采集440个数据段。

2.2 脑电和噪声成分分布可视化

真实脑电数据中包含多种噪声,为了验证特征空间中脑电信号成分分布规律,采用K-Means对所有成分聚类为20个簇,将两个簇的所有成分之间的欧氏距离平均作为簇间的距离,其分布如图2所示。每个簇的颜色表示该簇中被去除的成分的比例,圆圈的直径代表簇中成分数的对数,簇间连接线的宽度与簇间距离成反比,其中第2、3、6、8、12、13、15、16和20个簇的100%的成分被去除,第7个簇中57.44%的成分被去除。总体而言,脑电成分的分布更接近,被拒绝的噪声成分所形成的簇分布更为分散,而保留较多的脑电成分簇分布紧密。此外,被拒绝的簇中的成分数量较少,这也符合脑电中主要成分是脑活动的事实。

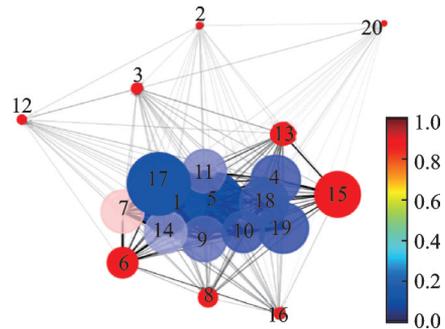


图2 脑电数据成分的聚类分布

Fig.2 Distribution of the clusters of EEG components

2.3 脑电去噪性能的量化分析

本文与现有的信号分解方法及噪声去除方法进行了对比分析。以往的研究^[12-13]认为自相关系数低于阈值的成分都是肌电成分,阈值一般

设置为0.6~0.9,本方法设置为0.8,并比较了4种去噪的方法:基于阈值的MEMD-CCA-thres、基于阈值的MRA-CCA-thres、基于异常检测的MEMD-CCA-OD和本文提出的方法MRA-CCA-OD。针对眼电去除,基于分形维度(Fractal dimension, FD)量化每个CCA成分复杂度^[35],并去除FD值低于阈值的眼电^[36-38]。由于实际FD值受数据的采样率和成分的滤波参数影响,很难为每个数据找到一个固定的阈值。本方法采用了Gómez-Herrero提出的自适应方法^[36],并与基于阈值的MRA-CCA-thres、基于FD阈值的MRA-CCA-FD和MRA-CCA-OD比较。工频去除主要采用48~52 Hz陷波的巴特沃兹滤波器(零相位,非因果),同时对比EEGLAB插件Cleanline^[39-40],带宽设置为4 Hz(频率中心50 Hz)。

对于半仿真脑电数据,使用相对均方根误差(Relative root mean squared error, RRMSE)来量化去噪误差。为了保证RRMSE值对噪声种类的特异性,将干净的脑电和去噪后重建的脑电滤波到相应的频率范围。对于肌电污染数据,干净的脑电和去噪后重建的脑电进行高通滤波,截止频率为20 Hz,同时进行带阻滤波,截止频率为48~52 Hz;对于眼电污染数据,两者进行低通滤波,截止频率为7.5 Hz;对于工频污染数据,两者进行带通滤波,截止频率为48~52 Hz。同时,比较去噪前后的每个通道的功率谱密度,展现去噪前后频率成分的变化,使用Welch's方法计算,频率分辨率为0.5 Hz。

2.3.1 肌电噪声

在半仿真脑电数据上,4种去噪方法在不同噪声强度条件下的RRMSE值如图3所示。当NSR≥4时,基于阈值的方法(MEMD-CCA-Thres和MRA-CCA-Thres)误差要小于基于异常检测的方法

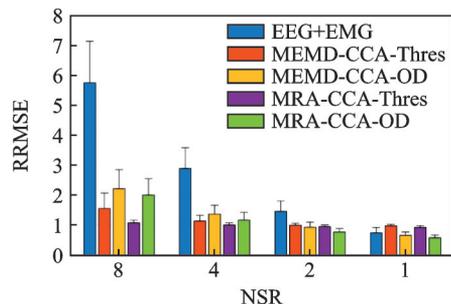


图3 在不同噪声强度条件下的4种肌电去噪方法的RRMSE值

Fig.3 RRMSE values of four methods for EMG artifact removal in different NSR conditions

(MEMD-CCA-OD和MRA-CCA-OD),而当肌电污染强度降低时($NSR=2$),基于异常检测的方法误差会降低,当 $NSR=1$ 时,基于阈值的方法甚至会引入其他的误差。

脑电数据中共有8个通道,所有通道噪声去除前后的功率谱平均值如图4所示。4种方法都能在一定程度上抑制肌电噪声,但是由于肌电噪声污染的频带较宽,基于异常检测的方法也无法完全去除所有肌电噪声,尤其是当污染强度较大时($NSR \geq 4$)。值得注意的是,基于阈值的方法过度去除了30 Hz以上的脑电活动,导致频域失真严重,这解释了图3中 $NSR=1$ 时基于阈值的方法所造成的更高的误差。

从图4中低频成分可以发现,基于异常检测的方法在去除肌电成分的同时,对眨眼活动也有所抑制,而基于阈值的方法无法去除眨眼活动。MRA-CCA-OD去噪后功率谱更接近于干净脑电,并且基于小波分解的MODWTMRA的计算要比MEMD快10倍以上。考虑到精度和计算效率,在后续分析中使用MODWTMRA进行信号分解。

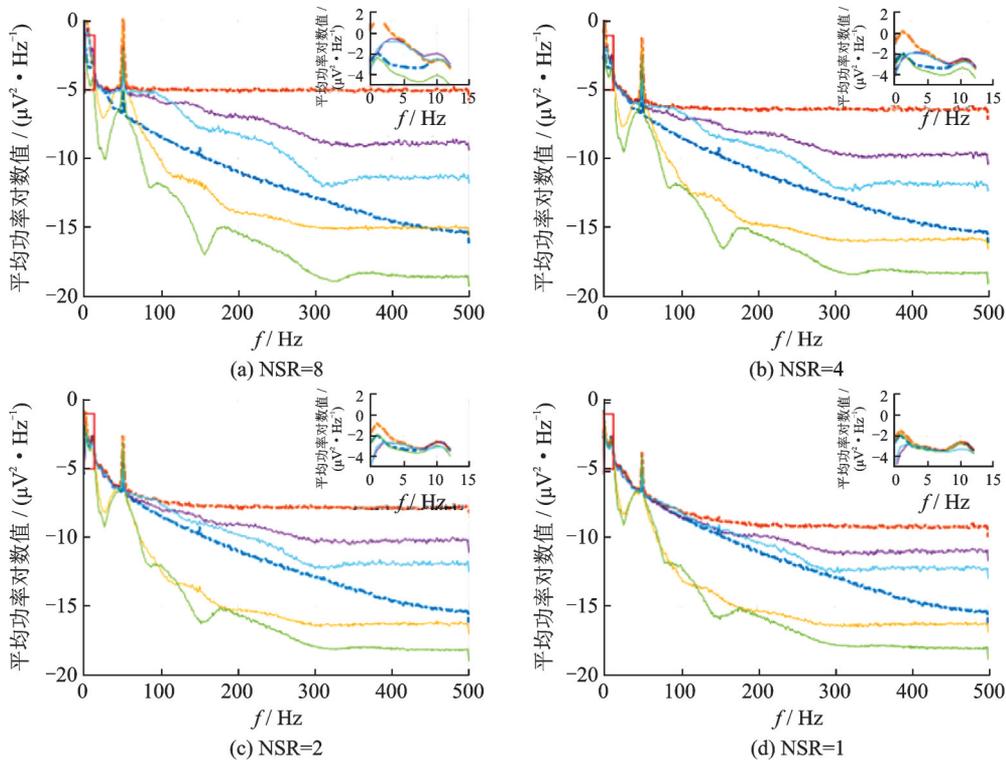


图4 脑电所有通道在去噪前后的平均功率谱(10 Hz以下的功率谱用红色矩形标记,并放大放置在每个子图的右上角)

Fig.4 Average PSDs of all EEG channels before and after EMG artifact removal (PSDs below 10 Hz are marked in red rectangle, and are emphasized at right-top of each subfigure)

2.3.2 眼电噪声

在不同眼电噪声强度条件下,4种去噪方法的RRMSE值如图5(a)所示。由于眼电相关成分具有较高的自相关值,基于自相关阈值的MRA-CCA-Thres几乎没有去除眼电噪声。其他两种方法在各种噪声强度条件下,能有效地去除了眼电噪声,当 $NSR \geq 2$ 时,基于FD的方法误差小于基于异常检测的方法。如图5(b)所示,由于眼电相关的成分和低频EEG活动都有较低的FD值,MRA-CCA-FD过度抑制了低频EEG活动,特别是在delta和theta频段(低于7 Hz)。作为对比,使用MRA-CCA-OD去除眼

电后,数据功率谱最接近于真实值,说明在去除大部分眼电相关成分的同时保留了实际的脑电活动。基于异常检测的自适应方法比使用FD阈值的方法,更有效地识别了眼电相关的成分。

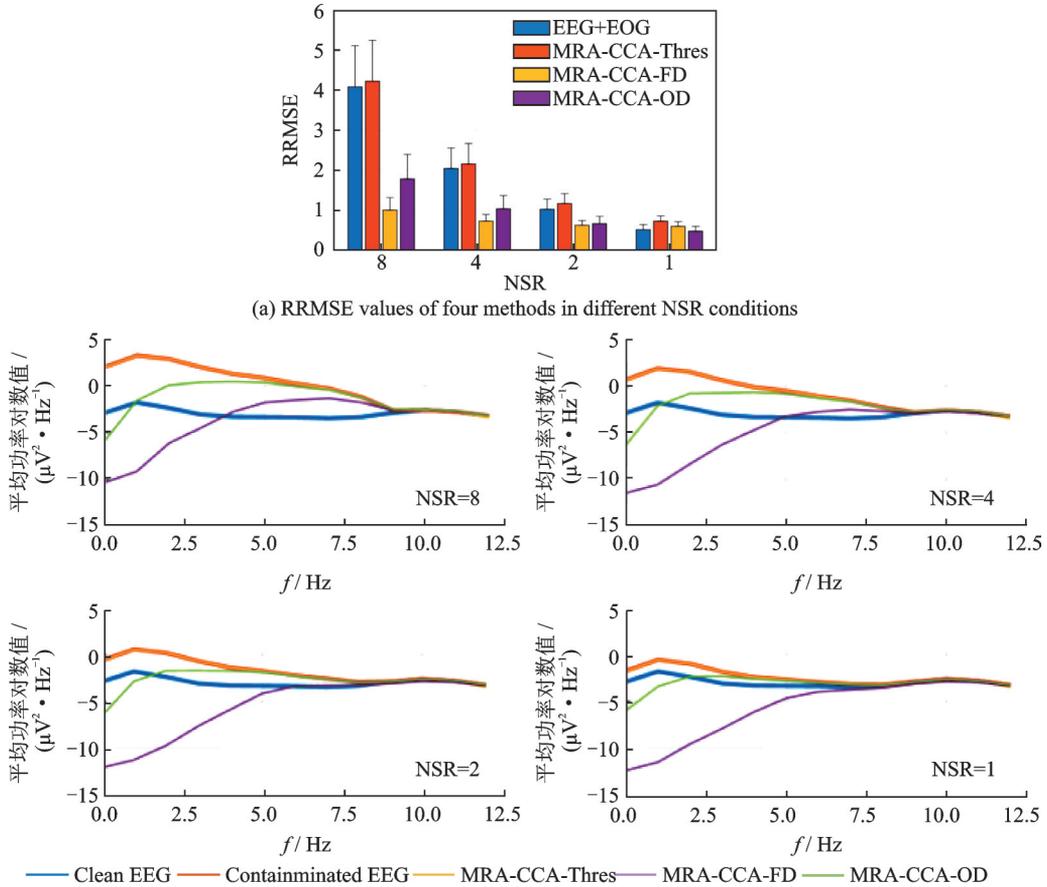


图5 不同方法对眼电噪声去除效果对比
Fig.5 Comparison of different methods for EOG artifact removal

2.3.3 工频噪声

针对脑电中的连续性工频噪声,3种去噪方法在不同噪声强度条件下的RRMSE值以及各通道去噪前后的功率谱如图6所示。3种方法均能有效降低工频噪声,但陷波滤波会对功率谱产生较大的扰动;另外两种方法对功率谱没有产生过多的失真。在较高工频强度下(NSR≥4)陷波滤波器取得的RRMSE值最低,而MRA-CCA-OD方法误差则小于Cleanline,并且工频的功率谱抑制更强。在较低工频强度下(NSR=1),3种方法RRMSE没有明显区别,MRA-CCA-OD和Cleanline能够很好地去除了工频污染,功率谱接近干净脑电。

针对间断性工频噪声,3种去噪方法在不同噪声强度条件下的RRMSE值以及各通道去噪前后的功率谱如图7所示。3种方法表现与连续性工频污染去除类似,陷波滤波器的RRMSE最低,但对功率谱扰动最大,而MRA-CCA-OD在较高工频强度下能够有效抑制工频功率谱。值得注意的是,Cleanline通过从工频污染数据中减去重构的正弦波来去除工频噪声,这点不适用于间断性工频污染,因此Cleanline的RRMSE值明显高于图7(a)中连续工频污染的情况。同时,如图7(b)所示,Cleanline无法去除泄漏的工频污染,导致46~49 Hz和51~54 Hz频率的噪声仍然较高,MRA-CCA-OD则有效降低了泄漏的工频污染。

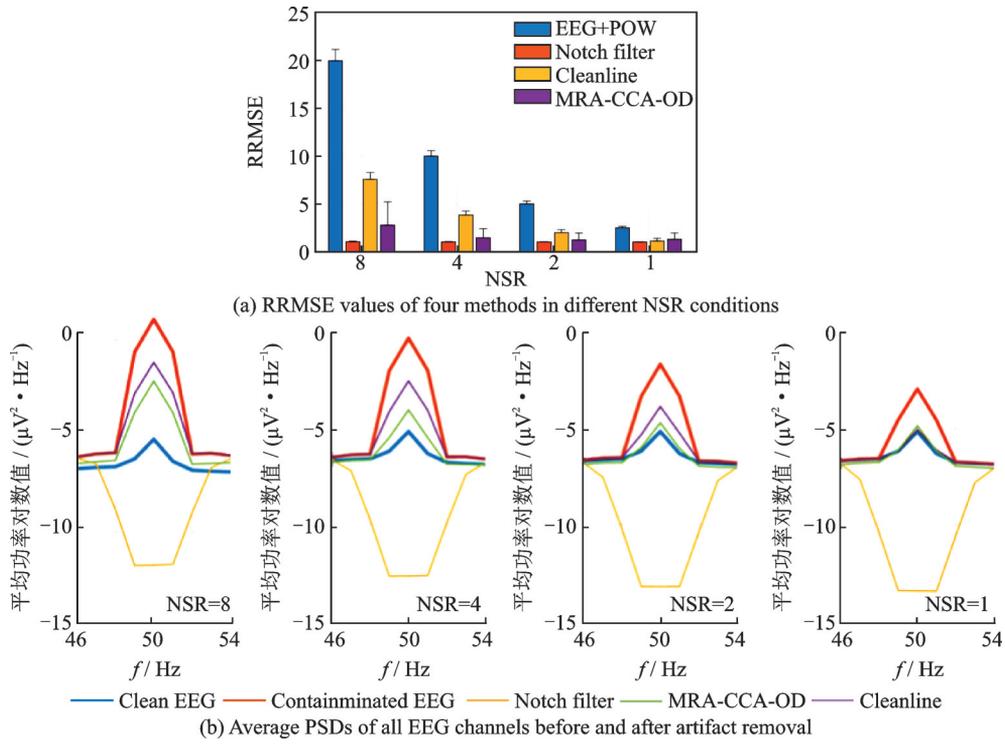


图 6 不同方法对连续工频噪声去除效果对比

Fig.6 Comparison of different methods for continuous power line artifact removal

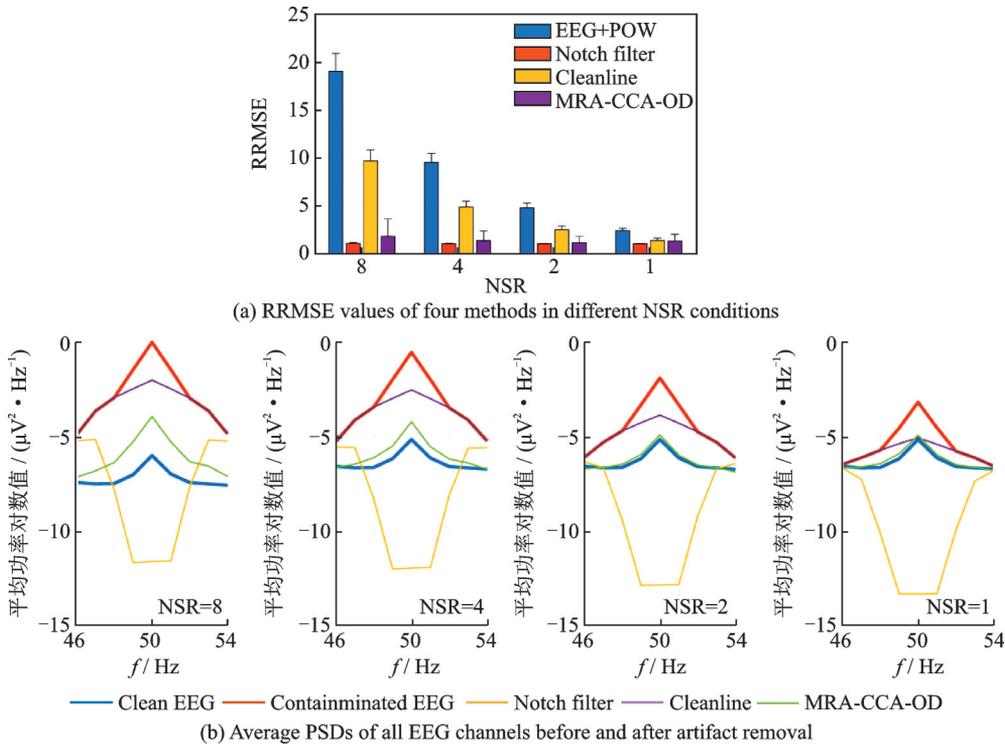


图 7 不同方法对间断性工频噪声去除效果对比。

Fig.7 Comparison of different methods for intermittent power line artifact removal

2.4 ERP数据的去噪分析

采用ICLabel和人工挑选两种方法,识别并去除被试ERP中的噪声成分。为了比较方法性能,选择3个通道进行去噪(C_z , P_z , O_z),每段数据长为500点,MODWTMRA的level=7。所获取的数据进行0.5~30 Hz的带通滤波,并且比较ERP波形。采用Kruskal-Wallis检验比较被试的ERP成分(N_1 、 P_2 、 P_3)的振幅。去噪后的ERP波形如图8所示,3种去除噪声方法, N_1 、 P_2 、 P_3 的幅度没有显著差异(Kruskal-Wallis test, $P < 0.05$),结果表明,本文提出的方法也适合ERP数据,与高密度脑电的分析工具性能相当。

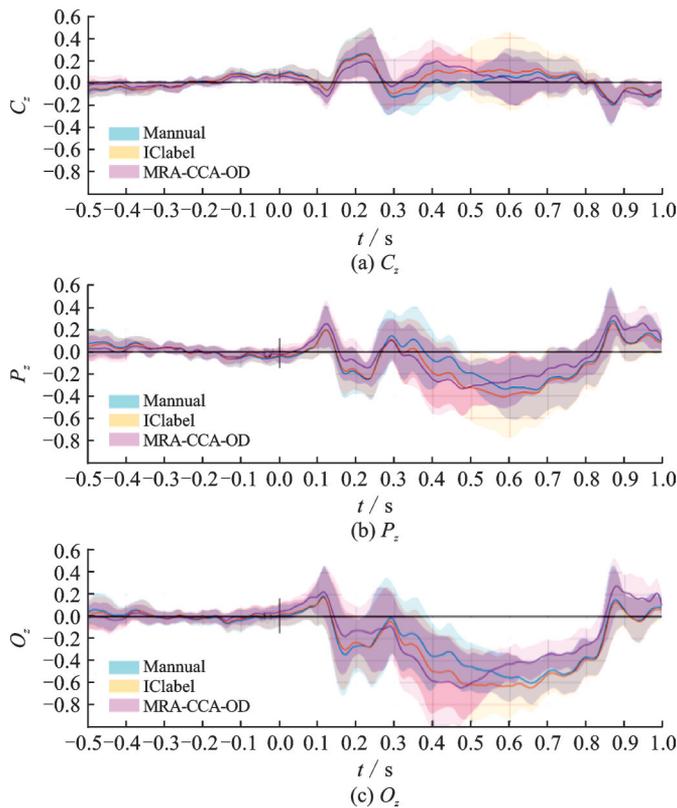


图8 3种方法去噪后的ERP波形(阴影部分表示被试间ERP幅值的四分差)

Fig.8 ERP waveform after artifact removal using three methods (Gray area represents the interquartile range (IQR) of each waveform of all participants at each time point)

3 结束语

脑电记录中,不同脑电活动之间差异不大,大部分噪声与脑电活动之间差异显著,在特征空间上噪声成分与脑电成分分布分散;不同噪声之间也存在较大的差异,多种噪声相关的成分在特征空间上也呈现分散分布。基于异常检测的思路,本文提出了一种低密度脑电自适应去噪方法,采用信号分解和盲源分离的方案提取潜在成分,然后根据其在特征空间中的分布情况,采用单类支持向量机识别并去除噪声相关的成分。仿真数据和真实EEG数据的定量分析结果表明,提出的方法在处理脑电数据中的肌电、眼电和工频等噪声方面,均优于现有方法。本文提出的低密度脑电自适应去噪方法,也适用ERP数据分析。该方法不需要调整参数,具有优良去噪性能和适用性。此外,本方法针对低密度脑电图的

噪声去除而设计,但只要满足对特征空间中成分分布的假设,也可以应用于多通道脑电或其他模态的信号。

参考文献:

- [1] COHEN M X. Where does EEG come from and what does it mean?[J]. *Trends in Neurosciences*, 2017, 40(4): 208-218.
- [2] CHEN H, CHEN W, SONG Y, et al. EEG characteristics of children with attention-deficit/hyperactivity disorder[J]. *Neuroscience*, 2019, 406: 444-456.
- [3] LENARTOWICZ A, LOO S K. Use of EEG to diagnose ADHD[J]. *Current Psychiatry Reports*, 2014, 16(11): 498.
- [4] SAKHAVI S, GUAN C, YAN S. Learning temporal information for brain-computer interface using convolutional neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(11): 5619-5629.
- [5] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. *Frontiers in Neuroscience*, 2012, 6(MAR): 39.
- [6] WOLPAW J R, WOLPAW E W. Brain-computer interfaces: Principles and practice[M]. New York: Oxford University Press, 2012.
- [7] DEBETTENCOURT M T, COHEN J D, LEE R F, et al. Closed-loop training of attention with real-time brain imaging[J]. *Nature Neuroscience*, 2015, 18(3): 470-478.
- [8] SEPULVEDA P, SITARAM R, RANA M, et al. How feedback, motor imagery, and reward influence brain self-regulation using real-time fMRI[J]. *Human Brain Mapping*, 2016, 37(9): 3153-3171.
- [9] 骆睿鹏, 冯铭科, 黄鑫, 等. 脑电信号预处理方法研究综述[J]. *电子科技*, 2022, 36(4): 1-8.
LUO Ruipeng, FENG Mingke, HUANG Xin, et al. A review of research on EEG signal preprocessing methods[J]. *Electronic Science and Technology*, 2022, 36(4): 1-8.
- [10] PION-TONACHINI L, KREUTZ-DELGADO K, MAKEIG S. ICLabel: An automated electroencephalographic independent component classifier, dataset, and website[J]. *NeuroImage*, 2019, 198: 181-197.
- [11] WINKLER I, BRANDL S, HORN F, et al. Robust artifactual independent component classification for BCI practitioners[J]. *Journal of Neural Engineering*, 2014, 11(3): 1-10.
- [12] CHEN X, XU X, LIU A, et al. The use of multivariate EMD and CCA for denoising muscle artifacts from few-channel EEG recordings[J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(2): 359-370.
- [13] JANANI A S, GRUMMETT T S, LEWIS T W, et al. Improved artefact removal from EEG using canonical correlation analysis and spectral slope[J]. *Journal of Neuroscience Methods*, 2018, 298: 1-15.
- [14] JANANI A S, GRUMMETT T S, BAKHSHAYESH H, et al. Fast and effective removal of contamination from scalp electrical recordings[J]. *Clinical Neurophysiology, International Federation of Clinical Neurophysiology*, 2020, 131(1): 6-24.
- [15] 王美娥, 徐艳华. 基于小波包分解和共空间模式方法的脑电运动想象分类方法[J]. *生物医学工程研究*, 2021, 40(3): 256-261.
WANG Meie, XU Yanhua. Classification of EEG motor imagination based on wavelet packet decomposition and common space model[J]. *Journal of Biomedical Engineering Research*, 2021, 43(3): 256-261.
- [16] 张力行, 张四聪, 徐光华, 等. 去除癫痫脑电信号运动伪迹的变分模态分解-自适应熵阈值方法[J]. *西安交通大学学报*, 2022, 56(1): 70-78.
ZHANG Lixing, ZHANG Sicong, XU Guanghua, et al. Variational modal decomposition-adaptive entropy threshold method for electroencephalogram motion artifact removal in epileptic seizure[J]. *Journal of Xi'an Jiaotong University*, 2022, 56(1): 70-78.
- [17] MIJOVIĆ B, DE VOS M, GLIGORIJEVIĆ I, et al. Source separation from single-channel recordings by combining empirical-mode decomposition and independent component analysis[J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(9): 2188-2196.
- [18] 樊凤杰, 白洋, 纪会芳. 基于EEMD-ICA的脑电去噪算法研究[J]. *计量学报*, 2021, 43(3): 395-400.
FAN Fengjie, BAI Yang, JI Huifang. Denoising method of EEG signal based on EEMD-ICA[J]. *Acta Metrologica Sinica*,

- 2021, 43(3): 395-400.
- [19] LIU Y, DAI Y, ZHOU Y, et al. An efficient and robust muscle artifact removal method for few-channel EEG[J]. *IEEE Access*, 2019, 7: 176036-176050.
- [20] MAMMONE N, LA FORESTA F, MORABITO F C. Automatic artifact rejection from multichannel scalp EEG by wavelet ICA[J]. *IEEE Sensors Journal*, 2012, 12(3): 533-542.
- [21] HOSSAIN M S, CHOWDHURY M E H, REAZ M B I, et al. Motion artifacts correction from single-channel EEG and fNIRS signals using novel wavelet packet decomposition in combination with canonical correlation analysis[J]. *Sensors*, 2022, 22(9): 3169.
- [22] UR REHMAN N, MANDIC D P. Filter bank property of multivariate empirical mode decomposition[J]. *IEEE Transactions on Signal Processing*, IEEE, 2011, 59(5): 2421-2426.
- [23] PERCIVAL D B, WALDEN A T. *Wavelet methods for time series analysis*[M]. Cambridge: Cambridge University Press, 2000.
- [24] PERCIVAL D B, MOFJELD H O. Analysis of subtidal coastal sea level fluctuations using wavelets[J]. *Journal of the American Statistical Association*, 1997, 92(439): 868-880.
- [25] CHAVEZ M, GROSSELIN F, BUSSALB A, et al. Surrogate-based artifact removal from single-channel EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2018, 26(3): 540-550.
- [26] ANIYAN A K, PHILIP N S, SAMAR V J, et al. A wavelet based algorithm for the identification of oscillatory event-related potential components[J]. *Journal of Neuroscience Methods*, 2014, 233: 63-72.
- [27] AL-KADI M I, REAZ M B I, MOHD ALI M A. Compatibility of mother wavelet functions with the electroencephalographic signal[C]//*Proceedings of 2012 IEEE-EMBS Conference on Biomedical Engineering and Sciences*. [S.l.]: IEEE, 2012: 113-117.
- [28] RAYKOV T, MARCOULIDES G A. *An introduction to applied multivariate analysis*[M]. New York: Routledge, 2008.
- [29] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [30] HOFMANN T, SCHÖLKOPF B, SMOLA A J. Kernel methods in machine learning[J]. *Annals of Statistics*, 2008, 36(3): 1171-1220.
- [31] SCHÖLKOPF B, PLATT J C, SHAWE-TAYLOR J, et al. Estimating the support of a high-dimensional distribution[J]. *Neural Computation*, 2001, 13(7): 1443-1471.
- [32] DELORME A, SEJNOWSKI T, MAKEIG S. Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis[J]. *NeuroImage*, 2007, 34(4): 1443-1449.
- [33] GASSER T, ZIEGLER P, GATTAZ W F. The deleterious effect of ocular artefacts on the quantitative EEG, and a remedy [J]. *European Archives of Psychiatry and Clinical Neuroscience*, 1992, 241(6): 352-356.
- [34] BARRY R J, JOHNSTONE S J, CLARKE A R. A review of electrophysiology in attention-deficit/hyperactivity disorder: II . Event-related potentials[J]. *Clinical Neurophysiology*, 2003, 114(2): 184-198.
- [35] CORBIT J D, GARBARY D J. Fractal dimension as a quantitative measure of complexity in plant development[J]. *Proceedings of the Royal Society B: Biological Sciences*, 1995, 262(1363): 1-6.
- [36] GÓMEZ-HERRERO G, DE CLERCQ W, ANWAR H, et al. Automatic removal of ocular artifacts in the EEG without an EOG reference channel[C]//*Proceedings of the 7th Nordic Signal Processing Symposium*. [S.l.]: NORSIG, 2006: 130-133.
- [37] SAMAVATI M, MOTIE NASRABADI A, MOHAMMADI M R. Automatic minimization of eye blink artifacts using fractal dimension of independent components of multichannel EEG[C]//*Proceedings of the 20th Iranian Conference on Electrical Engineering*. [S.l.]: IEEE, 2012: 1576-1578.
- [38] HSU W Y, LIN C H, HSU H J, et al. Wavelet-based envelope features with automatic EOG artifact removal: Application to single-trial EEG data[J]. *Expert Systems with Applications*, 2012, 39(3): 2743-2749.
- [39] 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.
- [40] MULLEN T. NITRC: CleanLine: Tool/resource info[EB/OL].(2012-02-09).<https://www.nitrc.org/projects/cleanline/>. 2012.

作者简介:



陈贺(1993-),男,助理研究员,研究方向:脑电信号处理、注意力评估与无创脑调控, E-mail: chenhe_bang@163.com。



张昊(1989-),男,助理研究员,研究方向:脑电信号处理、硬件系统设计, E-mail: zhanghao08@bnu.edu.cn。



柴一帆(1997-),男,硕士研究生,研究方向:信号处理算法、软件程序开发。



李小俐(1970-),通信作者,男,教授,研究方向:脑电信号处理、智能监控、故障诊断, E-mail: xiaoli@bnu.edu.cn。

(编辑:夏道家)