

DOI:10.3969/j.issn.1005-202X.2022.01.011

医学信号处理与医学仪器

基于互信息特征提取的运动想象脑机接口

贾婷婷^{1,2},董朝轶^{1,2},马爽^{1,2},马鹏飞^{1,2},陈晓艳^{1,2},肖志云^{1,2},齐咏生^{1,2}

1. 内蒙古工业大学电力学院, 内蒙古 呼和浩特 010088; 2. 内蒙古机电控制重点实验室, 内蒙古 呼和浩特 010051

【摘要】脑机接口是一种实现计算机和人脑及其他设备间通信的系统。本文引入F3、F4、C3、C4、FZ、CZ、FC1、FC2、FC5、FC6等多通道运动想象脑电信号的网络连接结构权值等特征,采用支持向量机对不同的运动想象任务进行分类。对所提出的基于互信息(MI)的脑网络结构特征提取方法同传统方法自回归模型(AR)参数特征提取方法进行对比研究,发现基于MI特征提取的运动想象脑电信号分类正确率显著高于AR参数特征提取方法,将两类特征进行融合后,运动想象脑电信号分类正确率又显著高于单独使用MI或AR特征提取方法。

【关键词】互信息;运动想象;自回归模型;支持向量机;脑机接口

【中图分类号】R318;TP14

【文献标志码】A

【文章编号】1005-202X(2022)01-0063-06

Brain-computer interface of motion imagery based on mutual information-based feature extraction

JIA Tingting^{1,2}, DONG Chaoyi^{1,2}, MA Shuang^{1,2}, MA Pengfei^{1,2}, CHEN Xiaoyan^{1,2}, XIAO Zhiyun^{1,2}, QI Yongsheng^{1,2}

1. College of Electric Power, Inner Mongolia University of Technology, Hohhot 010088, China; 2. Inner Mongolia Key Laboratory of Electromechanical Control, Hohhot 010051, China

Abstract: Brain-computer interface is a kind of system that realizes communication between computers and human brains and other devices. The features such as the network connection structure weights of multi-channel motion imagery electroencephalogram (EEG) signals from F3, F4, C3, C4, FZ, CZ, FC1, FC2, FC5, FC6, etc are introduced in the study, and support vector machine is used to classify different motion imagery tasks. The proposed brain network structure feature extraction based on mutual information (MI) is compared with the traditional autoregressive model-based parameter feature extraction. It is found that the accuracy rate of the MI-based feature extraction for motion imagery EEG signals classification is significantly higher than that of the autoregressive model-based parameter feature extraction. After the two types of features are fused, the classification accuracy rate of the constructed brain-computer interface classifier is significantly higher than that of feature extraction method using MI or autoregressive model alone.

Keywords: mutual information; motion imagery; autoregressive model; support vector machine; brain-computer interface

前言

目前,典型的脑机接口的分类过程通常包括信号采集和预处理、特征提取、模式分类等子过程。首先,采集、记录受试者的脑电信号;然后利用预处理

技术(例如滤波和去伪迹)以减少噪声和伪影;接着应用适合生物神经生理机制的特征提取技术来构建特征集合;最后,建立机器学习分类器对不同的生理、心理任务进行分类,将分类结构转换为指令,以控制目标设备^[1]。

总所周知,特征提取是整个运动想象脑电信号分类过程中的一个关键环节,其主要目的是得到脑机接口中各个导联信号分类差异最大的特征,以便于对其进行分类。特征的选取是否能够反映数据集中不同标签数据的本质区别,间接关系到模式分类器的分类效果。在给定的特征集合和数据长度的条件下,不同的分类器结构和机理,亦会直接影响最终分类的正确率。对于脑电信号尤其是运动想象脑电信号的分析,为达到最优的信号模式分类效果,国内外学者们发展了多种特征提取和分类器设计方法。

【收稿日期】2021-07-18

【基金项目】国家自然科学基金(61364018, 61863029, 61763037, 61661042); 内蒙古自然科学基金(2016JQ07, 2020MS06020); 内蒙古科技成果转化项目(CG-ZH2018129); 内蒙古自治区科技计划项目(关键技术攻关计划项目)

【作者简介】贾婷婷,硕士研究生,研究方向:模式识别和智能控制, E-mail: 1477001904@qq.com

【通信作者】董朝轶,博士,教授,主要研究方向:复杂生物网络建模、仿真与网络结构辨识等, E-mail: dongchaoyi@hotmail.com

常用的特征提取算法有共空间模式(Common Spatial Pattern, CSP)^[2]、小波变换^[3]、自回归模型(Autoregressive Model, AR)^[4-5]和功率谱分析^[6]等。常用的模式分类算法有线性判别分析(Linear Discriminant Analysis, LDA)^[7]、人工神经网络(Artificial Neural Network, ANN)^[8]。以上这些特征提取和模式分类算法机理各有差异,但在实际应用中一般会遇到特征提取不够充分,未能考虑脑网络结构的全局特征,模型结构过于复杂导致过拟合等问题。为克服以上实际问题,本文将互信息(Mutual Information, MI)法所辨识出的网络结构特征同AR参数特征相融合,采用支持向量机(Support Vector Machines, SVM)^[9-10]算法对左右手运动想象任务进行分类,取得了比单一特征提取方法更高的分类正确率。

本文基于8位被试者(S1~S8)的运动想象脑电数据进行分类器设计。对MI特征提取方法而言,计算延迟1~5个采样周期的脑网络MI连接,当延迟1~2拍时,模式分类正确率较延迟3~5拍高。对于被试S1~S7而言,特征融合方法的分类正确率均高于单一特征提取方法。以被试S5为例,单独采用MI脑网络结构特征提取法,分类正确率为91.63%;而单独采用AR参数特征提取方法,分类识别正确率为87.50%;两类特征进行融合(同时采用MI脑网络结构特征和AR参数特征)后,SVM识别正确率达到92.50%。对于被试S8,融合特征法的分类正确率较AR法的分类正确率略低,但仍高于MI法的分类正确率。试验结果验证了运动想象脑电信号分类任务中,网络特征提取并融合的必要性和有效性。

1 试验方法

1.1 MI算法

在概率论和信息论中,引入MI的概念以度量两随机变量间相互依赖关系^[11]。信息熵 H 表示一个随机变量的不确定程度, I 则表示任意两个随机变量间的彼此作用关系。对于变量 X 而言,其信息熵 $H(X)$ 扣除其它变量条件下自身的条件信息熵 $H(Y|X)$ 后,可以得到两变量间的互信息 $I(X, Y)$ 的值,图1给出了互信息 $I(X, Y)$ 的计算过程。

假设两个随机变量 X, Y 的联合分布 $p(x, y)$,边缘分布分别为 $p(x), p(y)$,则有^[12]:

$$H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y) \quad (1)$$

$$H(X) = - \sum_{x \in X} p(x) \log p(x) \quad (2)$$

$$H(Y) = - \sum_{y \in Y} p(y) \log p(y) \quad (3)$$




图1 1个变量熵 H 和两个变量间互信息 I 的关系
Figure 1 Relationship between a variable entropy H and the mutual information (MI) I between two variables

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (4)$$

$$H(X|Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x|y) \quad (5)$$

$$H(Y|X) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) \quad (6)$$

$$I(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) \quad (7)$$

由公式(1)~(7),可进一步得到:

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} P(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (8)$$

往往脑区间的相互作用,前件对象发出的作用,到达并影响后件对象需要消耗一定的传输时间,作用具有因果性。将前件变量提前若干拍采样周期的值同后件变量的当前值计算MI,可利用变量间作用的延时性,辨识出前件变量对后件变量的因果性动态连接关系。这里,式(8)修改为:

$$I_{\text{delay}}(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x(k - \tau), y(k)) \log \frac{p(x(k - \tau), y(k))}{p(x(k - \tau))p(y(k))} \quad (9)$$

其中, k 为当前时刻, τ 表示变量间作用延迟的节拍数。 $I_{\text{delay}}(X, Y)$ 计算了节点 X 指向节点 Y 的因果性互信息。

1.2 AR

AR由于其脑电信号特征提取中的作用,已成为脑电信号建模的一种重要方法。其基本思想为:将某一通道脑电信号的当前值看作其历史值和某一给定功率的白噪声信号当前值的线性表示。线性叠加的系数成为AR系数^[13]。因此,单一通道的脑电信号同它的AR模型系数是统一的,通过模型定阶算法(AIC准则),本文利用一个5阶AR对脑电信号进行建模,将其系数作为脑电信号的特征向量。

AR的差分方程表示如下:

$$x(n) = - \sum_{i=1}^p a_p(i) x(n - i) + v(n) \quad (10)$$

其中, $v(n)$ 为均值为零,方差为 σ^2 的白噪声序列; p 为AR模型阶数; $a_p(i), i = 1, 2, \dots, p$ 为 p 阶AR模型的参数。

1.3 模式分类方法

本文采用SVM模式分类方法对提取后的特征向量数据进行分类^[14-15]。分类时,常遇到线性不可分和非线性的情况,可在约束条件中引入松弛变量,在目标函数中引入惩罚因子来解决,则分类优化问题为:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^i \xi_i, i = 1, 2, \dots, N \quad (11)$$

$$y_i(\omega x_i + b) \geq 1 - \xi_i, i = 1, 2, \dots, N \quad (12)$$

其中, $(x_i, y_i), i = 1, 2, \dots, N$ 为训练样本。松弛变量 $\xi_i (\xi_i > 0)$ 用于衡量实际指示值 y_i 与 SVM 分类器输出之间的距离。 C 为惩罚因子,控制错分类程度。假设 H 为特征空间, X 为输入空间, ϕ 表示从 X 到 H 的映射, $\phi(x): X \rightarrow H$, 则核函数可定义为:

$$K(x_i, x_j) = [\phi(x_i) \cdot \phi(x_j)] \quad (13)$$

对应的决策函数变为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i^* y_i K(x_i, x) + b^* \right\} \quad (14)$$

其中, l 为支持向量的个数, α_i^* 为拉格朗日乘子, $K(x_i, x)$ 为核函数。

2 试验结果

2.1 数据采集

利用德国 BP 公司的 32 通道脑电设备对 8 个受试者分别进行运动想象脑电信号的采集。8 个受试者均为实验室成员,该试验不会对受试者造成任何伤害,且受试者身体健康并同意进行脑电信号采集。试验前先向脑电采集帽电极中打入导电膏,并将电极阻抗降至 5 kΩ 左右,采样频率设置为 500 Hz。受试者在 Matlab GUI 界面中的左右箭头的提醒下,开始进行左右手运动想象,并采集脑电数据,同时,需要对脑电信号的真实类别进行标记。试验的时序如图 2 所示:第 0~2 s 显示空白界面,第 2~3 s 界面出现一个“十”字符号,提示准备开始进行左右手运动想象试验,第 3~9 s 界面中出现向左或向右的箭头,此时受试者根据箭头方向进行左手或右手的运动想象。每位受试者每组 20 次,采集 4 组,共 80 组脑电信号的数据,其中一半数据作为训练数据进行特征提取和分类器训练,另外一半数据作为测试数据来验证分类的正确率。

2.2 预处理

脑电信号预处理的常用方法有巴特沃斯滤波器^[16]、独立成分分析 (Independent Component Analysis, ICA)^[17-18] 和主成分分析 (Principal Component Analysis, PCA)^[19-20] 等。本文主要采用了巴特沃斯滤波器对所采集的左右手运动想象脑电信号进行预处理,虽然 ICA 具有良好的盲源分离性能,




图2 试验时序图

Figure 2 Experimental sequence diagram

在脑电信号降噪领域具有良好效果,但在本试验中通过 ICA 去伪迹之后其分类正确率有所下降,因此本文在预处理环节只采用了巴特沃斯滤波器进行处理。采集被试在运动想象时, F3、F4、C3、C4、FZ、CZ、FC1、FC2、FC5、FC6 等 10 个通道的脑电信号。图 3 和图 4 分别给出了 C3 和 C4 两个通道在滤波前后的脑电信号时频域图。

2.3 试验结果

2.3.1 基于 MI 特征提取的脑网络结构图 本研究选取 F3、F4、C3、C4、FZ、CZ、FC1、FC2、FC5、FC6 共 10 个通道脑电数据进行处理,采用基于 MI 特征提取的运动想象脑机接口算法对不同导联间的关联性进行辨识。对左右手运动想象的脑网络结构进行构建,计算得到每两个导联间的因果性连接强度值,并对同一被试多次试验的左右手运动想象导联间的因果强度值取平均,确定左手运动想象脑网络显著性阈值设置为 0.227,右手运动想象脑网络显著性阈值设置为 0.187^[21],构建得到了左右手运动想象的脑网络邻接矩阵,如图 5 和表 1、表 2 所示。

2.3.2 特征融合后的模式分类结果 本研究将 MI 网络结构特征和 AR 模型参数特征融合后,采用 SVM 对左右手运动想象脑电信号进行分类器设计和分类测试。分类正确率如图 6 所示,对于 8 个受试者,基于 MI 的脑网络结构特征提取方法的平均分类正确率达到 78.24%,传统方法 AR 参数特征提取方法的平均分类正确率则达到 77.38%。另外,还研究了基于 MI 的脑网络结构特征提取方法中的参数设置问题,可通过设置其时间节拍来提高分类正确率,其分类结果如表 3 所示,在延迟 1~2 拍时分类效果要优于延迟 3~5 拍。最后,把基于 MI 的网络结构特征向量与 AR 参数特征向量相结合,平均分类正确率上升至 82.04%。试验结果表明:8 位受试者中,对受试者 S1~S7 而言,融合特征提取方法的分类正确率优于单独采用 MI 或 AR 特征提取方法的分类正确率,仅有第 8 个受试者由于个体差异性,特征融合之后的分类正确率略低于 AR 特征提取方法,但仍高于 MI 特征提取方法。




图 3 C3、C4通道滤波前脑电信号时频域图

Figure 3 Time-frequency domain diagrams of EEG signal before C3 and C4 channel filtering




图 4 C3、C4通道滤波后脑电信号时频域图

Figure 4 Time-frequency domain diagrams of EEG signal after C3 and C4 channel filtering

3 结 论

本研究针对运动想象脑电信号的脑网络结构生理特征,利用MI方法和AR方法分别对左右手运动想象脑电信号进行特征提取,并通过SVM对所提取的特征向量进行分类器设计,最终测试了左右手运动想象脑

电信号分类的正确率。试验测试结果表明:融合特征提取方法的分类效果显著优于单独使用基于MI或AR特征提取法的分类效果。本文所引入的基于因果MI计算的脑网络结构特征方法,计算过程简单,不依赖于网络结构的先验知识,大大节省了数据处理时间及数据存储空间,同时带来了较高的分类正确率,增强了脑机

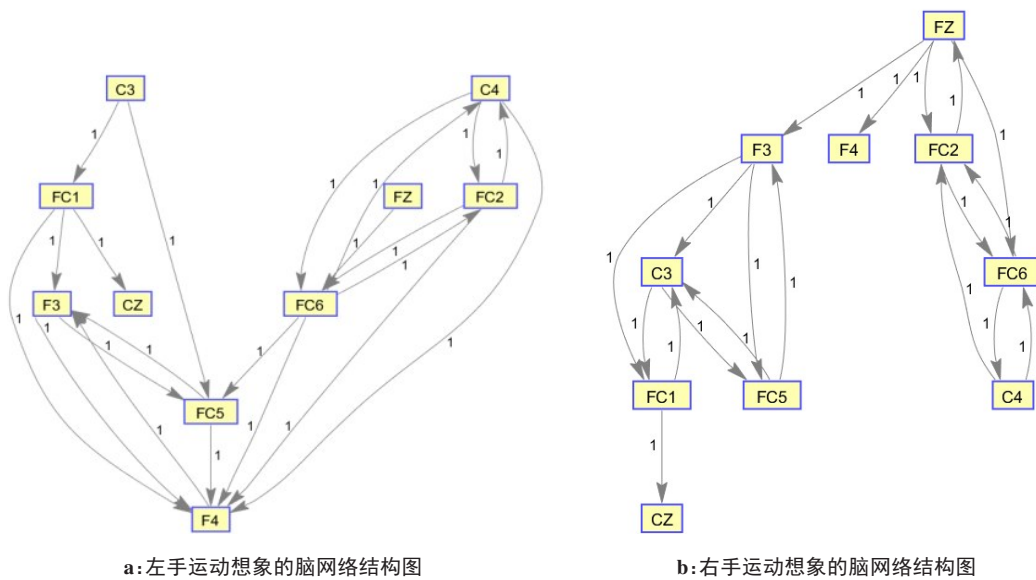


图5 左右手运动想象脑网络结构图

Figure 5 Brain network structure diagrams of left and right hand motion imagery

表1 左手运动想象的脑网络邻接矩阵

Table 1 Brain network adjacency matrix of the left hand motion imagery

通道	F3	F4	C3	C4	FZ	CZ	FC1	FC2	FC5	FC6
F3	0	1	0	0	0	0	1	0	1	0
F4	1	0	0	1	0	0	1	1	1	1
C3	0	0	0	0	0	0	0	0	0	0
C4	0	0	0	0	0	0	0	1	0	1
FZ	0	0	0	0	0	0	0	0	0	0
CZ	0	0	0	0	0	0	1	0	0	0
FC1	0	0	1	0	0	0	0	0	0	0
FC2	0	0	0	1	0	0	0	0	0	1
FC5	1	0	1	0	0	0	0	0	0	1
FC6	0	0	0	1	1	0	0	1	0	0

表2 右手运动想象脑网络邻接矩阵

Table 2 Brain network adjacency matrix of the right hand motion imagery

通道	F3	F4	C3	C4	FZ	CZ	FC1	FC2	FC5	FC6
F3	0	0	0	0	1	0	0	0	1	0
F4	0	0	0	0	1	0	0	0	0	0
C3	1	0	0	0	0	0	1	0	1	0
C4	0	0	0	0	0	0	0	0	0	1
FZ	0	0	0	0	0	0	0	1	0	0
CZ	0	0	0	0	0	0	1	0	0	0
FC1	1	0	1	0	0	0	0	0	0	0
FC2	0	0	0	1	1	0	0	0	0	1
FC5	1	0	1	0	0	0	0	0	0	0
FC6	0	0	0	1	1	0	0	1	0	0




图 6 MI 特征提取法、AR 参数特征提取法及二者融合后方法对运动想象脑电信号分类的正确率比较

Figure 6 Comparison of the accuracies of classifying motion imagery EEG signals by MI-based feature extraction method, autoregressive model-based parameter feature extraction method, and the fusion of the two methods

表 3 变量间作用延迟 τ 对基于 MI 特征提取的运动想象脑电信号分类正确率的影响(%)

Table 3 Effect of delay between variables (τ) on the accuracy of MI-based feature extraction for motor imagery EEG signals classification (%)

受试者	$\tau=1$	$\tau=2$	$\tau=3$	$\tau=4$	$\tau=5$
S1	87.00	86.50	79.50	72.00	68.25
S2	88.50	87.75	87.25	86.88	84.88
S3	82.13	81.50	82.00	81.37	80.25
S4	68.50	68.00	66.50	65.00	62.13
S5	90.75	91.75	90.25	86.62	83.13
S6	72.00	73.62	71.62	68.75	62.88
S7	69.38	68.87	66.37	63.13	62.38
S8	77.38	78.00	76.25	72.88	68.75

接口运行的稳定性,未来可进一步用来优化运动想象脑机接口的设计过程。

【参考文献】

[1] 赵欣, 陈志堂, 王坤, 等. 运动想象脑-机接口新进展与发展趋势[J]. 中国生物医学工程学报, 2019, 38(1): 84-93.
ZHAO X, CHEN Z T, WANG K, et al. New progress and development trend of brain-computer interface for motor imaging [J]. Chinese Journal of Biomedical Engineering, 2019, 38(1): 84-93.

[2] FU R R, HAN M M, TIAN Y S, et al. Improvement motor imagery EEG classification based on sparse common spatial pattern and regularized discriminant analysis[J]. J Neurosci Meth, 2020, 343(2): 108833.

[3] 高枫, 鲁昊, 高诺. 基于小波包和共同空间模型的运动想象脑电信号特征提取算法[J]. 生物医学工程研究, 2019, 38(4): 393-396.
GAO F, LU H, GAO N. Feature extraction algorithm of motor imagination EEG signal based on wavelet packet and common space model[J]. Journal of Biomedical Engineering Research, 2019, 38(4): 393-396.

[4] 刘琳琳, 陈健, 李松, 等. 基于相位同步与 AR 的运动想象脑电信号特征提取研究[J]. 软件导刊, 2018, 17(3): 7-10.
LIU L L, CHEN J, LI S, et al. Feature extraction of EEG in motion imagery based on phase synchronization and AR[J]. Software Guide, 2018, 17(3): 7-10.

[5] 李飞, 戴加飞, 李锦, 等. 自回归模型和隐马尔可夫模型在癫痫脑电识别中的应用[J]. 北京生物医学工程, 2017, 36(5): 478-482.
LI F, DAI J F, LI J, et al. Application of hidden Markov model and autoregressive model in detection of epileptic electroencephalogram [J]. Beijing Biomedical Engineering, 2017, 36(5): 478-482.

[6] 杨彬, 张爱华. 基于 BCI 的脑电信号功率谱熵分析[C]//中国自动化学会控制理论专业委员会、中国系统工程学会. 第三十二届中国控制会议论文集(C卷). 上海: 华东理工大学出版社, 2013: 4.
YANG B, ZHANG A H. Analysis of EEG signal power spectrum entropy based on BCI[C]//Control Theory Professional Committee of Chinese Society of Automation, Chinese Society of System Engineering. Proceedings of the 32nd China Control Conference (Volume C). Shanghai: East China University of Science and Technology, 2013: 4.

[7] GAREIS I E, ACEVEDO R C, ATUM Y V, et al. Determination of an optimal training strategy for a BCI classification task with LDA [C]. 2011 5th International IEEE/EMBS Conference on Neural Engineering. IEEE, 2012.

[8] DARWAN D, LIM K R, WIJAYA H, et al. Deep fluorescence imaging by laser-canning excitation and artificial neural network processing [J]. Adv Opt Mater, 2020, 8(19): 2000390.

[9] ABBAS W, KHAN N A. A discriminative spectral-temporal feature set for motor imagery classification [C]. 2017 IEEE International Workshop on Signal Processing Systems (SiPS). IEEE, 2017.

[10] LI D, ZHANG H X, SAAD KHAN M, et al. Recognition of motor imagery tasks for BCI using CSP and chaotic PSO twin SVM[J]. The Journal of China Universities of Posts and Telecommunications, 2017, 24(3): 83-90.

[11] MOON Y I, RAJAGOPALAN B, LALL U. Estimation of mutual information using kernel density estimators [J]. Phys Rev E Stat Phys Plasmas Fluids Relat Interdiscip Topics, 1995, 52(3): 2318-2321.

[12] 邓彩凤. 中文文本分类中互信息特征选择方法研究[D]. 重庆: 西南大学.
DENG C F. Research on mutual information feature selection method in chinese text classification[D]. Chongqing: Southwest University.

[13] 徐宝国, 宋爱国. 基于小波变换和 AR 参数模型的脑电信号识别方法[J]. 数据采集与处理, 2008, 23(5): 580-583.
XU B G, SONG A G. EEG recognition based on wavelet transform and AR parameter model[J]. Journal of Data Acquisition & Processing, 2008, 23(5): 580-583.

[14] 常宇. 基于运动想象的脑电信号分析与脑机接口系统设计[D]. 太原: 中北大学, 2019.
CHANG Y. EEG signal analysis and brain-computer interface system design based on motor imagination[D]. Taiyuan: North University of China, 2019.

[15] 李钢, 王蔚, 张胜. 支持向量机在脑电信号分类中的应用[J]. 计算机应用, 2006(6): 1431-1433.
LI G, WANG W, ZHANG S. Application of SVM in EEG signal classification[J]. Journal of Computer Applications, 2006(6): 1431-1433.

[16] LOW C Y, TEOH A B, NG C. Multi-fold gabor, PCA, and ICA filter convolution descriptor for face recognition[J]. IEEE Trans Circ Syst Vid, 2019, 29(1): 115-129.

[17] MAHATAS, KAR R, MANDAL D. Optimal approximation of asymmetric type fractional-order bandpass Butterworth filter using decomposition technique[J]. Int J Circ Theor App, 2020, 48(9): 1554-1560.

[18] REJER I, GÓRSKI P. Benefits of ICA in the case of a few channel EEG [C]. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2015: 7434-7437.

[19] YU X Y, CHUM P, SIM K B. Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system [J]. Optik, 2014, 125(3): 1498-1502.

[20] BATTULGA L, LEE S H, NASRIDINOV A, et al. Hash-tree PCA: accelerating PCA with hash-based grouping[J]. J Supercomput, 2020, 76(10): 8248-8264.

[21] GAO Y M, WANG X K, POTTER T, et al. Single-trial EEG emotion recognition using granger causality/transfer entropy analysis [J]. J Neurosci Meth, 2020, 346(2): 108904.

(编辑: 薛泽玲)