

基于脑功能网络和样本熵的脑电信号特征提取

罗志增* 鲁先举 周莹

(杭州电子科技大学智能控制与机器人研究所 杭州 310018)

摘要: 针对脑-机接口(BCI)研究中采用单一特征对运动想象脑电信号(EEG)识别率不高的问题, 该文提出一种结合脑功能网络和样本熵的特征提取方法。根据事件相关同步/去同步(ERS/ERD)现象以及皮层与肢体运动想象间的对侧映射机制, 选取小波包变换消噪重构后的 μ 节律脑电信号, 用左侧27个通道、右侧27个通道分别对左半球脑区和右半球脑区构建脑功能网络, 计算网络的平均节点度和平均聚集系数作为运动想象的脑功能网络特征, 并结合C3、C4通道 μ 节律的样本熵构筑分布性和指向性相结合的特征向量。选用支持向量机(SVM)对左右手运动想象脑电信号进行分类, 结果表明基于脑功能网络和样本熵的特征提取方法能够实现更优的分类效果, 分类准确率最高可达90.27%。

关键词: 脑电信号; 脑功能网络; 样本熵; 特征提取; 事件相关同步/去同步

中图分类号: TN911.7; TP391

文献标识码: A

文章编号: 1009-5896(2021)02-0412-07

DOI: 10.11999/JEIT191015

EEG Feature Extraction Based on Brain Function Network and Sample Entropy

LUO Zhizeng LU Xianju ZHOU Ying

(Institute of Intelligent Control and Robotics, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: For the low recognition rate of motor imagery ElectroEncephaloGram (EEG) signals using single feature in Brain-Computer Interface (BCI) research, a feature extraction method combining brain function network and sample entropy is proposed. According to the neural mechanism appearing in Event Related Synchronization/Event Related Desynchronization (ERS/ERD) phenomenon and the contralateral mapping mechanism between cortex and limb motor imagery, the μ rhythm is denoised by wavelet packet transform. The brain function network is constructed for left hemispherical brain region and right hemispherical brain region by μ rhythm of 27 left channels and 27 right channels respectively. The mean node degree and the mean clustering coefficient are calculated as the brain function network characteristics, and the feature vectors combining the distribution and directivity are constructed by the sample entropy of C3 and C4 channels with the μ rhythm. The Support Vector Machine (SVM) is used to classify the left hand and right hand motor imagery EEG signals. The results show that the feature extraction method based on brain function network and sample entropy achieves better classification result, and the highest classification rate reached 90.27%.

Key words: ElectroEncephaloGram (EEG); Brain function network; Sample entropy; Feature extraction; Event Related Synchronization/Event Related Desynchronization (ERS/ERD)

1 引言

脑-机接口(Brain-Computer Interface, BCI)是不依赖外周神经与肌肉组织, 在人脑和计算机之间直接建立交流通道的交互系统^[1,2]。基于运动想

象脑电信号(ElectroEncephaloGram, EEG)的假肢控制是目前BCI的主要研究方向之一, 它为运动功能障碍但思维正常的患者提供了一种新的人机交互方式, 有着重要的研究意义和广泛的应用前景^[3]。特征的选择与提取是BCI系统的关键环节, EEG特征提取常用的方法有: 傅里叶变换、功率谱、自回归模型、空-频域滤波、小波变换、希尔伯特-黄变换和小波包变换等^[4]。为了适应EEG的非线性特点, Lyapunov指数^[5]、Lempel-Ziv复杂度^[6]和样本熵^[7]等非线性动力学方法应用越来越多。但实践表明,

收稿日期: 2019-12-19; 改回日期: 2020-12-07; 网络出版: 2020-12-16

*通信作者: 罗志增 luo@hdu.edu.cn

基金项目: 国家自然科学基金(61671197)

Foundation Item: The National Natural Science Foundation of China (61671197)

单一的特征难以全面地表征EEG所蕴含的信息。

在进行单侧运动想象时，大脑同侧感觉运动区 μ 节律和 β 节律幅值增大，而对侧感觉运动区的幅值减小，称为事件相关同步/去同步(Event Related Synchronization/Event Related Desynchronization, ERS/ERD)现象^[8]。脑功能网络是通过计算各个脑区测量到的EEG信号之间的相关性而构建的复杂网络，它是对大脑结构网络中不同脑区之间动态活动交互整合的直观描述^[9]。近年来，对于脑功能网络的研究已取得初步成果。如Chaovalitwongse等人^[10]利用EEG构建脑功能网络，并把网络节点之间的欧氏距离作为特征向量输入到支持向量机中，实现对癫痫患者样本的分类识别；Stanley等人^[11]利用全局效率和局部效率网络特征来分析年轻人和老年人的大脑信息传递效率和工作记忆表现之间的关系。杨硕等人^[12]构建正常态和疲劳态脑功能网络，利用中间中心度、聚类系数和节点平均路径长度特征区分不同的脑功能状态。样本熵是一种非线性方法，它用于度量一个时间序列中产生新模式概率的大小^[7]。样本熵在EEG特征提取中已有较好应用。周鹏等人^[13]分析了左右手运动想象时感觉运动皮层的EEG信号样本熵及其动态变化规律，并利用Fisher线性分类器进行动态分类，取得较好分类效果。样本熵可以反映EEG的复杂度，但它不能分析不同脑区信号之间的关系；脑功能网络可以分析不同脑区信号间的相关性，弥补了样本熵对孤立通道信号分析的不足，但它不能反映信号的复杂度和信号新模式产生概率。因此脑功能网络和样本熵的结合，可以构筑分布性和指向性兼具的特征向量，使特征向量描述既有全局上的考虑，又能突出重点，更能全面地反映大脑运动想象的生理电活动特征。

本文用脑功能网络的结构特征和样本熵组成EEG特征向量，该特征向量从脑区功能连通性、信号复杂度两方面刻画EEG，并依托支持向量机(Support Vector Machine, SVM)对运动想象EEG进行分类。实验结果表明，基于脑功能网络和样本熵的特征提取方法能够实现更优的分类效果。

2 脑电信号特征

2.1 脑功能网络特征

虽然大脑不同区域有相对独立的功能，但即便是非常简单的意识任务也需要不同功能的脑区互相作用、互相联系，构成一个复杂的网络协调工作。脑功能网络是一种描述大脑各个区域统计性连接关系的脑网络，属于无向网络，它具有复杂网络中小世界网络的属性^[9]。构建脑功能网络的主要步骤如下：

(1) 定义网络节点：对于多通道EEG，通常把

每个EEG导联对应的电极覆盖的区域定义为一个节点。

(2) 量化节点之间的相关性：分析节点之间相关性的方法有Pearson相关系数、相干谱和互信息等方法。本文采用鲁棒性较高的Pearson相关系数法计算各通道EEG之间的相关性如式(1)所示

$$r_{ij} = \frac{\sum_{t=1}^T [x_i(t) - \bar{x}_i][x_j(t) - \bar{x}_j]}{\sqrt{\sum_{t=1}^T [x_i(t) - \bar{x}_i]^2 \sum_{t=1}^T [x_j(t) - \bar{x}_j]^2}} \quad (1)$$

其中， $x_i(t)$ 和 $x_j(t)$ 为节点 i 和节点 j 在 t 时刻的采样值， \bar{x}_i 和 \bar{x}_j 为节点 i 和节点 j 的平均采样值， $i, j=1, 2, \dots, N$ ， N 为节点数。 r_{ij} 的值介于-1和1，若 $r_{ij} < 0$ ，则取绝对值， r_{ij} 的绝对值越大，表示两节点相关性越强。计算两两节点之间的相关系数，可得到 $N \times N$ 的连接系数矩阵，该矩阵为对称矩阵。

(3) 选取合适的阈值 T ：对连接系数矩阵进行阈值处理，得到0-1矩阵 Q

$$a_{ij} = \begin{cases} 1, & r_{ij} \geq T \\ 0, & r_{ij} < T \end{cases} \quad (2)$$

$a_{ij} = 1$ 表示节点 i 和节点 j 之间存在连接边，反之则不存在连接边，根据矩阵 Q 可得到脑功能网络的拓扑结构。

(4) 计算脑功能网络特征：常用的脑功能网络测度有节点度、特征路径长度、聚集系数和网络密度等，这些测度反映了网络的结构特性。为了减少信息冗余，本文选择平均节点度 K 和平均聚集系数 C 作为脑功能网络特征，平均节点度是衡量网络规模大小的重要指标，平均聚集系数反映了网络中两个节点之间存在连接边的可能性，其定义分别为

$$K = \frac{1}{N} \sum_{i=1}^N k_i \quad (3)$$

$$C = \frac{1}{N} \sum_{i=1}^N c_i = \frac{1}{N} \sum_{i=1}^N \frac{2E_i}{k_i(k_i - 1)} \quad (4)$$

其中， N 为网络节点数， k_i 为节点 i 的度，表示与节点 i 直接连接的节点数，一个节点的度越大反映其在网络中的地位越重要； E_i 为与节点 i 直接连接的 k_i 个节点之间实际存在的边数， k_i 个节点之间最多存在 $k_i(k_i - 1)/2$ 条边， c_i 为节点 i 的聚集系数，即为 E_i 与 $k_i(k_i - 1)/2$ 的比值，因此 $0 \leq c_i \leq 1$ 。

2.2 样本熵

样本熵是Pincus^[14]在近似熵基础上提出的一种不计自身匹配的统计量，样本熵具有近似熵所有

优点的同时,避免了近似熵中统计量不一致的问题。样本熵用于衡量时间序列中产生新模式概率的大小,样本熵值越大,表示时间序列中产生新模式的概率越大,序列越复杂。计算时间序列 $z(l)(l=1, 2, \dots, M, M$ 为采样点数)样本熵的步骤如下:

(1) 将序列按顺序组成 m 维矢量

$$\mathbf{Z}_m(l) = [z(l), z(l+1), \dots, z(l+m-1)] \quad (5)$$

式中, $l = 1, 2, \dots, M - m$ 。

(2) 定义矢量 $\mathbf{Z}_m(l)$ 和 $\mathbf{Z}_m(s)$ 之间的距离为两个矢量对应元素差值中最大的一个

$$d[\mathbf{Z}_m(l), \mathbf{Z}_m(s)] = \max_{k=0,1,\dots,m-1} |z(l+k) - z(s+k)| \quad (6)$$

式中, $l, s = 1, 2, \dots, M - m$ 且 $l \neq s$ 。

(3) 给定阈值 p ,统计 $d[\mathbf{Z}_m(l), \mathbf{Z}_m(s)]$ 小于 p 的数目,记为 $A_l^m(p)$,计算该数目与距离总数目 $M - m + 1$ 的比值,记为 $B_l^m(p)$

$$B_l^m(p) = \frac{A_l^m(p)}{M - m + 1} \quad (7)$$

(4) 计算 $B_l^m(p)(l = 1, 2, \dots, M - m)$ 的平均值,记为 $B^m(p)$

$$B^m(p) = \frac{1}{M - m} \sum_{l=1}^{M-m} B_l^m(p) \quad (8)$$

(5) 将序列按顺序组成 $m + 1$ 维矢量,重复步骤(1)~(4)得到 $B^{m+1}(p)$ 。

(6) 序列的样本熵为

$$\text{SampEn}(m, p) = - \lim_{M \rightarrow \infty} \ln \frac{B^{m+1}(p)}{B^m(p)} \quad (9)$$

(7) 实际应用中,由于序列长度有限,因此采样点数为 M 的序列样本熵的估计值为

$$\text{SampEn}(m, p, M) = - \ln \frac{B^{m+1}(p)}{B^m(p)} \quad (10)$$

3 实验数据与预处理

本文实验数据来自BCI Competition IV Data Set 1,由Berlin BCI研究中心提供^[15]。实验范式为7名健康受试者(A~G)面对电脑屏幕的相应提示执行左手、右手和脚运动想象中的任意两类,其中2名受试者(A, F)选择左手和脚运动想象,另外5名受试者选择左手和右手运动想象。数据的采集电极放置符合10-20导联标准,每组数据包含59个通道的EEG信号,采样频率为100 Hz。本文实验选用B, C, D, E和G5位受试者的实验数据进行实验分析。实验过程中每名受试者均进行了200次运动想象,每个动作执行100次,单次实验持续时间为

8 s。每次实验记录过程如下:0~2 s,屏幕显示固定的交叉十字,受试者处于运动想象准备状态;2~6 s,屏幕显示向左或向右或向下的箭头,受试者根据箭头进行左手或右手或脚的运动想象;6~8 s,屏幕变为黑屏,受试者处于休息状态,表示1次实验结束。

由于EEG信号十分微弱,采集到的信号中包含很多干扰和伪迹的成分,因此有必要对数据进行预处理。ERS/ERD现象与 μ 节律(8~13 Hz)和 β 节律(13~26 Hz)有关, β 节律中部分频率是 μ 节律的谐波, μ 节律与运动或运动想象存在紧密联系^[16]。EEG信号采样频率为100 Hz,采用db5小波进行5层分解,对小波包分解后的小波系数进行重构得到 μ 节律用于后期的脑功能网络构建与特征提取。图1为受试者B右手运动想象C3通道和左手运动想象C4通道的原始EEG和小波包变换消噪重构后的 μ 节律。

4 实验结果与分析

4.1 脑功能网络特征提取

根据ERS/ERD现象与运动想象的侧映射规律,为了体现大脑运动想象左半球脑区和右半球脑区潜在的功能连通性差异,本文用 μ 节律分别对左半球脑区:AF3, F1/3/5, FC1/3/5, CFC1/3/5/7, T7, C1/3/5, CCP1/3/5/7, CP1/3/5, P1/3/5, PO1和O1共27个电极作为节点和右半球脑区:AF4, F2/4/6, FC2/4/6, CFC2/4/6/8, T8, C2/4/6, CCP2/4/6/8, CP2/4/6, P2/4/6, PO2和O2共27个电极作为节点,分别构建两侧半球脑功能网络,记为左脑功能网络和右脑功能网络,电极位置具体分布情况如图2所示。

在脑功能网络构建过程中,目前连接阈值的选取没有普遍的标准。本文阈值的选取是以构建的脑网络具有显著的小世界特性且功能连接性显著为基本原则。小世界网络概念的提出,为量化研究复杂脑网络的性质和脑功能性疾病提供了新手段。计算小世界网络特性公式为

$$\gamma = \frac{C_{\text{real}}}{C_{\text{rand}}} \gg 1 \quad (11)$$

$$\lambda = \frac{L_{\text{real}}}{L_{\text{rand}}} \approx 1 \quad (12)$$

$$\sigma = \frac{\gamma}{\lambda} \quad (13)$$

其中, C_{real} 和 L_{real} 分别为所构建真实网络的平均聚集系数和平均路径长度, C_{rand} 和 L_{rand} 分别为相同规模随机网络的平均聚集系数和平均路径长度。 σ 为度量网络是否具备小世界属性的综合指标, $\sigma > 1$




图1 受试者B原始EEG和小波包变换提取的 μ 节律




图2 电极位置分布图

表明该网络具备小世界属性，且 σ 越大说明小世界属性越强。图3为阈值按照0.05步长递增至 σ 特性分布。

由图3可知， σ 与阈值大小关系呈正相关。但是随着阈值 T 增大，网络中节点连边的数量减少，会导致网络平均节点度 K 逐渐降低。当阈值过大时，会造成网络出现较多孤立节点的现象，导致网络的功能连接性下降，进而保证不了脑网络信息的完整性。因此网络平均节点度 K 不能小于网络节点数 N 的自然对数，即 $K \geq \ln N = \ln(54) \approx 3.988$ 。当阈值 $T=0.85$ 时，脑功能网络平均节点度 K 的范围为




图3 阈值 T 按照0.05步长递增至 σ 特性分布图

5~16，满足 $K \geq \ln N$ 的关系，因此该阈值对应的脑功能网络同时保证了显著的小世界特性和功能连接性。图4为受试者B左右手运动想象的左、右脑功能网络拓扑结构，图5为受试者B左右手运动想象的左、右脑功能网络的平均节点度 K 、平均聚类系数 C 分布。

从图4可以直观地看出，右手运动想象时，左脑功能网络的网络密度大于右脑功能网络的网络密度，而左手运动想象时，右脑功能网络的网络密度大于左脑功能网络的网络密度，该结果与ERS/ERD现象一致，也反映了左、右脑功能网络的结构特性可作为对侧右手和左手运动想象EEG的分类特征。从图5可知左、右脑功能网络的平均节点度和平均聚类系数具有一定的区分度，但仍有较多样本重叠。

4.2 样本熵提取

样本熵的值与 m 、 p 和 M 3个参数有关^[7,14]：

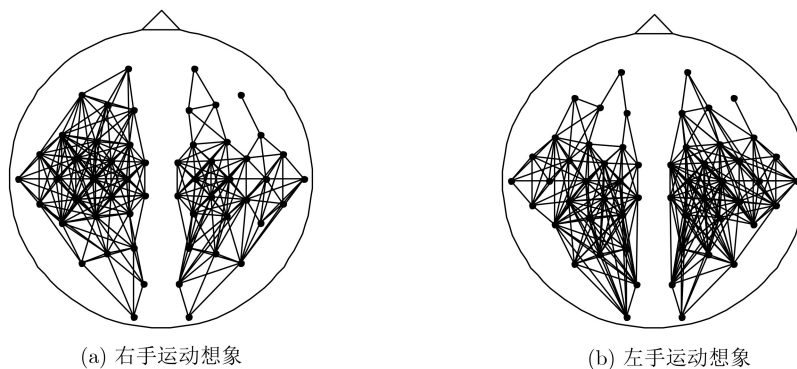


图4 脑功能网络拓扑结构




图5 左、右脑功能网络平均节点度、平均聚集系数分布

(1) 维数 m 一般取值1或2, 当 $m > 2$ 时, 要求数据量 M 在数千点以上, 但 M 过大不能保证序列具有相同的性质; M 一定时, 若 $m > 2$, 需要 p 较大才能取得较好的效果, 但是 p 太大会丢失序列的许多细节信息。Pincus^[14]研究认为 $m=2$ 比 $m=1$ 效果好, 可使序列的联合概率进行动态重构时提供更详细的信息。(2) p 用来衡量时间序列相似性的大小。如果 p 选得太小, 估计出的统计概率会不理想; 若 p 选得太大, 会丢失时间序列中很多细节, 达不到预期的效果。Pincus^[14]通过对确定性和随机过程的理论分析及其对计算和临床应用的研究, 总结出 p 取值为 $0.1 \sim 0.25SD$ (SD 为原始序列的标准差)能得出有效的统计特征。(3) M 表示输入数据点, 一般取值为 $100 \sim 5000$ 。因此根据上述原则, 本文取 $m=2$, $p=0.2SD$ 。根据实验研究发现当 $M < 100$ 时, 不同状态的脑电信号的样本熵并无太大差异; 当 $M > 100$ 时, 不同状态的脑电信号的熵值有明显差异。因此 M 取值为100。即用长度为100点, 间隔为4点的滑动窗计算EEG在运动想象期(2~6 s)的样本熵序列, 然后求该序列的均值作为该EEG的样本熵。ERS/ERD现象主要出现在C3和C4电极对应的感觉运动区上, 例如, 右手运动想象时可观测到C3电极对应的感觉运动区ERD现象, 左手运动想象时可观测到C4电极对应的感觉运动区ERD现

象^[17]。根据运动想象的ERS/ERD现象在感觉运动区的C3和C4通道表现得最为明显, 且 μ 节律与运动想象有紧密的联系, 本文分别计算C3和C4通道 μ 节律的样本熵, 使特征选择方面在全局性脑功能网络特征的基础上, 又补充指向明确的区域特征。图6是受试者B的C3和C4通道样本熵值分布。

从图6可知, C3和C4通道 μ 节律的样本熵对左右手运动想象EEG具有一定的区分度, 但仍有较多样本重叠。

4.3 支持向量机分类

本文选择支持向量机(SVM)对左右手运动想象EEG进行分类。从B, C, D, E和G每名受试者的样本数据中, 各随机取50组左手运动想象和50组右手运动想象样本, 合计500组样本作为训练集, 余下的




图6 C3和C4通道样本熵值分布

500组样本作为测试集。分别将脑功能网络特征(4维)、样本熵(2维)、脑功能网络特征与样本熵的组合(6维)作为特征向量输入SVM对左、右手运动想象EEG进行分类,分类前先对特征向量进行归一化处理, SVM的核函数选择高斯核函数。采用

10倍交叉验证确定最佳的惩罚因子 $c = 2.46$, 核参数 $g = 0.28$ 。为了减小因训练集不同而产生的误差,进行20次分类实验,取20次实验的平均正确识别率。表1为用不同特征向量重复20次分类的平均正确识别率。

表1 不同特征向量平均正确识别率与方差(%)

特征向量	受试B	受试C	受试D	受试E	受试G	平均正确识别率
脑功能网络	75.37±1.02	79.58±1.54	80.71±1.90	74.42±1.39	82.32±0.58	78.48±7.89
样本熵	70.28±1.93	76.70±2.25	74.59±3.96	69.43±1.87	77.36±1.58	73.67±11.20
脑功能网络+样本熵	85.28±0.85	89.59±0.94	87.11±1.69	83.88±0.75	90.27±0.34	87.23±5.94

从表1可知,基于脑功能网络和样本熵的所有受试平均正确识别率为87.23%,相比仅使用脑功能网络特征或样本熵作为特征向量,识别率分别提高了8.75%和13.56%。而且基于脑功能网络和样本熵特征识别率的方差低于任意单一特征,说明两种特征的融合具有更好的鲁棒性。对于受试G,平均正确识别率达到了90.27%。表2为各受试不同特征 t 检验的 p 值,从表2可知各受试不同特征之间的 p 值均小于0.01,表明不同的特征具有显著性差异。

以上结果说明,基于脑功能网络和样本熵两类特征的融合可以得到更佳分类效果,并验证了本文在特征选择上采取全局特征和局部特征相结合的方式能取得更好分类效果的设想。

为了更好地突出基于脑功能网络和样本熵的特征提取方法的有效性,本文将其与现有成熟方法进行对比说明,对比方法实验数据均来自BCI Competition IV Data Set 1,与本文采用的实验数据一致,如表3所示。

表2 各受试不同特征 t 检验的 p 值

受试	(脑网络+样本熵, 脑网络)	(脑网络+样本熵, 样本熵)
B	<0.01	<0.01
C	<0.01	<0.01
D	<0.01	<0.01
E	<0.01	<0.01
G	<0.01	<0.01

表3 不同特征提取方法平均正确识别率对比

特征提取方法	平均正确识别率(%)	实验数据来源
本文	87.23	BCI Competition IV Data Set 1
共空间模式算法 ^[18]	70.90	BCI Competition IV Data Set 1
滤波器组共空间模式 ^[18]	80.88	BCI Competition IV Data Set 1
功率谱密度 ^[19]	73.13	BCI Competition IV Data Set 1
希尔伯特-黄变换 ^[20]	84.70	BCI Competition IV Data Set 1

从表3可以看出:共空间模式算法、滤波器组共空间模式、功率谱密度和希尔伯特-黄变换方法进行分类的平均正确识别率分别为70.90%, 80.88%, 73.13%和84.70%,均低于本文基于脑功能网络和样本熵的特征提取方法,有力验证了本文提出方法的有效性。因此,基于脑功能网络和样本熵两者结合的特征提取方法可为大脑意识任务模式分类提供新思路。

5 结论

根据ERS/ERD现象与运动想象的对侧映射规律,为体现大脑运动想象左半球脑区和右半球脑区功能连通性差异,本文用 μ 节律分别对左、右半球脑区构建脑功能网络,并计算网络的平均节点度和平均聚集系数作为脑功能网络特征。为了弥补脑功能网络在运动想象区域特征描述上的不足,在脑功能网络特征基础上融合样本熵,更全面地反映大脑运动想象的生理电活动特性,故本文结合C3和C4通道 μ 节律的样本熵,将脑功能网络特征和样本熵组合作为EEG的特征向量。该特征向量充分考虑了左右脑的成对组合,并从脑区功能连通性、信号复杂度两方面更全面地描述EEG。实验结果表明,结合脑功能网络和样本熵的特征提取方法对左、右手运动想象EEG的正确识别率高于仅采用脑功能网络特征、样本熵以及其他传统特征提取算法的正确识别率。因此,本文的特征提取方法在BCI研究中具有参考价值。

参考文献

- [1] LUO Zhizeng, LU Xianju, and XI Xugang. EEG feature extraction based on a bilevel network: Minimum spanning tree and regional network[J]. *Electronics*, 2020, 9(2): 203. doi: 10.3390/electronics9020203.
 - [2] 谭平, 刘利枚, 郭璠, 等. Chernoff加权分类器框架在运动想象脑-机接口中的应用[J]. *电子与信息学报*, 2020, 42(2): 488-494. doi: 10.11999/JEIT181132.
- TAN Ping, LIU Limei, GUO Fan, et al. Applying Chernoff

- weighted classification frame method to motorimagery brain computer interface[J]. *Journal of Electronics & Information Technology*, 2020, 42(2): 488–494. doi: [10.11999/JEIT181132](https://doi.org/10.11999/JEIT181132).
- [3] 唐贤伦, 李伟, 马伟昌, 等. 基于条件经验模式分解和串并行 CNN 的脑电信号识别[J]. *电子与信息学报*, 2020, 42(4): 1041–1048. doi: [10.11999/JEIT190124](https://doi.org/10.11999/JEIT190124).
TANG Xianlun, LI Wei, MA Weichang, *et al.* Conditional empirical mode decomposition and serial parallel CNN for electroencephalogram signal recognition[J]. *Journal of Electronics & Information Technology*, 2020, 42(4): 1041–1048. doi: [10.11999/JEIT190124](https://doi.org/10.11999/JEIT190124).
- [4] MOURA A, LOPEZ S, OBEID I, *et al.* A comparison of feature extraction methods for EEG signals[C]. 2015 IEEE Signal Processing in Medicine and Biology Symposium, Philadelphia, USA, 2015: 1–2. doi: [10.1109/SPMB.2015.7405430](https://doi.org/10.1109/SPMB.2015.7405430).
- [5] BANITALEBI A, SETAREHDAN S K, HOSSEIN-ZADEH G A. A technique based on chaos for brain computer interfacing[C]. The 2009 14th International CSI Computer Conference, Tehran, Iran, 2009: 464–469. doi: [10.1109/CSICC.2009.5349623](https://doi.org/10.1109/CSICC.2009.5349623).
- [6] ABÁSULO D, HORNERO R, GÓMEZ G, *et al.* Analysis of EEG background activity in Alzheimer’s disease patients with Lempel–Ziv complexity and central tendency measure[J]. *Medical Engineering & Physics*, 2006, 28(4): 315–322.
- [7] 周静, 吴效明. 基于样本熵的睡眠呼吸暂停综合征脑电研究[J]. *中国医学物理学杂志*, 2016, 33(7): 722–725. doi: [10.3969/j.issn.1005-202X.2016.07.017](https://doi.org/10.3969/j.issn.1005-202X.2016.07.017).
ZHOU Jing and WU Xiaoming. Electroencephalogram of sleep apnea syndrome based on sample entropy[J]. *Chinese Journal of Medical Physics*, 2016, 33(7): 722–725. doi: [10.3969/j.issn.1005-202X.2016.07.017](https://doi.org/10.3969/j.issn.1005-202X.2016.07.017).
- [8] BIRBAUMER N. Breaking the silence: Brain-Computer Interfaces (BCI) for communication and motor control[J]. *Psychophysiology*, 2006, 43(6): 517–532. doi: [10.1111/j.1469-8986.2006.00456.x](https://doi.org/10.1111/j.1469-8986.2006.00456.x).
- [9] SPORNS O. Structure and function of complex brain networks[J]. *Dialogues in Clinical Neuroscience*, 2013, 15(3): 247–262.
- [10] CHAOVALITWONGSE W A, POTTENGER R S, WANG Shouyi, *et al.* Pattern- and network-based classification techniques for multichannel medical data signals to improve brain diagnosis[J]. *IEEE Transactions on Systems, Man, and Cybernetics- Part A: Systems and Humans*, 2011, 41(5): 977–988. doi: [10.1109/tsmca.2011.2106118](https://doi.org/10.1109/tsmca.2011.2106118).
- [11] STANLEY M L, SIMPSON S L, DALE D, *et al.* Changes in brain network efficiency and working memory performance in aging[J]. *PLoS One*, 2015, 10(4): e0123950. doi: [10.1371/journal.pone.0123950](https://doi.org/10.1371/journal.pone.0123950).
- [12] 杨硕, 艾娜, 王磊, 等. 脑疲劳状态的脑功能网络特征分类研究[J]. *生物医学工程学杂志*, 2018, 35(2): 171–175.
YANG Shuo, AI Na, WANG Lei, *et al.* Research on classification of brain functional network features during mental fatigue[J]. *Journal of Biomedical Engineering*, 2018, 35(2): 171–175.
- [13] 周鹏, 葛家怡, 曹红宝, 等. 基于样本熵的运动想象分类研究[J]. *信息与控制*, 2008, 37(2): 191–196. doi: [10.3969/j.issn.1002-0411.2008.02.013](https://doi.org/10.3969/j.issn.1002-0411.2008.02.013).
ZHOU Peng, GE Jiayi, CAO Hongbao, *et al.* Classification of motor imagery based on sample entropy[J]. *Information and Control*, 2008, 37(2): 191–196. doi: [10.3969/j.issn.1002-0411.2008.02.013](https://doi.org/10.3969/j.issn.1002-0411.2008.02.013).
- [14] PINCUS S. Approximate entropy (ApEn) as a complexity measure[J]. *Chaos*, 1995, 5(1): 110–117.
- [15] BLANKERTZ B, DORNHEGE G, KRAULEDAT M, *et al.* The non-invasive Berlin Brain-Computer Interface: Fast acquisition of effective performance in untrained subjects[J]. *NeuroImage*, 2007, 37(2): 539–550.
- [16] JOCHUMSEN M, ROVSING C, ROVSING H, *et al.* Classification of hand grasp kinetics and types using movement-related cortical potentials and EEG rhythms[J]. *Computational Intelligence and Neuroscience*, 2017, 2017: 7470864. doi: [10.1155/2017/7470864](https://doi.org/10.1155/2017/7470864).
- [17] NAGAMORI S and TANAKA H. Analysis method for ERD in mu-rhythm detection in motor imagery brain-computer interface[C]. 2016 IEEE International Conference on Systems, Man, and Cybernetics, Budapest, Hungary, 2017: 867–870. doi: [10.1109/SMC.2016.7844349](https://doi.org/10.1109/SMC.2016.7844349).
- [18] ZHANG Haihong, CHIN Z Y, ANG K K, *et al.* Optimum spatio-spectral filtering network for brain-computer interface[J]. *IEEE Transactions on Neural Networks*, 2011, 22(1): 52–63. doi: [10.1109/TNN.2010.2084099](https://doi.org/10.1109/TNN.2010.2084099).
- [19] 李静, 王金甲, 李慧. 融合脑电特征的弹性网特征选择和分类[J]. *生物医学工程学杂志*, 2016, 33(3): 413–419. doi: [10.7507/1001-5515.20160070](https://doi.org/10.7507/1001-5515.20160070).
LI Jing, WANG Jinjia, and LI Hui. Selection and classification of elastic net feature with fused electroencephalogram features[J]. *Journal of Biomedical Engineering*, 2016, 33(3): 413–419. doi: [10.7507/1001-5515.20160070](https://doi.org/10.7507/1001-5515.20160070).
- [20] 袁玲, 杨帮华, 马世伟. 基于HHT和SVM的运动想象脑电识别[J]. *仪器仪表学报*, 2010, 31(3): 649–654. doi: [10.19650/j.cnki.cjsi.2010.03.029](https://doi.org/10.19650/j.cnki.cjsi.2010.03.029).
YUAN Ling, YANG Banghua, and MA Shiwei. Discrimination of movement imagery EEG based on HHT and SVM[J]. *Chinese Journal of Scientific Instrument*, 2010, 31(3): 649–654. doi: [10.19650/j.cnki.cjsi.2010.03.029](https://doi.org/10.19650/j.cnki.cjsi.2010.03.029).
- 罗志增: 男, 1965年生, 博士, 教授, 研究方向为生物信息处理与分析、机器人技术、传感器及多信息融合等。
- 鲁先举: 男, 1995年生, 硕士生, 研究方向为模式识别、脑-机接口及相关应用等。
- 周莹: 男, 1993年生, 硕士生, 研究方向为脑-机接口。