

基于偏最小二乘法的事件相关电位单次提取研究

严瀚莹 吴帆 姜忠义 邹凌*

(常州大学信息科学与工程学院 江苏 常州 213164)

(常州市生物医学信息技术重点实验室 江苏 常州 213164)

摘要 为满足脑-机接口特征提取实时性以及临床脑电检测高效性的要求,探讨事件相关电位的单试次高效提取技术尤为重要。将小波分析、经验模态分解、极限学习机以及偏最小二乘(PLS)应用于仿真和真实脑电信号,完成特征提取。结果显示:仿真实验中,不同信噪比下 PLS 提取性能稳定,P300 潜伏期误差小于 4 ms;真实脑中,PLS 少次迭代,特征提取更为精确,峰值误差 0.551 μV ,峰值潜伏期偏移量 27 ms,均小于小波、经验模态分解以及极限学习机多试次迭代结果($P < 0.01$)。结果表明偏最小二乘法在事件相关电位单试次提取中具有显著优势。

关键词 事件相关电位 单试次提取 脑-机接口 小波分析 经验模态分解 偏最小二乘

中图分类号 TP399 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2020.03.011

SINGLE EXTRACTION OF EVENT-RELATED POTENTIAL BASED ON PARTIAL LEAST SQUARES

Yan Hanying Wu Fan Jiang Zhongyi Zou Ling*

(School of Information Science and Engineering, Changzhou University, Changzhou 213164, Jiangsu, China)

(Changzhou Key Laboratory of Biomedical Information Technology, Changzhou 213164, Jiangsu, China)

Abstract In order to meet the requirements of real-time feature extraction of brain-computer interface and high efficiency of clinical EEG detection, it is particularly important to explore the single-trial and high-efficiency extraction technology of event-related potentials. Wavelet analysis, empirical mode decomposition, extreme learning machine and partial least squares (PLS) were applied to simulate and real EEG signals to complete feature extraction. The results show that the PLS extraction performance is stable under different SNR, and the latency error of P300 is less than 4 ms. In real EEG, PLS features are extracted more accurately with less iteration. The peak error is 0.551 μV , and the peak latency offset is 27 ms, which are smaller than the results of multiple iterations of wavelet, empirical mode decomposition and extreme learning machine ($P < 0.01$). The results show that the partial least squares method has significant advantages in single-trial extraction of event-related potentials.

Keywords Event-related potential Single-trial extraction Brain-computer interface Wavelet analysis Empirical mode decomposition Partial least squares

0 引言

脑电 (electroencephalogram, EEG) 因其非侵入式、

分辨率高、成本低等优点,在临床以及科学研究领域发挥着重要作用。事件相关电位 (Event-related potentials, ERP) 为 EEG 的一种衍生物,是由外部施加的特定刺激引起的电位变化^[1-2]。目前研究最为广泛的成

分是 P300,它通常是由受试者在 oddball 范式中辨认靶刺激时所诱发,潜伏期为 300 ms 左右的正向电位,主要分布在头顶皮层处^[3]。自 P300 成分被发现以来,它已经被广泛应用于认知心理学、神经科学等领域。

EEG 信号在记录时,人脑头皮上任意一点所收集的都是该大脑区域各种活动的非线性混合信号。而诱发电位信噪比很低,很易被强背景噪声所淹没,因此它的提取是 ERP 研究中的主要挑战之一。目前诱发电位提取技术中,独立成分分析(independent component analysis,ICA)应用最为广泛^[4]。但对于成分的选取,ICA 需依靠主观经验,而由于利用多导联信号提取诱发电位增加了计算复杂度,先前利用 ICA 提取诱发电位的研究中只研究了少量导联。例如, Lee 等^[5]只选取了单个导联来提取 P300 成分。除 ICA 之外,其他使用较广泛的方法还有:小波分解、经验模式分解(empirical mode decomposition,EMD)等^[6-7]。虽然小波分解在阿尔兹海默症患者等脑电特征提取中效果显著,EMD 也在 ERP 的提取中得到了应用,但这两种方法也存在着一定的局限性。小波分解可能会丢失部分有效成分,选择合理的阈值较为困难,且实时性差^[8]。而 EMD 方法操作性强,依赖于研究者的经验。除上述传统方法,约束 ICA、稀疏贝叶斯时空模型、残差迭代分解等方法也被应用于诱发电位的成分提取^[9-11]。约束 ICA,相比于 ICA 具有更好的鲁棒性,但也无法解决多导计算量大的问题。贝叶斯时空模型解决了多导信号特征提取困难的问题,但是这种基于多尺度建模的问题,需要先验且算法复杂度高。残差迭代分解法解决了 ERP 延时性问题,但 ERP 提取的幅值误差等同样需要考虑。近年来,极限学习机(extreme learning machine,ELM)作为神经网络新算法也应用于脑机接口的特征提取及分类^[12]。偏最小二乘(partial least squares,PLS)算法可以对复杂混合体系进行快速分析,最初应用于经济学和化学计量学。PLS 算法模型相对简单,对处理变量多样本少的数据具有明显的优势^[13],适用于单次多导脑电信号的 ERP 提取。2016 年 Cheung 等^[14]已经将该方法引入神经影像学,用于脑磁图数据的统计分析,但目前将 PLS 应用于诱发电位成分提取的研究还比较匮乏。

本文首先构造不同信噪比的模拟脑电数据,采用 PLS 算法提取 P300、N100 成分,验证了 PLS 方法的鲁棒性。基于 oddball 实验范式采集真实脑电数据,使用小波分解、EMD、ELM 及 PLS 算法提取 P300 成分,并通过相关系数、峰值误差和峰值潜伏期偏移量指标进一步验证 PLS 算法的有效性。

1 实验数据及方法

1.1 实验数据

1.1.1 模拟脑电数据

由刺激诱发的 EEG 信号中包含了诱发电位、自发脑电信号以及采集信号时所带的噪声信号。构造模拟脑电数据的过程主要分为三个步骤:

首先利用式(1)对 EP 信号进行仿真,其中采样点 2 016,采样频率为 1 008 Hz,采样时间为 2 s,波形如图 1(a)所示,横坐标为时间(单位毫秒),纵坐标为幅值,范围为 $-8 \sim 6 \mu\text{V}$ 。

$$f(t) = -10e^{(-2t)} \sin(4\pi t) \quad (1)$$




图1 模拟脑电信号

其次,采用 AR 模型仿真出自发脑电信号 $v(n)$,如式(2)所示,其中 $u(n)$ 为零均值高斯噪声。之后对真实脑电中的噪声信号进行仿真,这里使用白噪声,采样点为 2 016,采样频率为 1 008 Hz,采样时间为 2 s。将两个信号相加作为诱发电位的背景噪声,如图 1(b)所示。

$$v(n) = u(n) + a_1 \times u(n-1) + a_2 \times u(n-2) + a_3 \times u(n-3) + a_4 \times u(n-4) \quad (2)$$

最后,将仿真自发脑电信号、白噪声和仿真诱发电位,以 -9 dB 的低信噪比混合作为实验数据,如图 1(c)所示,幅值约为 $-50 \sim 50 \mu\text{V}$,图中基本看不出 N100 和 P300 的波形特征。共仿真 20 道模拟脑电数据,每道时长为 2 s。

1.1.2 真实脑电数据

(1) 数据采集。为了验证偏最小二乘方法的可行性,共采集了 8 名健康被试者(18 ~ 22 岁)的头皮脑电数据。实验所使用的信号采集设备为美国 EGI 公司 64 导脑电帽及放大器,参考电极取 Cz 点,采样频率为 1 000 Hz。本次实验之前所有被试均签署了知情同意书。

(2) 实验范式。实验采用 oddball 范式,该范式是 ERP 实验常用范式之一。通常 oddball 范式在试验中

会随机呈现作用于同一感官的两种刺激,两种刺激出现的概率不同。将概率较大的刺激作为标准刺激,概率小的刺激作为靶刺激。本次实验以被试自身证件照为靶刺激(出现概率为20%)、以陌生人证件照为标准刺激(出现概率为80%),要求被试忽略陌生人证件照,对自身证件照出现时作出相应的按键反应来进行实验。其中靶刺激120次,标准刺激为480次。在每个被试实验前做一次预实验,剔除预选照片中被试较为熟悉的照片。

(3) 数据预处理。为了衡量诱发电位提取的效果,将相应导联上处理后叠加平均所得的诱发电位信号作为参考信号。脑电信号的预处理步骤为:① 降采样,将采样率降为500 Hz;② 滤波,范围为0.1~40Hz;③ 去除眼电伪迹,使用EEGLAB工具箱中的ICA工具;④ 对信号进行分段,刺激前200 ms至刺激后1 000 ms;⑤ 对每种刺激下的信号进行叠加平均,最终得到相对纯净的诱发电位波形。

1.2 方法设计

提取诱发电位的过程实际上就是从记录的脑电信号中去除自发脑电和其他噪声信号。小波分解与经验模态分解都是信号去噪的常用方法,在诱发电位的提取中也应用广泛。极限学习机是神经网络新方法。将偏最小二乘方法与以上三种方法的效果进行对比可验证其有效性。总体流程如图2所示。

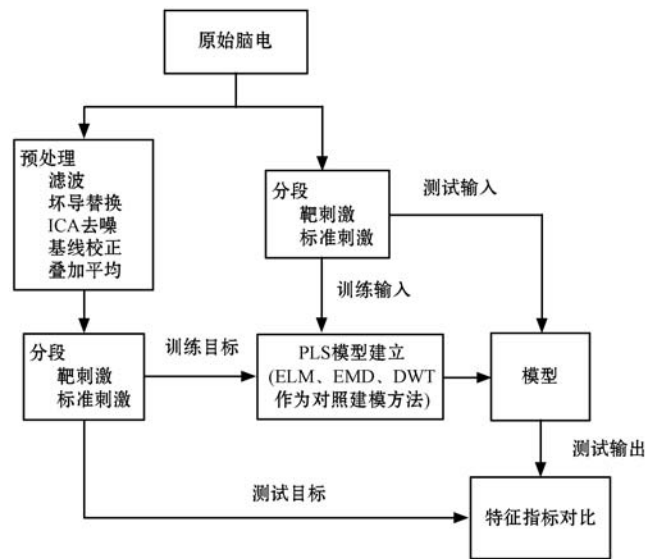


图2 P300提取流程图

1.2.1 小波变换

离散小波变换(Discrete Wavelet Transformation, DWT)方法不论在频域还是时域上都能较好地反映信号特征。小波分解所采用的窗函数是可变的,增加了时间平移和尺度伸缩两个参数。因此,使用小波分解的方法对信号的高频信息及低频信息都能进行分析。

对于分析类似于脑电信号的非平稳信号,小波分解是一种较为合适的方法。

利用小波分解进行成分提取共包含三个方面:基本小波的选择、阈值函数的选取、阈值的选择。在提取成分时小波基选取CoifN小波函数,该小波基相比dbN更能保证信号在分解、重构时不会产生失真和相位延迟。分解层数为7层,根据不同被试脑电信号特性选取分解层进行阈值函数处理,其他分解层置零,最后对信号进行重构。

1.2.2 经验模态分解

EMD是根据信号自身的特点,将该信号分解成若干个本征模态函数IMF之和,是一种自适应性的信号处理方法。每一个本征函数必须满足以下两个条件:在整段的数据上,极值点的个数和过零点的个数必须相等或最多相差一个;在数据的任意时间段,上、下包络线的平均值必须是零。

每一个IMF计算步骤如下:

首先,找到原信号 $x(t)$ 的所有极值点,通过三次样条插值将所有极值点连接起来,拟合出上、下包络线 $e_+(t)$ 和 $e_-(t)$ 。将上、下包络线的均值作为 $x(t)$ 的均值包络 $m_1(t)$:

$$m_1(t) = \frac{e_+(t) + e_-(t)}{2} \quad (3)$$

将原信号序列减去 $m_1(t)$ 就得到一个去掉低频的新信号 $h_1^1(t)$,如果 $h_1^1(t)$ 不满足IMF的两个条件,则重复上述过程,经过 k 次重复之后得到的 $h_1^k(t)$ 满足IMF的定义,则 $x(t)$ 的第一个IMF分量记为:

$$c_1(t) = \text{imf}_1(t) = h_1^k(t) \quad (4)$$

将 $c_1(t)$ 从原信号 $x(t)$ 中分离出来,得到第二个IMF分量 $c_2(t)$,重复之前的步骤 n 次后,得到第 n 个IMF分量 $c_n(t)$ 。当其余量 $r_n(t)$ 小于预设值,或当 $r_n(t)$ 为单调函数或常量时,循环终止。最后得到:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (5)$$

式中: $r_n(t)$ 为残余量,代表信号的平均趋势或均值。

1.2.3 极限学习机

极限学习机(ELM)是一种针对单隐层前馈神经网络(Single-hidden Layer Feedforward Neural Network, SLFN)的新算法。相较于传统SLFN算法,ELM方法具有学习速度快、泛化性能好等优点。对于一单隐层神经网络,输入样本 (X_i, t_i) , $X_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbf{R}^n$, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbf{R}^m$ 。通过一个有 L 个隐层节点的单隐层神经网络,表示为:

$$\sum_{i=1}^L \beta_i g(W_i \cdot X_j + b_i) = o_j \quad j = 1, 2, \dots, N \quad (6)$$

式中: $g(x)$ 为激活函数, W_i 为输入权重, β_i 为输出权重, b_i 是第 i 个隐层单元的偏置。ELM 学习的目标是使得模型输出 o_j 尽可能逼近样本实际输出 t_j , 矩阵表示为:

$$HB = T \quad (7)$$

式中: H 是隐层节点的输出; β 为输出权重; T 为期望输出。该问题则是求解式(7)的极小范数最小二乘解 $\hat{\beta} = H^+ T$, H^+ 为矩阵的 Moore-Penrose 广义逆。利用 ELM 回归将原始信号作为输入, 将 ERP 特征波作为输出, 输入输出权重及隐层单元偏置可随机设定且无须调整, 大大提高了运算效率。

1.2.4 偏最小二乘法

实现偏最小二乘回归的基本思想, 其实是求如下目标函数最大化的优化问题:

$$\begin{aligned} \max \{ Cov(t_1, u_1) \} &= \max (X_0 w_1, Y_0 c_1) \quad (8) \\ \text{s. t. } \begin{cases} w_1^T w_1 = 1 \\ c_1^T c_1 = 1 \end{cases} \end{aligned}$$

式中: X_0 、 Y_0 分别为 X 、 Y 标准化矩阵, w_1 是 $X_0^T Y_0 Y_0^T X_0$ 最大特征值对应的单位特征向量, c_1 是 $Y_0^T X_0 X_0^T Y_0$ 最大特征值对应的特征向量^[15]。

该问题求解的算法思想可以理解为解释隐变量与反映隐变量之间的回归关系方程。假定 m 个自变量 $\{x_1, x_2, \dots, x_m\}$ 和 n 个因变量 $\{y_1, y_2, \dots, y_n\}$, 构成自变量与因变量的数据表 $X = \{x_1, x_2, \dots, x_m\}$ 和 $Y = \{y_1, y_2, \dots, y_n\}$ 。在 X 与 Y 中分别提取出代表各自特征的成分 t_1 和 u_1 , 在提取 t_1 和 u_1 成分时, 要求 t_1 和 u_1 应尽可能大地携带它们各自数据表中的变异信息, 而且满足 t_1 与 u_1 的相关程度能够达到最大。第一次迭代后, 成分 t_1 和 u_1 被提取, X 进行对 t_1 的回归, 而 Y 进行对 u_1 进行回归。若回归方程已经达到满意的精度, 则成分确定; 否则将利用 X 被 t_1 以及 Y 被 u_1 解释后的残余信息进行第二轮成分 t_2 和 u_2 提取, 继续实施 X 和 Y 对 t_2 和 u_2 的回归, 该过程一直迭代直到精度满足要求为止。若最终对 X 共提取了 k 个成分 t_1, t_2, \dots, t_k , 再通过 Y 对 t_1, t_2, \dots, t_k 的回归, 最后都可转化为 Y 对自变量 x_1, x_2, \dots, x_m 的回归方程, 完成了偏最小二乘的回归建模。

运用到脑电信号中, 自变量即为含噪的脑电信号, 这里我们用的是 64 导脑电信号, 则 $X = \{x_1, x_2, \dots, x_n\}$ 中, n 为 64, 而经过预处理及多试次叠加平均所得的脑电信号便被近似为纯净 ERP 信号, 表示为因变量 $Y = \{y_1, y_2, \dots, y_n\}$, 偏最小二乘方法集成了主成分分析、多元线性回归和相关性分析的优点, 它主要是通过最

小化误差的平方和找到一组数据的最佳函数匹配。用最简单的方法求得一些绝对不可知的真值, 而令误差平方之和为最小。脑电信号的单次提取, 以减少实验获得质量较好的 ERP 成分为目的。算法执行按如下操作:

第一次建模, 自变量输入为单次 trail-1 的原始信号, 设为 X_1 , 其经过预处理后则为 Y_1 , 经过 PLS 建模后得到重构系数矩阵 sol_1 。

第二次建模, 自变量输入为单次 trail-2 的原始信号, 设为 X_2 , 预处理后的 X_1 与 X_2 迭加平均作为 Y_2 , 建模得到 sol_2 , 用 sol_1 模型与 X_2 得到的预测信号为 y_2 , ER_2 为 y_2 与 Y_2 之间的误差。

第 n 次建模, 自变量输入为单次 trail- n 的原始信号 X_n , 前 n 次预处理后的脑电信号的均值作为 Y_n , 建模得到 sol_n , 若 sol_{n-1} 模型与 X_n 得到的预测信号 y_n 与 Y_n 之间的误差小于限定误差 ER, 则 sol_n 将作为最终实验模型, 此时迭代次数为 n 。

1.3 评价指标

为了检测 PLS 方法应用于诱发电位提取的有效性, 使用了如下几个评价指标: 相关性系数、峰值误差、峰值潜伏期偏移量。

1.3.1 相关系数

相关系数主要考虑两个信号在一段时间内的同步程度。用在信号重构中, 可用于检测信号重构的质量。

$$R = \frac{\left| \frac{\sum_{i=1}^n (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{Y})^2}} \right|}{\quad} \quad (9)$$

式中: n 为信号的样本点总数, x_i 、 y_i 分别为两个信号时刻点 i 的观测值, \bar{X} 和 \bar{Y} 则分别为两信号的样本均值。 R 描述了信号 X 和 Y 之间的相关程度, R 的取值范围在 0 到 1 之间, 越接近 1 说明两信号越相关。

1.3.2 峰值误差

对于 ERP 的提取中, 我们所关注的成分的直接表现就是波形的幅值, 峰值误差表示了模型提取的成分波与理想成分波在峰值上的误差的绝对值。表示为:

$$Err_{\text{peak}} = |x_m - y_n| \quad m \in (k, l), n \in (k, l) \quad (10)$$

在特定区间 (k, l) 内, 信号 X 在 m 时刻取得最高值(或最低值), 而信号 Y 在 n 时刻取得最高值(或最低值), 则其峰值差的绝对值为峰值误差。

1.3.3 峰值潜伏期偏移量

除了信号的幅值以外, 峰值相位的准确度也是检验成分提取质量的标准之一。峰值潜伏期偏移量则是

在峰值确定下时刻 m 与时刻 n 点所对应的实际时间:

$$Err = |m - n| \times t \quad (11)$$

式中: t 为信号样本点间的时间最小间隔。

2 结果分析

2.1 模拟数据

对于模拟的含噪脑电信号,首先使用 PLS 方法迭代共 12 次得到最佳提取模型,之后利用该模型提取模拟含噪脑电信号中的 N100、P300 成分。观察提取信号的时域波形可以直观反映提取效果,图 3 为信噪比为 -7 dB 模拟信号的理想 ERP 与 PLS 方法提取波形的对比图。实线波形为理想 ERP 信号,虚线波形为 PLS 方法提取波形。从图中可以直观看出,PLS 方法提取的诱发电位与理想 ERP 波形相似性很高,N100 与 P300 成分也都很明显。




图 3 PLS 提取波形与理想 ERP 对比图

为了衡量 PLS 方法的稳定性,对不同信噪比的模拟含噪脑电信号用 PLS 方法进行成分提取。将提取后的成分潜伏期与理想 ERP 成分潜伏期作差,该差值即为 PLS 方法成分提取的潜伏期偏移量。对信噪比为 0 dB 至 -9 dB 的模拟脑电信号进行成分提取,N100、P300 的潜伏期偏移量如图 4 所示。可以看出 N100、P300 潜伏期偏移量都在 7 ms 之内,误差较小。其中 N100 潜伏期偏移量较 P300 偏大,P300 潜伏期最大偏移量为 4 ms 而 N100 与真实位置偏差最大达到 6.2 ms。但最后噪声再增加而 N100、P300 偏移量将保持稳定。




图 4 PLS 模型在不同信噪比下模拟数据的潜伏期偏移量

2.2 真实脑电数据

将 PLS 应用于真实的脑电数据,将提取结果与小波变换、经验模式分解以及极限学习机方法的结果进行对比。图 5 为同一个被试 Pz 电极处利用四种不同方法提取的时域波形,(a) 为该被试单次原始脑电波形,(b) 为四种方法提取波形与叠加平均 (Ensemble Averaging, EA) 后的 ERP 波形对比。(b) 中 PLS 方法在 P300 处与 EA 波形最为接近,ELM 结果次之,EMD 方法峰值与 EA 相差过大而 DWT 方法峰值较 EA 有明显偏移。PLS 方法较其他三种方法时域波形结果较好。




图 5 不同方法诱发电位提取结果

为了定量衡量不同方法时域波形的提取效果,对 P300 成分较为明显的 P3、P4、C3、C4 导联计算提取信号与 EA 的相关系数。从图 6 中可明显看出 EMD 方法相关系数最低,PLS 以及 ELM 方法在四个导联上的相关系数都在 0.7 之上,小波分解方法除 C3 导联外相关系数都比 PLS 方法低。PLS 和 ELM 较 DWT 和 EMD 方法与 EA 有更强相关性,且它们在多个电极的 ERP 提取上都表现出良好性能。




图 6 不同方法提取信号相关系数

对四种方法在 8 个被试的 P300 提取中的偏移误差进行计算,如表 1 所示。PLS 方法的潜伏期偏移量与幅值偏移量较其他三种方法平均值都更小,方差统计也显示出其更稳定的性能。

表 1 四种方法在 P300 提取中的偏移误差比较

偏移误差	PLS		EMD		DWT		ELM	
	均值	方差	均值	方差	均值	方差	均值	方差
潜伏期偏移量/s	0.027	0.022	0.040	0.063	0.085	0.120	0.029	0.080
幅值偏移量/ μ V	0.551	0.669	1.399	1.540	0.615	0.763	0.607	0.632

3 结 语

在仿真数据的实验中,偏最小二乘模型在特征提取上具有很好的抗干扰性能,能成功提取 N100 和 P300 成分。而在真实脑电 ERP 的提取中,虽然小波、经验模态分解以及极限学习机在使用大量试次(120 次)叠加平均建模的基础上提取到了准确的 P300 成分,但偏最小二乘模型在少试次(最少 9 次)的建模中得到了更加稳定的模型。在后续的验证试验中,PLS 与 ELM 提取的 P300 成分,在相关性指标上均具有较好表现。而 PLS 在信号峰值误差、潜伏期误差等指标上都优于其他三个模型。PLS 模型实现了少试次精确建模,解决了多导 ERP 成分的单试次提取困难,为脑电 ERP 研究以及 BCI 脑机接口的发展提供了技术支持。

参 考 文 献

- [1] Kayser J, Tenke C E. Issues and considerations for using the scalp surface Laplacian in EEG/ERP research: a tutorial review[J]. *International Journal of Psychophysiology*, 2015, 97(3): 189–209.
- [2] 张萍淑,孔祥慧,元小冬,等.听觉和视觉认知电位 P300 系列成分的临床电生理学特征[J]. *中国健康心理学杂志*, 2017,25(1):16–20.
- [3] Kempny A M, James L, Yelden K, et al. Patients with a severe prolonged Disorder of Consciousness can show classical EEG responses to their own name compared with others, names[J]. *NeuroImage: Clinical*, 2018, 19:311–319.
- [4] Hajian A, Yong S P. Feature extraction from EEG data for a P300 based brain-computer interface[C]//Pacific-asia Conference on Knowledge Discovery & Data Mining. Springer, Cham, 2017.
- [5] Lee W L, Tan T, Falkmer T, et al. Single-trial event-related potential extraction through one-unit ICA-with-reference[J]. *Journal of Neural Engineering*, 2016, 13(6):066010.
- [6] Mortaheb S, Rostami F, Shahin S, et al. Wavelet based single trial Event Related Potential extraction in very low SNR conditions[C]//2016 6th International Conference on Com-

puter and Knowledge Engineering(ICCKE). IEEE, 2016: 82–87.

- [7] Chimit N, Misch W, Tan L, et al. Comparative study of simple feature extraction for single-channel EEG based classification[C]//IEEE International Conference on Electro Information Technology. IEEE, 2017.
 - [8] 胡春海,信思旭,刘斌,等.基于小波变换和盲源分离的 P300 识别算法研究[J]. *计量学报*,2017,38(2): 242–246.
 - [9] Karimi F, Kofman J, Mrachacz-Kersting N, et al. Detection of movement related cortical potentials from EEG using constrained ICA for brain-computer interface applications[J]. *Frontiers in Neuroscience*, 2017, 11:356.
 - [10] Zhang Y, Zhou G, Jin J, et al. Sparse Bayesian multiway canonical correlation analysis for EEG pattern recognition[J]. *Neurocomputing*, 2017, 225: 103–110.
 - [11] Ouyang G, Sommer W, Zhou C. Updating and validating a new framework for restoring and analyzing latency-variable ERP components from single trials with residue iteration decomposition(RIDE)[J]. *Psychophysiology*, 2015, 52(6): 839–856.
 - [12] Xiong Y, Luo Y, Huang W, et al. A novel classification method based on ICA and ELM: a case study in lie detection[J]. *Bio-medical materials and engineering*, 2014, 24(1): 357–363.
 - [13] 黄彪,魏滢,吴顺祥. PLS 算法在多维数据挖掘判别分类中的研究及应用[J]. *计算机应用与软件*,2017,34(11): 58–63.
 - [14] Cheung M J, Kovačević N, Fatima Z, et al. [MEG]PLS: A pipeline for MEG data analysis and partial least squares statistics[J]. *Neuroimage*, 2016, 124(Pt A):181–193.
 - [15] Yanti D K, Yusoff M Z, Bekdash M, et al. Single trial visual evoked potential extraction using fast PLS[C]//IEEE International Conference on Signal & Image Processing Applications. IEEE, 2016.
-
- (上接第 21 页)
- [24] Harrison R, Counsell S J, Nithi R V. An evaluation of the MOOD set of object-oriented software metrics[J]. *IEEE Transactions on Software Engineering*, 1998, 24(6): 491–496.
 - [25] Henderson-Sellers B. Object-oriented metrics: measures of complexity[M]. Prentice-Hall, Inc., 1995.
 - [26] Lanza M, Marinescu R. Object-oriented metrics in practice: using software metrics to characterize, evaluate, and improve the design of object-oriented systems[M]. Springer Science & Business Media, 2007.