

基于连续小波变换和符号传递熵的脑功能网络构建方法

李明爱^{1,2,3}, 张圆圆¹

(1. 北京工业大学信息学部, 北京 100124; 2. 计算智能与智能系统北京市重点实验室, 北京 100124;
3. 教育部数字社区工程研究中心, 北京 100124)

摘要: 为有效利用运动想象脑电信号(Motor Imagery Electroencephalogram, MI-EEG)的频域信息并精确反映脑电极之间的非线性因果交互作用, 本文提出一种基于连续小波变换和符号传递熵的脑功能网络构建方法. 首先, 对每导 MI-EEG 进行连续小波变换, 求得其时-频-能量矩阵; 然后, 将与运动想象密切相关的频带内各频率所对应的时间-能量序列依次拼接, 得到各导联的一维时频能量序列; 最后, 基于任意两电极时频能量序列间的符号传递熵计算连接矩阵, 构建脑功能网络. 实验结果表明, 以电极时频能量序列间的符号传递熵构建的脑功能网络, 能够有效反映 MI-EEG 的时频特征和非线性特征信息传递, 相比于传统脑网络构建方法, 更有利于增强不同运动想象任务的可行性.

关键词: 脑-机接口; 运动想象脑电信号; 连续小波变换; 符号传递熵; 脑功能网络

中图分类号: TP18

文献标识码: A

文章编号: 0372-2112(2022)07-1600-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210298

A Brain Functional Network Based on Continuous Wavelet Transform and Symbolic Transfer Entropy

LI Ming-ai^{1,2,3}, ZHANG Yuan-yuan¹

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China;

2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China;

3. Engineering Research Center of Digital Community (Ministry of Education), Beijing 100124, China)

Abstract: In order to utilize the frequency domain information of motor imagery electroencephalogram (MI-EEG) signals to effectively and accurately reflect the nonlinear causal interaction between different EEG electrodes, this paper presents a brain functional network based on continuous wavelet transform and symbolic transfer entropy. Firstly, the continuous wavelet transform is applied to each MI-EEG signal to compute the time-frequency-energy matrix. Then, the one-dimensional time-frequency energy sequence of each channel is obtained by joining serially spliced time-energy sequence in the frequency band closely related to motor imagery. Finally, the brain connectivity matrix is calculated based on the symbolic transfer entropy between the time-frequency energy sequences of any two channels, and the brain functional network is constructed. The experiment results show that the brain functional network constructed with the symbolic transfer entropy between time-frequency energy sequences can effectively reflect the time-frequency characteristics and nonlinear characteristic information transmission of MI-EEG. Compared with the traditional brain network construction method, it is beneficial to enhance the separability of different motor imagery tasks.

Key words: brain-computer interface; motor imagery electroencephalography; continuous wavelet transform; symbolic transfer entropy; brain functional network

1 引言

脑-机接口 (Brain-Computer Interface, BCI) 技术不

依赖于传统的肌肉和神经通路, 通过采集到的脑电信号直接解读大脑意识, 实现人机或人与周围环境之间

的通信^[1]. 运动想象脑电信号(Motor Imagery ElectroEncephaloGraphy, MI-EEG)是指人在没有执行实际动作的情况下大脑想象肢体运动时产生的脑电信号,其包含了大量的神经生理信息,已被广泛应用于BCI领域^[2,3]. 人脑是一个复杂而密集的网络,由数十亿相互连接的神经元组成,在执行运动想象任务时,信息始终在不同脑功能区之间相互传递和整合. 近年来,基于图论的复杂网络分析方法被广泛应用于神经科学中,通过复杂网络基本原理可以进行大脑属性分析,以及发现脑网络节点间潜在的信息传递关系. 越来越多的研究表明,利用脑功能网络(Brain Functional Network, BFN)中的度量来区分运动想象脑电信号具有一定的可行性^[4,5]. 因此,从BFN的角度研究不同MI任务下的大脑活动模式,对揭示运动想象背后的神经机制具有重要的意义.

构建BFN时,节点通常是EEG电极,而边定义为节点之间的连接性. 计算连接性的指标主要分为两类:功能连接和有效连接. 在现有的文献中^[6,7],大多数关于脑功能网络的研究都是基于功能连接度量进行的. Kim等人^[8]使用相关系数(Correlation Coefficient, CC)来估计脑网络节点之间的连接性,结果表明,执行左手和右手运动想象任务时,网络节点的CC值高于脚和舌头,且额叶和顶叶区电极之间的CC值在也存在显著不同. Gong等人^[9]提出一种基于时频交叉互信息(Cross Mutual Information, CMI)的脑功能网络建模方法,研究了四类运动想象任务(左手,右手,脚和舌头)下大脑的生理机制;他们利用统计分析发现不同任务下大脑的反应水平、反应时间和激活靶区都存在明显的差异. Filho等人^[10]提出一种基于图案同步法(Motifs' Synchronization, MS)的脑功能网络构建方法,针对BCI2000数据集中十名受试者的左手和右手MI-EEG进行模式识别. 结果显示,在 α 频带和 β 频带上,平均分类准确率均达到了83%. 然而,功能连接度量仅能捕获电极之间在统计意义上的相互依赖性,却无法提供信息流动的方向以及不同神经结构之间的因果关系.

有效连接可描述节点之间的因果交互作用,相比于功能连接,它能更容易发现运动想象过程中节点之间隐藏和被忽视的连接性. Hu等人^[11]使用基于时不变双变量自回归(Bivariate Autoregressive, BVAR)模型的格兰杰因果指数(Granger Causality, GC)研究了运动想象任务的大脑因果信息流. 他们发现在左手和右手运动想象期间,Cz导联与C3/C4之间的方向性连接有很大不同. Ghosh等人^[12]提出一种基于多元自回归模型(MultiVariate AutoRegressive, MVAR)定向转移函数(Directed Transfer Function, DTF)的BFN构建方法,实验结果表明,利用网络节点度和网络密度可有效区分左手、右手和舌头的MI-EEG信号. 不足的是,GC和

DTF依赖于线性自回归模型,使得它们难以准确地反映出人脑这种高度非线性系统中存在的因果关系.

传递熵(Transfer Entropy, TE)是一种基于非参数统计的信息理论量,它不需要预先假设交互作用的模型,可用于衡量两个非线性向量之间信息交互,是研究大脑信息流的理想方法^[13]. 符号传递熵(Symbolic TE, STE)是传递熵的一种变体,具有计算速度快,抗噪声能力强等优点^[14]. 已有研究人员将其应用于脑功能网络的构建中,并根据不同MI任务下节点间连接性的差异来区分运动想象脑电信号^[15]. 然而,现有方法直接通过计算原始MI-EEG之间的连接性来构建BFN,难以充分利用脑电信号在频域上的特征信息.

为此,本文提出了一种基于连续小波变换(Continuous Wavelet Transform, CWT)和STE的脑功能网络构建方法,将EEG电极的时频能量序列作为网络节点的输入信号,并使用符号传递熵计算脑电极之间的非线性因果交互作用. 在BCI 2000公开数据集上进行了实验研究,以验证本文方法的有效性和优越性.

2 方法

本文提出了一种基于连续小波变换和符号传递熵的脑功能网络建模方法,其主要步骤如下:

2.1 基于CWT获取EEG的时频能量序列

2.1.1 连续小波变换

连续小波变换通过小波函数的伸缩和平移将信号分解成不同尺度上的小波系数,已被广泛应用于信号的时频分析和处理领域^[16]. 对于任意能量有限信号 $s(t)$,其连续小波变换的公式为

$$\text{WT} = \left\langle s(t), \psi_{a,b}(t) \right\rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} s(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

式中,WT为小波系数, a 为尺度因子, b 为平移量, $\psi(t)$ 为母小波函数, $\psi_{a,b}(t)$ 为伸缩平移后的小波函数, $\psi^*(t)$ 为 $\psi(t)$ 的共轭复数.

2.1.2 获取MI-EEG的时频能量序列

设 $X_i = \{x_n^i\}$ 为第 i 导脑电信号, $i=1,2,\dots,L$; $n=1,2,\dots,M$. L 代表导联数, M 为采样点数. 对 X_i 进行连续小波变换,并截取与运动想象密切相关的频带内的小波系数,得到其小波系数矩阵 $W_i = \{WT_{fn}^i\}$, $f=f_p, \dots, f_q$. f_p 和 f_q 分别为小波分解后感兴趣频带的左、右边界频率, WT_{fn}^i 表示第 i 导脑电信号在 n 时刻 f 频率时的小波系数值. 将小波系数模长的平方作为信号的小波能量值 e_{fn}^i ,即

$$e_{fn}^i = \left| \text{WT}_{fn}^i \right|^2 \quad (2)$$

进而,求得感兴趣频带内的时频能量矩阵

$e_i = \{e_{jm}^i\}$. 将 e_i 各行依次进行拼接, 得到第 i 导联电信号的一维时频能量序列, 记为: $E_i = \{E_t^i\}, t=1, 2, \dots, N_i$.

$N_i = (f_q - f_p + 1) \times M$ 为序列 E_i 的长度.

2.2 基于符号传递熵构建脑功能网络

2.2.1 序列符号化

计算符号传递熵的第一步是对信号进行符号化, 设 $U_i^i = \{E_t^i, E_{t+\lambda}^i, E_{t+2\lambda}^i, \dots, E_{t+(D-1)\lambda}^i\}$ 为序列 E_i 中 D 个元素的集合, λ 为延迟因子, D 为符号阶次. 根据 U_i^i 内各采样点幅值的大小排列情况定义符号 s_t^i (由于脑电信号的高噪声特性, 不考虑相邻采样点相等的可能性):

$$s_t^i = \begin{cases} 1, & \text{if } E_t^i > E_{t+\lambda}^i > E_{t+2\lambda}^i > \dots > E_{t+(D-1)\lambda}^i \\ 2, & \text{if } E_{t+\lambda}^i > E_t^i > E_{t+2\lambda}^i > \dots > E_{t+(D-1)\lambda}^i \\ \vdots & \vdots \\ D, & \text{if } E_{t+\lambda}^i > E_{t+2\lambda}^i > \dots > E_{t+(D-1)\lambda}^i > E_t^i \\ \vdots & \vdots \\ D!, & \text{if } E_{t+(D-1)\lambda}^i > \dots > E_{t+2\lambda}^i > E_{t+\lambda}^i > E_t^i \end{cases} \quad (3)$$

用符号 s_t^i 对 U_i^i 进行标注, 可得到 E_i 的符号序列, 记为: $E_i^s = \{s_t^i\}$. 图 1 为 $D=3, \lambda=1$ 时, 序列符号化的示意图.




图 1 序列符号化示意图

2.2.2 符号传递熵

符号传递熵根据符号序列中各符号出现的相对频率来估计联合概率分布和条件概率分布. 对于两个符号序列 $E_i^s = \{s_t^i\}$ 和 $E_j^s = \{s_t^j\}$, 它们之间的符号传递熵可通过下式计算:

$$\text{STE}(E_i^s \rightarrow E_j^s) = \sum p(s_{t+\tau}^j, s_t^j, s_t^i) \log_2 \left(\frac{p(s_{t+\tau}^j | s_t^j, s_t^i)}{p(s_{t+\tau}^j | s_t^j)} \right) \quad (4)$$

式中, $p(\cdot)$ 为概率密度函数, τ 为时间滞后.

2.2.3 构建脑功能网络

以 L 个 EEG 电极为节点, 将任意两导脑电信号时频能量序列之间的符号传递熵作为连接边, 计算脑功能网络的连接矩阵 A :

$$A = \begin{pmatrix} a_{11} & \dots & a_{1L} \\ \vdots & \ddots & \vdots \\ a_{L1} & \dots & a_{LL} \end{pmatrix} \in \mathbf{R}^{L \times L} \quad (5)$$

式中, $a_{ij} = \text{STE}(E_i^s \rightarrow E_j^s)$ 为节点 i 到节点 j 之间的符号传递熵, $i, j=1, 2, \dots, L$.

3 实验研究

为了验证本文方法的有效性, 本文分析了不同运动想象任务的脑功能网络, 并分别以连接矩阵元素和脑网络特征参数作为分类器的输入, 对 MI-EEG 信号进行模式分类.

3.1 实验数据及预处理

实验使用的 MI-EEG 数据来自于 BCI 2000 公开数据库^[17], 共记录了 64 个头皮电极的脑电数据, 电极分布位置如图 2 所示. 采集的 EEG 经过 1 Hz~50 Hz 带通滤波及 50 Hz 陷波滤波, 采样频率为 160 Hz. 该数据库共包含 109 名受试者, 每名受试者进行约 45 次实验, 想象任务为左手或右手运动, 每次实验持续约 8 s, 其中 0 s~4 s 为运动想象期.




图 2 电极位置与导联序号分布图

构建 BFN 的一个关键挑战是体积传导效应, 它会导致头皮电极之间产生虚假连接性, 从而误导对脑网络的分析. 共平均参考 (Common Average Reference, CAR) 使用所有导联的平均值对信号进行重定位, 可有效减小体积传导效应^[18]. 因此, 本文在预处理阶段截取了 0 s~4 s 想象期的 MI-EEG 数据, 并使用 CAR 滤波器对其进行空间滤波.

3.2 基于连接矩阵的 MI-EEG 识别

3.2.1 计算有效连接矩阵

根据 2.1 节, 使用连续小波变换对预处理后的脑电信号进行时频分解, 图 3 为基于 Morlet 连续小波变换对某次实验 C3 导联 MI-EEG 信号进行分解后得到的时频

能量图,横轴为时间,纵轴为频率,颜色代表小波能量值.在执行运动想象任务时,事件相关去同步(ERD)/事件相关同步(ERS)现象大多出现在 Mu 节律(8 Hz~13 Hz)和 Beta 节律(13 Hz~30 Hz)上^[19].因此,本文分别截取了时频能量图的 α (8 Hz~13 Hz)和 β (13 Hz~30 Hz)两个频带进行分析.以 β 频带为例,小波分解后 β 频带范围覆盖 12 个离散频率,记为: f_1, f_2, \dots, f_{12} ,将其对应的时间-能量序列依次拼接后得到一维时频能量序列,如图 4 所示.

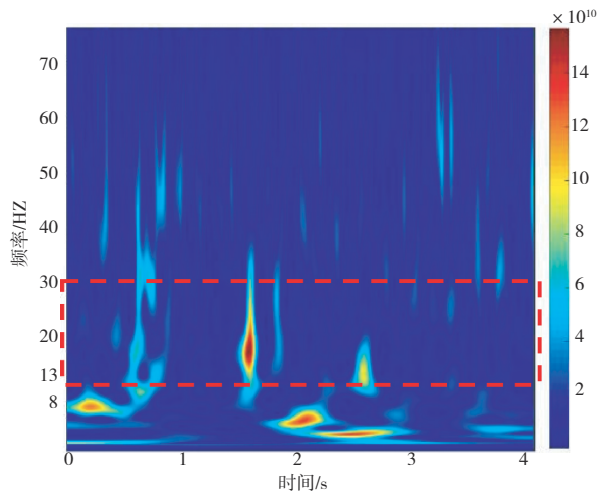


图3 C3 导联 MI-EEG 的时频能量图






图4 C3 导联 β 频带的一维时频能量序列

以 64 个 EEG 电极作为脑网络的节点,计算任意两个电极时频能量序列之间的符号传递熵(实验中 λ 和 τ 均设为 1),得到 64×64 的有效连接矩阵.图 5 展示了受试者 S1 的连接矩阵图,其横轴与纵轴均表示导联序号,且导联与电极之间的一一对应关系与图 2 中一致,矩阵

中的元素代表两个导联之间的因果连接性.由图可见,大脑在进行想象左手运动和想象右手运动两类任务时,节点之间的连接性具有显著不同,图中紫色圆圈标记了两类想象任务连接性显著不同的部位.当想象左手运动时,位于中央区右侧的 C4 节点与位于前额右侧的节点(FC2、FC4、FC6)之间的连接性远大于想象右手运动;而想象右手运动时,信息由顶叶右半区传递至前额叶左半区,位于顶叶右侧的节点(如 P2、P4)与前额叶左侧的 FP1 节点之间的连接性明显强于想象左手运动.



(a) 想象左手运动



(b) 想象右手运动

图5 受试者 S1 两类想象任务的大脑连接矩阵图

3.2.2 特征选择和分类

大脑进行运动想象时,并非所有区域都会被激活,使用连接矩阵中的全部元素作为特征可能不利于 MI-EEG 的识别.因此,有必要对矩阵进行优化.

对于每名受试者,本文通过计算大脑连接矩阵各位置元素与类别标签之间的皮尔逊(Pearson)相关系数

值来优化矩阵元素,将相关性较小的元素置零,保留相关性较大的元素.提取优化后矩阵的非零元素构成特征向量,采用支持向量机(Support Vector Machine, SVM)分类器进行模式分类,并借助网格搜索法确定SVM分类器的最优超参数^[20].由于每名受试者的实验次数较少,本文使用留一法对样本进行测试,即每次分类使用一次实验的MI-EEG数据作为测试集,剩余44次实验数据作为训练集,最终结果取45次分类结果的平均值.

图6显示了受试者S1的分类准确率随皮尔逊相关系数阈值的变化情况.由图知,阈值的选择对分类准确率有着较大的影响,当阈值小于等于0.30时,分类准确率逐渐升高;而当阈值大于0.30时,分类准确率则出现了明显下降;当阈值设为0.30时,分类准确率达到最大值100.00%,从而确定S1的最优皮尔逊相关系数阈值为0.30.依此方法,确定其他每名受试者的最优Pearson相关系数阈值.




图6 受试者S1的分类准确率

此外,本文还对比了Wrapper和Fisher滤波这两种不同特征选择算法的分类准确率,结果如表1所示,表中准确率为109名受试者的平均值.从表1中可以看出,当不使用特征选择算法时(表中None),分类效果较不理想,平均准确率仅为63.95%;而使用特征选择算法优化矩阵元素后,分类准确率有了大幅度的提升,且三种特征选择算法的准确率相近.使用Pearson特征选择算法的准确率最高,达到了94.75%,而使用Wrapper时的准

准确率为94.46%,使用Fisher滤波时结果为94.74%.这说明使用有效连接矩阵中的全部元素构建特征向量,会造成特征信息的冗余,并不利于MI-EEG的分类.

表1还给出了不同特征选择算法在达到平均分类正确率时所需要的特征数目,可以看出,当使用Pearson特征选择算法时,所需特征数目最少,仅为120个,相比于未进行矩阵优化时的4096个特征,极大地降低了分类的计算成本.

表1 不同特征选择方法的平均准确率对比

	特征选择算法			
	None	Wrapper	Fisher	Pearson
准确率	0.639 5	0.944 6	0.947 4	0.947 5
特征数目	4 096	190	130	120

3.2.3 选取母小波函数

与传统脑网络构建方法不同,本文首先基于CWT求取信号的时频能量序列,然后将电极时频能量序列之间的符号传递熵作为网络的边,进一步提取了EEG信号的时频特征.为了选择最适合表达MI-EEG信号时频信息的母小波函数,本节将针对不同母小波函数的分类结果展开讨论.

实验选取了五种经典的母小波函数进行对比研究,分别为:Haar小波、Daubechies小波、Mexican Hat小波、Meyer小波和Morlet小波.表2同时给出了基于不同小波函数获得的109名受试者的平均分类准确率以及单个受试者的最高准确率,表中的None则表示未对EEG信号进行连续小波变换,仅将各通道EEG信号之间的符号传递熵作为网络连接边时的识别正确率.

从表中可以看出,不同频带下的分类准确率略有差异,且 β 频带的正确率均高于 α 频带,这可能是由于受试者在进行左手、右手运动想象时, β 频带的ERD/ERS生理现象更加明显.同时,无论是在 α 频带还是 β 频带,当以原始EEG信号之间的符号传递熵为边构建脑功能网络时,得到的平均分类准确率是最低的,这是由于原始脑电信号难以体现MI-EEG在频域上差异,而连续小波变换通过在时间和频率两个尺度上对信号进行分解,可以较好地提取信号在频域上的特征,进而为正确识别脑电信号提供了更多的有用信息.此外, Daubechies、Meyer和Morlet三个小波函数在两个频带

表2 不同小波函数的分类准确率

频带	准确率	小波函数					
		None	Haar	Daubechies	Mexican Hat	Meyer	Morlet
α	平均准确率	0.833 6	0.841 3	0.833 6	0.872 6	0.862 7	0.907 8
	最高准确率	0.955 6	0.977 8	1.000 0	1.000 0	1.000 0	1.000 0
β	平均准确率	0.841 3	0.907 0	0.897 0	0.874 5	0.914 0	0.947 5
	最高准确率	0.977 8	1.000 0	1.000 0	0.977 8	1.000 0	1.000 0

下单个受试者的最高分类准确率均为 100.00%,但 Morlet 小波的平均分类正确率最高,在 α 频带达到了 90.78%,在 β 频带为 94.75%;这表明,相比于其他四个母小波函数, Morlet 小波函数能够更好地表达出 MI-EEG 的时频特性,并且对于不同受试者能表现出较好的鲁棒性. 因此,基于 Morlet 小波函数的连续小波变换将用于本文后续的实验中.

3.2.4 确定最优符号阶次

计算两个信号之间的符号传递熵的第一步是对信号进行符号化,为了不丢失 EEG 信号的时间信息,实验应确保每个符号都尽可能地出现在信号中. 根据文献 [21],对于长度为 N_i 的信号,符号阶次 D 应满足 $N_i \gg D!$. 因此,本文选取 $D=2, \dots, 6$ 进行了对比研究,实验结果如图 7 所示,图中准确率为 109 名受试者的平均分类准确率. 总体来看,无论是 α 频带还是 β 频带,随着符号阶次的增加,分类准确率先升高后降低. 除此之外, β 频带的正确率仍然高于 α 频带,这一结果与 3.2.3 节类似;当 $D=2$ 时,分类准确率最低,为 87.97%; $D=4$ 时,准确率达到了最大值 94.75%;而当 D 继续增大时,正确率则发生了下降,这可能是由于 $D=4$ 时最能吻合该数据集脑电信号的复杂性.




图 7 不同符号阶次的平均识别准确率

3.3 基于网络拓扑特征参数的 MI-EEG 分类

3.3.1 计算脑网络特征参数

为了进一步研究在不同运动想象任务下大脑各区域的激活模式,本文计算了两个重要的脑网络参数:度和中间中心性. 由于二值化有效连接矩阵可能会丢失部分重要的网络信息,本文使用文献 [22] 中的方法计算加权网络的特征参数:

(1) 度 (Degree)

节点度的计算式如下:

$$d_i = \sum_j a_{ij} \quad (6)$$

式中, a_{ij} 为节点 i 和节点 j 之间的连接性,节点的度越大,表明该节点与其他节点之间的连接性就越强.

(2) 中间中心性 (Betweenness Centrality, BC)

节点 i 的中间中心性可由式 (7) 计算:

$$bc_i = \frac{2}{(N-1)(N-2)} \sum_{i \neq j \neq k} \frac{l_{jk}(i)}{l_{jk}} \quad (7)$$

式中, $l_{jk} = \frac{1}{a_{jk}}$ 为特征路径长度, $l_{jk}(i)$ 为经过节点 i 的特征路径长度. 节点的中间中心性越高,该节点承载的信息量就越大,对脑功能网络的影响也越大.

依据式 (6),计算所有节点的度,构成特征向量 F_D :

$$F_D = [d_1, d_2, \dots, d_L] \in \mathbf{R}^{1 \times L} \quad (8)$$

由式 (7),计算每个节点的中间中心性,构成特征向量 F_{BC} :

$$F_{BC} = [bc_1, bc_2, \dots, bc_L] \in \mathbf{R}^{1 \times L} \quad (9)$$

将 F_D 与 F_{BC} 串行融合,获得融合特征向量 F_{D+BC} :

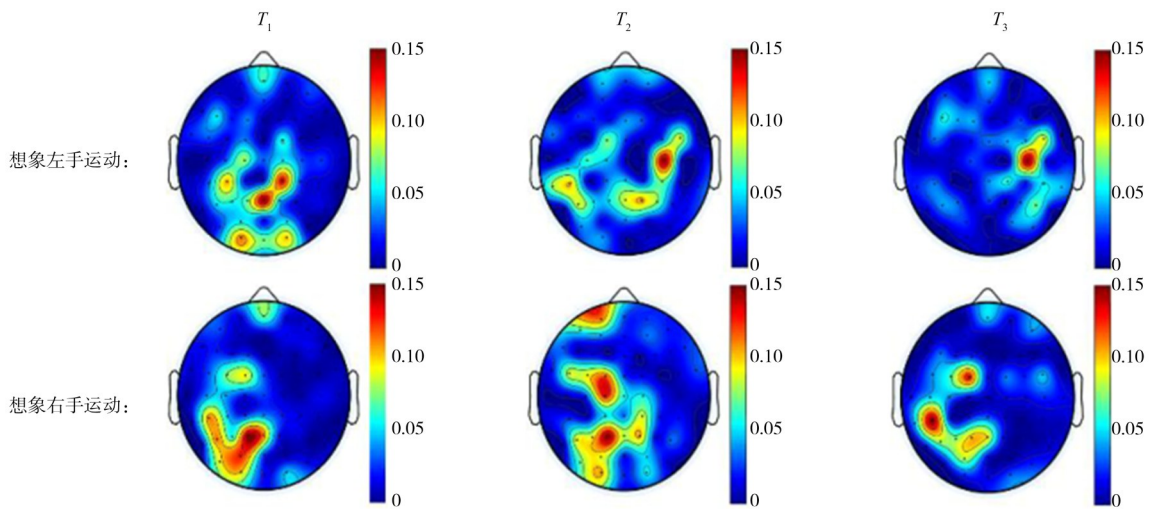
$$F_{D+BC} = [F_D \quad F_{BC}] \in \mathbf{R}^{1 \times 2L} \quad (10)$$

为了体现脑功能网络的时变特性,本节采用窗长为 2 s,步长为 1 s 的滑动时间窗将原始数据划分为 $T_1(0 \text{ s} \sim 2 \text{ s})$ 、 $T_2(1 \text{ s} \sim 3 \text{ s})$ 和 $T_3(2 \text{ s} \sim 4 \text{ s})$ 三个时间段,每个时间段数据共包含 320 个采样点. 对每个时间段信号分别构建脑功能网络,并计算特征向量.


3.3.2 基于网络特征参数的 MI-EEG 分类

图 8(a) 展示了在不同时间段内,想象左手运动和想象右手运动的脑地形图,使用的特征参数为度. 可以看出,随着时间的变化,大脑的激活区域呈现一定的变化规律,但总体来看,执行左手运动想象任务时,位于右侧脑皮层的节点强度更大,而执行右手运动想象时,位于大脑左侧区域的节点度更高. 图 8(b) 为使用中间中心性作为特征参数时的脑地形图,对比于图 8(a),本文也能得到类似的结果. 这从复杂网络的角度进一步阐述了 ERD/ERS 现象在运动想象任务中的模式,即大脑在执行手部运动想象任务时,对侧脑功能区更有可能被激活.

此外,本文还尝试以度和中间中心性来构建特征向量对两类 MI-EEG 进行模式分类. 同样使用 Pearson 特征选择算法优选贡献度较大的特征. 图 9 展示了 β 频带下 $D=4$ 时 T_1 、 T_2 和 T_3 三个时间段的分类准确率及平均分类准确率. 可以看出,仅使用 BC 值作为特征时,三个时间段的平均准确率为 86.20%;仅使用 Degree 时,三个时间段的平均准确率为 89.83%;将 Degree 与 BC 融合时,平均准确率为 92.38%. 特别地,在 T_2 时段,使用 BC 和 Degree 融合特征时,分类准确率达到 93.55%,这一结果接近



(a) 度



(b) 中间中心性

图8 不同时间段的脑地形图

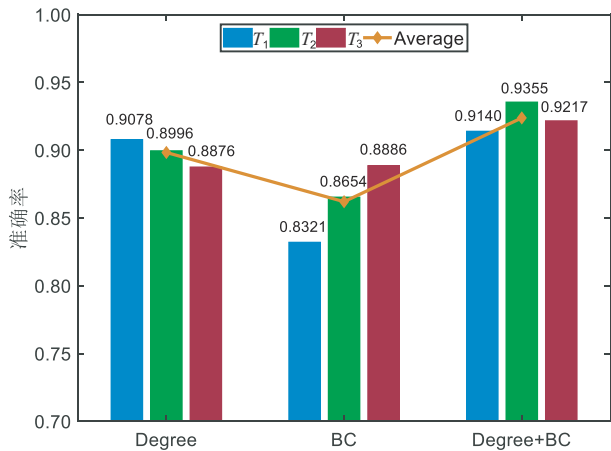


图9 不同时间段的分类准确率

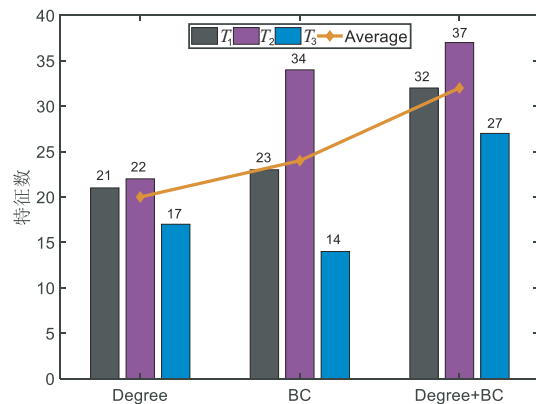


图10 获得图9准确率所需的特征数目

于使用连接矩阵元素作为特征时的准确率94.75%。此外,图10还给出了达到图9分类准确率时所需的特征数

目。可见,当使用网络特征参数进行分类时,达到最优准确率所需的特征数目仅为32,这相比于使用连接矩阵元

素 a_{ij} 作为特征时的数目减少了约 3/4.

3.3.3 多种脑网络特征提取方法对比

为了验证本文提出的脑功能网络构建方法的优越性,本节还对比了不同方法在该数据集下的分类性能,结果如表 3 所示,表中分别计算了将有效连接矩阵元素 a_{ij} 以及脑网络参数 Degree+BC 作为分类器输入时 109 名受试者的平均分类准确率和 Kappa 值. 从表中可以看出,互信息(CMI)和相关系数(CC)的分类准确率较低,这是由于它们无法衡量 EEG 电极之间连接的方向性,造成特征信息的丢失;而格兰杰因果指数(GC)和定向传递函数(DTF)能够表示信号之间的因果连接性,这种连接性是具有方向的,从而为脑电信号的识别提供了更多的有用信息. 不足的是,GC 和 DTF 是基于线性回归模型估计的,将其应用于人脑这样的非线性动力系统中难免会存在一定的局限性. 相比之下,符号传递熵更适合反映脑电极之间的交互作用,且这种交互作用是有向的、非线性的,符合人脑的非线性动力学特性,因此取得了最高的分类准确率和 Kappa 分数. 本文还对比了文献[10]中使用图案同步法(MS)在相同数据集下的分类结果,当以连接矩阵元素 a_{ij} 为特征时,平均分类准确率提升了 11.59%;当以 Degree 和 BC 为特征时,准确率提高了 11.41%,显示了本文方法的有效性和优越性.

表 3 基于多种脑功能网络方法的 109 名受试者平均分类准确率和 Kappa 值对比

方法	平均分类准确率		平均 Kappa 值	
	a_{ij}	Degree+BC	a_{ij}	Degree+BC
CC [8]	0.701 0	0.609 6	0.660 8	0.587 7
CMI [9]	0.622 8	0.457 0	0.598 2	0.365 6
GC [11]	0.909 6	0.751 6	0.827 7	0.701 3
DTF [12]	0.874 2	0.872 6	0.799 4	0.778 1
MS [10]	0.831 6	0.809 7	0.775 3	0.767 7
Ours	0.947 5	0.923 8	0.858 0	0.809 0

4 结论

本文提出了一种基于 CWT 和 STE 的脑功能网络建模方法,克服了传统脑网络构建方法易丢失脑电信号的频域信息这一不足,并能够准确地反映不同节点之间的非线性因果交互作用. 在 BCI 2000 公开数据集上的实验结果表明,虽然不同运动想象任务的 BFN 具有一定差异性,但大脑对 MI 任务的反应是局部的. 当使用网络连接矩阵的全部元素作为特征时,分类效果并不理想,而合理使用特征选择算法可以较大幅度地提高识别正确率;此外,本文发现在执行手部运动想象任务时,位于大脑对侧功能区节点的 Degree 和 BC 值大于同侧,这从复杂网络的角度进一步阐述了在进行运动

想象时大脑的 ERD/ERS 生理现象;同时,本文还尝试了以网络特征参数 Degree 和 BC 为特征对 MI-EEG 信号进行识别,获得的分类准确率十分接近于直接使用 a_{ij} 时的结果,而特征向量的长度更小,这减少了分类的计算成本. 最后,对比了多种脑功能网络构建方法的分类性能,本文方法均获得了最高的平均分类准确率和 Kappa 值,这说明本方法能有效地体现运动想象脑电信号的时频特征和非线性特征,相比于其他方法具有显著优势. 这一改进有助于脑科学的研究,并将扩大脑网络分析方法在 EEG 中的应用.

在未来的工作中,我们将进一步筛选合适的脑网络拓扑特征参数,深入研究运动想象过程中大脑的神经生理机制以及脑网络的动态变化规律;同时尝试将脑功能网络分析方法与其他方法相结合进行多元特征提取,以进一步提高 BCI 系统中 MI-EEG 的识别正确率.

参考文献

- [1] WOLPAW JR, BIRBAUMER N, MCFARLAND DJ, et al. Brain-computer interface for communication and control [J]. *Clinical Neurophysiology*, 2002, 113(6): 767-791.
- [2] GOMEZ-PILAR J, CORRALEJO R, NICOLAS-ALONSO LF. Neurofeedback training with a motor imagery-based BCI: Neurocognitive improvements and EEG changes in the elderly[J]. *Medical & Biological Engineering & Computing*, 2016, 54(11): 1655-1666.
- [3] HAMED M, SALLEH S H, NOOR A M. Electroencephalographic Motor imagery brain connectivity analysis for BCI: A review[J]. *Neural Computation*, 2016, 28(6):1-43.
- [4] RODRIGUES P G, FILHO CAS, ATTUX R, et al. Space-time recurrences for functional connectivity evaluation and feature extraction in motor imagery brain-computer interfaces[J]. *Medical & Biological Engineering & Computing*, 2019, 57: 1709-1725.
- [5] 张娜, 孙炎璐, 李明爱. 一种个性化动态脑功能网络的构建与特征提取方法[J]. *北京生物医学工程*, 2020, 39(6): 551-560.
ZHANG N, SUN YJ, LI MA. A personalized dynamic brain functional network and feature extraction [J]. *Beijing Biomedical Engineering*, 2020, 39(6): 551 - 560. (in Chinese)
- [6] GAO Z, WANG Z, MA C, et al. A wavelet time-frequency representation based complex network method for characterizing brain activities underlying motor imagery signals [J]. *IEEE Access*, 2018, 6: 65796-65802.
- [7] 彭丝雨, 周到, 张家琦, 王宇, 高军峰. 基于互信息的脑网

- 络及测谎研究[J]. 电子学报, 2019, 47(7): 1551-1556.
- PENG S Y, ZHOU D, ZHANG J Q, WANG Y, GAO J F. Research on mutual information-based brain network and lie detection[J]. Acta Electronica Sinica, 2019, 47(7): 1551-1556. (in Chinese)
- [8] CHUNG Y G, KIM M K, KIM S P. Inter-channel connectivity of motor imagery EEG signals for a noninvasive BCI application[C]//IEEE International Workshop on Pattern Recognition in Neuroimaging. Cambridge: ACM, 2011: 49-52.
- [9] GONG A, LIU J, CHEN S, et al. Time-frequency cross mutual information analysis of the brain functional networks underlying multiclass motor imagery[J]. Journal of Motor Behavior, 2018, 50(3): 254-267.
- [10] FILHO C A S, ATTUX R, CASTELLANO G. EEG sensorimotor rhythms' variation and functional connectivity measures during motor imagery: Linear relations and classification approaches[J]. PeerJ, 2017, 5: 3983.
- [11] HU S, WANG H, ZHANG J, et al. Causality from Cz to C3/C4 or between C3 and C4 revealed by granger causality and new causality during motor imagery[C]//International Joint Conference on Neural Networks. Beijing: IEEE, 2014: 3178-3185.
- [12] GHOSH P, MAZUMDER A, BHATTACHARYYA S, et al. Functional connectivity analysis of motor imagery EEG signal for brain-computer interfacing application[C]//2015 7th International IEEE/EMBS Conference on Neural Engineering. Montpellier, France: IEEE Press, 2015: 210-213.
- [13] BAIG M Z, KAVAKLI M. Connectivity analysis using functional brain networks to evaluate cognitive activity during 3D modelling[J]. Brain Sciences, 2019, 9(2): 24.
- [14] STANIEK M, LEHNERTZ K. Symbolic transfer entropy [J]. Physical Review Letters, 2008, 100(15): 158101.
- [15] PANCHE I D L P, ALVAREZ-MEZAA M, OROZCO-GUTIERREZ A. A data-driven measure of effective connectivity based on renyi's α -entropy[J]. Frontiers in Neuroscience, 2019, 13: 1277.
- [16] GAO Z, WANG Z, MA C, et al. A wavelet time-frequency representation based complex network method for characterizing brain activities underlying motor imagery signals[J]. IEEE Access, 2018, PP(99): 1-1.
- [17] SCHALK G, MCFARLAND DJ, HINTERBERGER T, et al. BCI2000: A general-purpose brain-computer interface(BCI) System[J]. IEEE Transactions on Biomedical Engineering. 2004, 51(6): 1034-1043.
- [18] BRUNNER C, BILLINGER M, SEEGER M, et al. Volume conduction influences scalp-based connectivity estimates[J]. Frontiers in Computational Neuroscience. 2016, 10: 121.
- [19] NEUPER P C. Motor imagery activates primary sensorimotor area in humans[J]. Neuroscience Letters, 1997, 239(2): 65-68.
- [20] ZHU X, LI P, LI C, et al. Separated channel convolutional neural network to realize the training free motor imagery BCI systems[J]. Biomedical Signal Processing and Control, 2019, 49(3): 396-403.
- [21] ROMAN B, GUISANDE N, GRANADO M. Characterization of visuomotor/imaginary movements in EEG: An information theory and complex network approach[J]. Frontiers in Physics, 2019, 7: 115.
- [22] FILHO C A S, ATTUX R, CASTELLANO G. Can graph metrics be used for EEG-BCIs based on hand motor imagery? [J]. Biomedical Signal Processing & Control, 2018, 40(2): 359-365.

作者简介



李明爱 女, 1966年7月出生, 河南鹤壁人. 2006年于北京工业大学获得博士学位, 现为北京工业大学教授、博士生导师, 主要研究方向为脑机接口技术、人工智能与智能康复.

E-mail: limingai@bjut.edu.cn



张圆圆 男, 1996年12月出生, 安徽安庆人. 现为北京工业大学信息学部硕士研究生, 主要研究方向为脑机接口技术、信号处理与模式识别.

E-mail: zyybjutemail@emails.bjut.edu.cn