

运动态人脑默认模式网络脑电信息 传递动力学行为分析

李佳佳, 冯钊, 赵亮

(西安建筑科技大学信息与控制工程学院, 710055, 西安)

摘要: 为探究人体进行运动相关任务时大脑默认模式网络与其他脑区间的连接规律, 基于运动及运动想象脑电信号公开数据集, 通过快速傅里叶变换对不同状态下的脑电信号划分频段并进行滑动加窗处理, 得到静息与运动态下同皮层不同频段的平均时间序列。采用动态传递熵的构造方法, 分析默认模式网络到运动皮层、默认模式网络到前额叶皮层的信息交互, 并在多个数据集下进行显著性检验。将动态传递熵的分析方法结合逻辑回归、决策树、XGBoost 算法对不同任务进行分类研究, 结果表明: 大脑不同皮层功能区在进行不同任务时具有显著差异; 相较于静息态, 前额叶皮层和运动皮层在运动过程中更加活跃, γ 频段相较其他频段也更加活跃; 相较于静息态, 运动态及运动想象态下默认模式网络到运动皮层、默认模式网络到前额叶皮层的信息交互都更强烈, 其结果在不同样本空间的显著性检验 P 值小于 0.025, 此方法稳健; 脑电信号动态传递熵方法可以将机器学习算法的分类准确率提高 20% 以上。研究可为运动态脑电信号辨识提供理论参考。

关键词: 默认网络; 传递熵; 有向网络; 脑电信号

中图分类号: TN911.7 **文献标志码:** A

DOI: 10.7652/xjtuxb202306003 **文章编号:** 0253-987X(2023)06-0018-11

Dynamic Behavior Analysis of Electroencephalogram Information Transmission in Human Brain Default Mode Network

LI Jiajia, FENG Zhao, ZHAO Liang

(School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: To explore the connection rule of the default mode network (DMN) of the brain and other brain areas when the human body performs motor-related tasks, based on the public dataset of motor and motor imagery electroencephalogram (EEG) signals, the EEG signals in different states were divided into frequency bands by fast Fourier transform (FFT) and subjected to sliding windowing processing, and the average time sequences of different frequency bands in the same cortex in resting and moving states were obtained. The construction method of dynamic transfer entropy was used to analyze the information interaction from the default mode network to the motor cortex and the default mode network to the prefrontal cortex, and the significance test was performed on multiple data sets. Finally, the dynamic transfer entropy analysis method was combined with the logic regression, decision tree, and XGBoost algorithm for classified study of different tasks. The results showed that different functional regions of cerebral cortex showed

收稿日期: 2022-08-29。 作者简介: 李佳佳(1989—), 男, 副教授, 硕士生导师; 赵亮(通信作者), 男, 教授, 硕士生导师。

基金项目: 国家自然科学基金资助项目(12002251)。

网络出版时间: 2023-03-10

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1069.T.20230310.1442.002.html>

significant differences when performing different tasks. Compared with the resting state, the prefrontal cortex and motor cortex were more active during the exercise, and the γ band was more active than other bands. Compared with the resting state, the information interaction between the default mode network and the motor cortex, and between the default mode network and the prefrontal cortex was more intense in the motor and motor imagery states. The P value of the significance test in different sample spaces was less than 0.025, indicating the robustness of the method. The electroencephalogram dynamic transfer entropy method can improve the classification accuracy of the machine learning algorithm by more than 20%. This study has provided a reliable theoretical reference for dynamic EEG signal identification.

Keywords: default mode network; transfer entropy; directed network; electroencephalogram signal

近年来,运动态头皮脑电(electroencephalogram, EEG)测试技术已逐渐成为脑机接口(brain computer interface, BCI)相关领域的支撑技术^[1]。研究表明,默认模式网络(default mode network, DMN)与运动感知相关皮层的关联性对运动刺激具有极强的敏感性,进而被广泛应用于BCI相关领域的研究中^[2-5]。Van Geest等^[6]实验发现,在静息态到任务负荷增强过程中,DMN功能连接显著提高,表明DMN的连接性与任务负荷的增加有关。Hugdahl等^[7]关于静息态与任务处理周期间DMN的研究表明,DMN与外部模式网络(运动区、额叶、顶叶等)存在相互作用,表现为一种负相关关系。Dayan等^[8]在关于运动感知的研究中表明,DMN作为功能结构连接最密集的区域,在运动刺激下与运动相关的皮层区域结构高度连接,DMN区域的活动与运动敏感区存在负相关关系^[9]。

目前,许多非线性动力学的方法广泛应用到脑电信号研究中。用该方法对脑电信号进行重构可以提取相关非线性指标来研究脑电信号的内在特征,常见的非线性特征分析方法有近似熵、传递熵、样本熵等研究方法。近似熵作为一种度量序列复杂性的指标,主要用有效的统计过程来区分各种过程,但近似熵的算法复杂,保留的信息多,实现困难^[10]。样本熵作为近似熵的一种改进算法,在较短时间的脑电序列计算中效果较好,主要是通过衡量时间序列中产生的概率进行计算,但是算法的实现相对复杂^[11]。传递熵是在信息熵的基础上发展的,对比上述两种方法,可以更好地度量两个生物系统的信息流向和转移量,因此使用传递熵的方法研究脑电信号研究时可以更好地判断信息的传递方向,量化非线性神经元相互作用^[12]。

在关于脑区关联性的研究中,Khoshnoud等^[13-14]等通过使用近似熵、模糊熵等方法对额叶、中央皮

质、颞叶等脑区进行分析,证明了脑区的功能连接关系。默认网络作为人脑基线状态下最核心的脑区,关于其功能连接性的研究目前还较少。Cai等^[15]进行脑区关联性研究时使用约束典型相关分析等方法,但未使用熵的相关分析方法。传递熵作为一种非线性动力学的分析方法^[16-17],目前在工程领域、金融领域等方面已经得到了广泛应用^[18-20],在脑电信号处理中也受到了广泛的关注^[21],传递熵的方法可以利用脑电通道间的信息交互^[22],实现信息的有向连通性^[23-24]。利用传递熵检测大脑网络的节点连接性^[25],可以更精确地识别节点,达到更好的研究效果,该方法也被用于疲劳驾驶脑区信息强度连接^[26]、运动神经系统中脑肌电耦合的研究中^[27-29],都取得了较好的研究效果。并且,传递熵的研究方法可以结合格兰杰因果法、图理论、相干分析法、互信息等方法以获得更好的实验结果^[30-31]。因此,利用传递熵的有向性进行默认模式网络与其他脑区功能连接性研究可以补充目前研究的不足。

本文研究在运动相关任务下,DMN与运动相关皮层功能连接性相比静息态的统计显著性,通过动态传递熵与时频分析的结合,利用传递熵有向性的优点,从功能连接角度实现运动态刺激下的DMN动力学行为分析。主要研究过程如下:对原始脑电(EEG)信号去除眼动、工频干扰等伪迹信号,采用快速傅里叶变换及滑动窗口对脑电数据进行波段划分,并对不同节律下的EEG构造传递熵有向网络,进而对整个运动相关过程中的DMN与其他皮层间动态传递熵进行分析,并对不同样本空间数据进行假设检验;在对EEG信号进行动态传递熵特征提取的基础上,结合机器学习决策树、逻辑回归、XGBoost方法对不同任务下的EEG信号进行分类,并与原始EEG特征提取下的分类精度进行对比。

1 研究理论和实验方法

1.1 数据及预处理

运动及运动想象采用的两组 BCI 头皮脑电数据分别来自 PhysioNet(数据集 1)^[32]和 GigaDB(数据集 2)^[33]的关于运动/运动想象的数据集。采样频率分别为 160、512 Hz,通道数均为 64,被试人数分别为 109 和 52。本研究脑电信号为皮层脑电,遵照“10-20 标准”进行电极排布。根据运动认知最相关功能脑区的分布,大脑在执行不同动作时表现出分区化的特点,本文重点分析默认网络、前额叶皮层(prefrontal cortex, PFC)和初级运动皮层(primary motor cortex, 用符号 M1 表示)的感兴趣区(region of interest, ROI)。默认皮层在静息态更加活跃,前额叶皮层在包括运动等多种认知过程中进行参与^[34],运动皮层通常在进行运动时更活跃^[35]。完整的默认网络包括额中回(middle frontal gyrus, MFG)、角回(angular gyrus, AG)、中颞叶皮质(middle temporal cortex, MTC)、额叶皮质(frontal cortex, FG)、后内侧皮质(posteromedial cortex, PMC)、内侧前额叶皮质(medial prefrontal cortex, MPFC)等脑区。本文研究的默认网络主要针对角回。对应脑区的空间区域参考文献[36-37],分布范围及标准电极图如图 1 所示。




图 1 实验分析采用的标准 64 电极图

Fig. 1 Standard 64-electrode diagram used in the experiment analysis

数据集 1 的实验任务包括:1 min 静息态(睁眼,闭眼),2 min 4 种不同类型的运动相关任务状态(张开或握紧左右拳(Mo1),打开或握紧左右拳运动想象(I1),打开或握紧双拳或双脚(Mo2),打开或握紧双拳或双脚运动想象(I2))。

数据集 2 实验任务包括:静息态,左手运动态(ML),右手运动态(MR),左手运动想象态(IL),右手运动想象态(IR)。

两组数据集的基本任务都包含静息、运动、运动想象。

1.2 EEG 数据的时频分析方法

为从无序的脑电信号中观测到更直观的本质特征,找出想要研究的频率成分进行解析,本文对时间域的信号进行快速傅里叶变换(fast Fourier transform, FFT)。

利用 FFT,本文将原始 EEG 信号从时域变换至频域中,从每个电极中提取原始 EEG 信号,比较多个频段(θ (4~7 Hz)、 α (8~13 Hz)、 β (14~25 Hz)、 γ (30~50 Hz))下不同状态的皮层信息,并重点对 γ 频段进行分析。

1.3 EEG 数据的传递熵分析方法

理解大脑不同部分、不同皮层的连通性和因果关系十分有必要。作为量化两个系统或者变量相关程度或混沌程度的参数,传递熵可用于处理有限长度的生理信号数据,对表征运动脑电信号的皮层区域之间的关联性具有显著效果。基于此,本文采用传递熵的方法进行脑电信号的相关分析^[38]。

将时间序列用矩阵形式表示。设具有耦合关系的皮层脑电信号时间序列(用矩阵形式表示)为 $\mathbf{X} = \{x(n), n=1, 2, \dots, N\}$ 和 $\mathbf{Y} = \{y(n), n=1, 2, \dots, N\}$ 。由通道 $\mathbf{X}$ 到通道 $\mathbf{Y}$ 的传递熵定义为 $T_{\mathbf{X} \rightarrow \mathbf{Y}}$,则两个通道序列关系为

$$T_{\mathbf{X} \rightarrow \mathbf{Y}} = H(y_{t+u} | \mathbf{y}_t^n) - H(y_{t+u} | \mathbf{x}_t^m, \mathbf{y}_t^n) \quad (1)$$

式中: t 是离散时间; u 是时间预测值; $\mathbf{x}_t^m$ 和 $\mathbf{y}_t^n$ 分别表示 m 和 n 维的延迟向量; $H(y_{t+u} | \mathbf{y}_t^n)$ 表示 $t+u$ 时刻下的通道 $\mathbf{Y}$ 基于 t 时刻下的通道 $\mathbf{Y}$ 下的条件熵,从条件熵的计算公式可以得到

$$H(y_{t+u} | \mathbf{y}_t^n) = - \sum_{y_{t+u}} p(y_{t+u}, \mathbf{y}_t^n, \mathbf{x}_t^m) \log(p(y_{t+u} / \mathbf{y}_t^n)) \quad (2)$$

其中, p 表示概率, $H(y_{t+u} | \mathbf{x}_t^m, \mathbf{y}_t^n)$ 表示 $t+u$ 时刻的通道 $\mathbf{Y}$ 基于 t 时刻的通道 $\mathbf{X}$ 与通道 $\mathbf{Y}$ 共同作用的条件熵,计算式为

$$H(y_{t+u} | \mathbf{x}_t^m, \mathbf{y}_t^n) = - \sum_{y_{t+u}} p(y_{t+u}, \mathbf{y}_t^n, \mathbf{x}_t^m) \log(p(y_{t+u} / \mathbf{y}_t^n, \mathbf{x}_t^m)) \quad (3)$$

因此,通道 $\mathbf{X}$ 对于通道 $\mathbf{Y}$ 的传递熵可以表示为

$$T_{\mathbf{X} \rightarrow \mathbf{Y}} = \sum_{y_{t+u}, \mathbf{y}_t^n, \mathbf{x}_t^m} p(y_{t+u}, \mathbf{y}_t^n, \mathbf{x}_t^m) \log \frac{p(y_{t+u} | \mathbf{x}_t^m, \mathbf{y}_t^n)}{p(y_{t+u} | \mathbf{y}_t^n)} =$$

$$\sum_{y_{t+u}, y_t^n, x_t^m} p(y_{t+u}, y_t^n, x_t^m) \log \frac{p(y_{t+u}, y_t^n, x_t^m) p(y_t^n)}{p(y_{t+u}, y_t^n) p(y_t^n, x_t^m)} \quad (4)$$

通过式(4)可得两个脑电通道的传递熵,传递熵越大,说明此通道间耦合越强,反之亦然。为得到不同大脑通道的传递熵,定义所有的大脑通道信号为时间序列 $\mathbf{X}, \mathbf{Y}$, 构建传递熵矩阵。在本文分析中,将默认网络、运动皮层、前额叶皮层的脑电通道通过求和取平均值的方法将多通道数据降低为一维数组,并作为序列 $\mathbf{X}, \mathbf{Y}$, 构建皮层 ROI 间动态传递熵。

1.4 机器学习相关方法

1.4.1 决策树

决策树是一种基于各种情况发生概率的决策分析方法。本文基于动态传递熵的研究方法,设 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 为提取脑电信号中特征的训练数据集,其中, $x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})^T$ 为输入实例(特征向量),使之可以对数据集进行正确的分类。

在决策树分类脑电任务的构建中,通过 Gini 系数对分类准确率进行评估。Gini 系数是指样本集合中一个随机选中的样本被分错的概率,Gini 系数的计算式^[39]为

$$G(\mathbf{X}) = \sum_{x \in \mathbf{X}} p(x)(1 - p(x)) \quad (5)$$

将脑电训练数据集 D 放在根节点,训练数据集划分为若干子集,确保每个子集在当前条件下具有最低 Gini 系数,每个子集都作为叶节点,在进行分类时,每个样本通过各个决策分支往下找,找到叶子即为分类结果。测试集与训练集的占比分别为 20% 和 80%,random_state 设置为 2 020,splitter 设置为 random,确保决策树分枝时更随意,限制树的最大深度,有效抑制过拟合。

1.4.2 XGBoost

本文使用的 XGBoost 分类器由一系列 CART 作为基分类器构成,该算法对代价函数进行了二阶泰勒展开,并加入了正则项、支持列抽样和缺失值处理,支持利用多线程并行计算,极大地提升了训练速度和预测精度。

在分类时, $y_i = (1, 2, \dots, k), i = 1, 2, \dots, N$ 作为样本标记,该特征下的预测模型^[40]为

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (6)$$

式中: K 为树的数量; $f_l(x_i)$ 表示第 l 棵树; $\hat{y}_i$ 表示样本的预测结果。模型的目标函数由损失函数和正

则项 Ω 两部分组成

$$\mathcal{O}(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(\theta)}) + \sum_{i=1}^l \Omega(f_i) \quad (7)$$

在整个训练过程中,目标函数采用加法分步的策略。优化第一棵树之后再优化第二棵树,每加入一棵树,损失函数不断降低,直至优化完 K 棵树。超参数的取值对分类模型性能有较大的影响,为了得到较好的分类结果,通过网格调参进行参数的选取。学习率设置为 0.3,下采样设置为 0.9,colsample_bytree 设置为 0.6,max_depth 设置为 8。

1.4.3 逻辑回归

使用逻辑回归模型进行动态传递熵脑电任务分类。逻辑回归模型通过 Logistic 函数转换为线性模型,提供概率预测^[41]。Logistic 函数为

$$\text{Logistic}(i(z)) = \frac{1}{1 + e^{-z}} \quad (8)$$

Logistic 函数是单调递增函数,在 $z=0$ 的时候取值为 0.5,并且 Logistic($i(z)$) 函数的取值范围为 (0,1)。回归的基本方程为 $z = w_0 + \sum_{i=1}^N w_i x_i$,将回归方程写入其中得到

$$p = p(y = 1 | x, \vartheta) = h_{\vartheta}(x, \vartheta) = \frac{1}{1 + e^{-(w_0 + \sum_{i=1}^N w_i x_i)}} \quad (9)$$

所以, $p(y = 1 | x, \vartheta) = h_{\vartheta}(x, \vartheta), p(y = 0 | x, \vartheta) = 1 - h_{\vartheta}(x, \vartheta)$ 。因此,本文在使用逻辑回归进行分类时,将脑电信号 $x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})^T$ 作为输入特征, $y_i = (1, 2, \dots, k)$ 作为标签, ϑ 为估计量。由此可知,对于函数 Logistic($i(z)$) = $\frac{1}{1+e^{-z}}$,当 $z \geq 0$ 时, Logistic($i(z)$) ≥ 0 , 分类为 1,当 $z < 0$ 时, Logistic($i(z)$) < 0 , 分类为 0。Logistic($i(z)$) 可视为类别的概率预测值。

采用该方法进行预测分类时,选取相同的测试集和训练集比例,random_state 设置为 2 020,在训练好模型后,评估模型效果并进行分类预测。

2 实验结果与分析

2.1 ROI 脑区 EEG 有向网络的构建及分析

2.1.1 ROI 脑区的 EEG 动态时频域动态分析

大脑默认皮层与前额叶、运动皮层在不同运动态时的激活状态如图 2 所示。一般在静息态下,默认网络皮层的活动与静息态呈正相关,运动皮层和前额叶皮层的活动与静息态呈负相关,因此在静息态下默认网络到运动皮层及默认网络到前额叶皮层的

联系比较弱^[42]。与静息态相反的是,运动皮层和前额叶的活动与运动态呈正相关,因此运动态下默认网络到运动皮层及默认网络到前额叶皮层的联系增强,在运动结束后二者之间的联系又会减弱^[43]。




图 2 大脑默认皮层与前额叶、运动皮层在不同运动态下的激活状态

Fig. 2 Information communication between the cortex DMN and PFC and M1 during different motion states

为证明不同频段、不同皮层在整个运动中的动态变化,提取 α 和 γ 频段下的脑电信号,并根据大脑区域的脑电极点分布划分脑电信号,进行滑动加窗处理,得到静息与运动态下同皮层不同频段的平均时间序列,如图 3 所示。

一般来说,在清醒放松状态下,大脑会出现规律且有恒定频率的 α 波动,在成年人中占主导地位。整个静息过程的动态变化也表明, α 频段比 γ 频段更活跃。通过分析不同大脑皮层可知,静息态默认网络比前额叶皮层和运动皮层更活跃。

与静息态相比,在运动过程中,前额叶皮层和运动皮层比默认网络平均功率更高,整个运动过程中皮层更加活跃。并且,不同频段的信号幅值变化也有比较显著的区别, γ 频段比 α 频段的信号幅值更高, γ 频段更活跃,表明 γ 频段与各种高等认知活动如注意行为状态及运动状态等相关, γ 频段在大脑认知活动中的起着至关重要的作用,对于运动态头皮脑电 γ 频段的研究十分有必要。




图 3 不同频段不同皮层内通道的平均 EEG 时间序列

Fig. 3 Dynamic average time series of different frequency bands and different cortex channels

2.1.2 基于传递熵方法的有向网络分析

为验证不同频段及脑区的大脑信息强度在进行运动时的参与度,利用传递熵的分析方法,对不同状态下 θ 、 α 、 β 、 γ 共 4 个频带的脑电信号构建有向网络,结果如 4 和图 5 所示。

可以看出,静息态默认网络的传递熵比其他皮层的大。在运动态下,默认网络传递熵较小,运动皮层以及前额叶皮层传递熵较大,尤其在 α 频段(图 5(b))和 γ 频段(图 5(d))更为显著。该结果完全符合默认网络及运动皮层在不同状态下参与度不同的理论。




图 4 静息态不同频段的有向网络

Fig. 4 Directed networks in different frequency bands in resting state




图 5 运动态不同频段的有向网络

Fig. 5 Directed networks in different frequency bands in motion state

2.2 ROI 脑区动态传递熵及显著性统计分析

2.2.1 基于滑动时间窗的动态传递熵分析

为了分析不同被试在进行不同运动相关行为时的共同特征,利用动态传递熵的构造方法,分别分析 DMN 与 M1、DMN 与 PFC 脑区活动的信息交互。对上述的两个数据集中的所有状态进行滑动加窗操作,窗口大小为 0.25 s,重叠窗口大小为 0.19 s,以加强实

验结果的准确性。数据集 1 单一被试 6 种状态下的动态传递熵如图 6 所示。可以看出,在数据集 1 中,对比两类静息态,运动态以及运动想象态下 DMN 与 M1 及 DMN 与 PFC 的传递熵强度呈强正相关,信息的流向更强烈。表明大脑在进行运动相关行为时,大脑脑区间具有显著的信息交互。因此,大脑脑区间的信息交互特征可助力 BCI 领域中的运动识别研究。




图 6 数据集 1 单一被试 6 种状态下 DMN 流向 M1、PFC 的 γ 频段动态传递熵序列

Fig. 6 The dynamical γ -band TE between the DMN to M1 and PFC across 6 different states in dataset 1

2.2.2 数据集 1 的显著性统计分析

基于滑动时间窗的动态传递熵方法得到数据集 1 的双侧 t 检验,如图 7 所示。图中:R 表示静息态;**** 表示对应 0.01% 显著水平,即 $P<0.000\ 05$ 。可以看出,对比静息态,不同运动态以及运动想象态下,动态传递熵的各项统计指标均处于显著性较高的水平,与单一被试动态传递熵的研究结果相同,表明了在进行相关任务时大脑皮层间信息强度增强的结果具有显著性。




图 7 数据集 1 中 4 种运动任务态相对静息态的皮层间传递熵显著性统计

Fig.7 Statistics of γ -band dynamic transfer entropy for DMN to M1 and PFC between the resting state and other four motion in dataset 1

表 1 给出了该数据集下两种静息动态传递熵的均值与运动态、运动想象态动态传递熵进行显著性检验的结果,表中 T 为统计值。可以看出,在数据集 1 中,DMN 同 M1 以及 DMN 同 PFC 的动态传递熵在运动相关状态对比静息态存在显著性差别。

表 1 数据集 1 显著性检验结果

Table 1 Significance test results in dataset 1

状态	皮层	T	P
Mo1	DMN→M1	6.490 4	$2.672\ 8\times10^{-9}$
	DMN→PFC	7.455 7	$2.363\ 3\times10^{-11}$
Mo2	DMN→M1	9.712 1	$2.107\ 5\times10^{-16}$
	DMN→PFC	9.305 4	$1.768\ 2\times10^{-15}$
I1	DMN→M1	6.610 9	$1.500\ 2\times10^{-9}$
	DMN→PFC	8.344 93	$1.507\ 1\times10^{-13}$
I2	DMN→M1	8.733 4	$3.471\ 0\times10^{-14}$
	DMN→PFC	7.941 7	$2.031\ 8\times10^{-12}$

2.2.3 数据集 2 的显著性统计分析

使用相同的动态传递熵构造方法对数据集 2 中 5 种状态进行显著性检验,结果如图 8 所示。图中: * 表示对应 5% 显著水平,即 $P<0.025$; ** 表示对应 1% 显著水平,即 $P<0.005$; *** 表示对应 0.1% 显著水平,即 $P<0.000\ 5$ 。可以看出,相比静息态,运动态以及运动想象态下的动态传递熵均处于比较高

的水平。




图 8 数据集 2 中 4 种运动任务态相对静息态的皮层间传递熵显著性统计

Fig.8 Statistical significance analysis of transfer entropy between cortex of four motor task states relative to resting state in dataset 2

表 2 给出了运动相关任务状态对比静息态的动态传递熵显著性检验结果。可以看出,在数据集 2 中,DMN 同 M1 以及 DMN 同 PFC 的静息态与任务态存在显著性差别。与之前的分析结果一致,进一步验证了之前的实验结果。

表 2 数据集 2 显著性检验结果

Table 2 Significance test results in dataset 2

状态	皮层	T	P
ML	DMN→M1	7.500 6	$8.829\ 6\times10^{-10}$
	DMN→PFC	9.378 8	$1.096\ 2\times10^{-12}$
MR	DMN→M1	9.822 0	$2.370\ 9\times10^{-13}$
	DMN→PFC	8.030 7	$1.300\ 9\times10^{-10}$
IL	DMN→M1	3.119 2	0.003 0
	DMN→PFC	3.800 9	$3.860\ 2\times10^{-4}$
IR	DMN→M1	2.767 7	0.007 8
	DMN→PFC	2.547 2	0.013 9

2.3 机器学习融合传递熵的运动脑电信号分类分析

2.3.1 研究方法及步骤

构建运动相关任务时,动态传递熵可以有效分析脑区间信息交互,因此本文将动态传递熵分析应用到脑电信号分类中。对原始信号进行预处理,通过基线采样去除脑电数据中的眼动伪迹等干扰。通过 FFT 对去除扰动后的脑电信号分频段,将频段后的信号构建传递熵矩阵。分析不同被试脑电极的传递熵变化,选取 C4、AF8、P3 这 3 个脑电通道作为运动皮层、前额叶、运动皮层下的 ROI 脑区通道,将二维数据通过逐行求和取平均值的方式转换为一维数组,并提取每组数中的最大值、最小值、中位数、方差、标准差作为一次实验的特征向量。最终,所有被试的这些

特征向量将构成一组二维数据,作为分类器的输入。

将特征向量作为分类器输入时,根据 20% 和 80% 的比例划分测试集与训练集,并设置样本标签方便训练。3 种分类方法的输入参数保持一致,以便结果对比。利用逻辑回归、决策树以及 XGBoost 进行分类,得到最终的分类结果,3 种方法具体参考第 1 节研究理论和实验方法,具体流程图如图 9 所示。




图 9 非线性结合时频分析处理脑电信号识别整体流程
Fig. 9 The overall flow chart of nonlinear combined time-frequency analysis processing EEG signal recognition

2.3.2 实验结果及分析

表 3 给出了将动态传递熵分析结合逻辑回归、XGBoost、决策树进行脑电信号分类的准确率,同时给出了未使用传递熵分析进行脑电信号分类时的分类准确率。结果表明,传递熵分析处理后数据的脑电信号分类准确率高于原始数据,通过构建传递熵网络进行运动相关任务分析的有效性得到了验证。

表 3 数据集 1 脑电信号分类准确率
Table 3 Classification accuracy results of EEG signals in dataset 1

分类方法	分类数据	准确率
逻辑回归	原始数据	0.532 1
	传递熵分析处理后数据	0.743 1
XGBoost	原始数据	0.670 5
	传递熵分析处理后数据	0.943 2
决策树	原始数据	0.693 1
	传递熵分析处理后数据	0.943 2

3 结 论

本文提出了一种基于传递熵与时频分析融合的脑电信号分析方法,利用传递熵的有向性与大脑默认网络在运动态下与其他皮层间信息交互的强耦合特性,分析了不同运动态下大脑传递熵信息的变化。通过快速傅里叶变换、滑动时间窗的方法,构建整个任务过程的动态传递熵信息,并对静息态、运动态、运动想象态下的默认网络与运动皮层、默认网络与前额叶的动态传递熵变化进行分析。结合显著性统计方法得到的结果显示,默认网络与初始运动皮层、前额叶皮层间在运动态、运动想象态的传递熵平均信息显著性高于处在静息态,其中运动态时的传递熵平均信息略高于运动想象时刻。在动态传递熵分析方法基础上,本文同时对比了 3 种分类方法(逻辑回归、决策树、XGBoost)对原始脑电数据以及传递熵方法处理后脑电数据的运动态行为分类效果,结果表明,结合传递熵方法的分类准确率较高。

目前,脑机接口领域的发展十分迅速,随着理论的逐步完善,技术水平日趋提高,可穿戴式技术和设备也逐渐兴起。未来,脑控机器人可实现意念控制机器人的行为,帮助残疾人重新获得运动能力等。作为脑机接口领域的关键技术,本文对于脑电信号的精确辨识和研究可以更好地服务脑机接口技术,为进一步探究大脑机理特征提供研究思路和方法。

参考文献:

[1] 何柳诗, 谢俊, 于鸿伟, 等. 融合眼动追踪和目标动态可调的稳态视觉诱发电位脑机接口系统设计 [J]. 西安交通大学学报, 2021, 55(10): 87-95.
HE Liushi, XIE Jun, YU Hongwei, et al. A design of brain-computer interface system for steady-state visual evoked potential integrating eye movement tracking and target dynamical adjustment [J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 87-95.

[2] ANTICEVIC A, COLE M W, MURRAY J D, et al. The role of default network deactivation in cognition and disease [J]. Trends in Cognitive Sciences, 2012, 16(12): 584-592.

[3] JUNG J Y, BUNBERT A, BOWTELL R, et al. Modulating brain networks with transcranial magnetic stimulation over the primary motor cortex: a concurrent TMS/fMRI study [J]. Frontiers in Human Neuroscience, 2020, 14: 31.

[4] 仲文远, 李大海, 张进华, 等. 可穿戴式干电极脑机接口系统设计 [J]. 西安交通大学学报, 2020, 54(6):

- 66-74.
- ZHONG Wenyuan, LI Dahai, ZHANG Jinhua, et al. Design of wearable brain-computer interface system based on dry electrode [J]. Journal of Xi'an Jiaotong University, 2020, 54(6): 66-74.
- [5] 张彦军, 谢俊, 薛涛, 等. 稳态视觉诱发电位脑机接口的现场可编程逻辑门阵列实现 [J]. 西安交通大学学报, 2020, 54(2): 158-165.
- ZHANG Yanjun, XIE Jun, XUE Tao, et al. Implementation of steady-state visual evoked potential BCI system based on field programmable gate array [J]. Journal of Xi'an Jiaotong University, 2020, 54(2): 158-165.
- [6] VAN GEEST Q, DOUW L, VAN'T KLOOSTER S, et al. Information processing speed in multiple sclerosis: relevance of default mode network dynamics [J]. NeuroImage: Clinical, 2018, 19: 507-515.
- [7] HUGDAHL K, RAICHLE M E, MITRA A, et al. On the existence of a generalized non-specific task-dependent network [J]. Frontiers in Human Neuroscience, 2015, 9: 430.
- [8] DAYAN E, SELLA I, MUKOVSKIY A, et al. The default mode network differentiates biological from non-biological motion [J]. Cerebral Cortex, 2016, 26(1): 234-245.
- [9] CARVALHO F M, CHAIM K T, SANCHEZ T A, et al. Time-perception network and default mode network are associated with temporal prediction in a periodic motion task [J]. Frontiers in Human Neuroscience, 2016, 10: 268.
- [10] 李玲, 王瑞平. 睡眠脑电信号的非线性动力学分析 [J]. 北京生物医学工程, 2010, 29(3): 304-307.
- LI Ling, WANG Ruiping. Nonlinear dynamics analysis for sleep EEG [J]. Beijing Biomedical Engineering, 2010, 29(3): 304-307.
- [11] 罗志增, 鲁先举, 周莹. 基于脑功能网络和样本熵的脑电信号特征提取 [J]. 电子与信息学报, 2021, 43(2): 412-418.
- LUO Zhizeng, LU Xianju, ZHOU Ying. EEG feature extraction based on brain function network and sample entropy [J]. Journal of Electronics & Information Technology, 2021, 43(2): 412-418.
- [12] 李天翔, 李双燕. 传递熵算法研究进展及其应用 [J]. 生物医学工程学杂志, 2022, 39(3): 612-619.
- LI Tianxiang, LI Shuangyan. Research progress and application of transfer entropy algorithm [J]. Journal of Biomedical Engineering, 2022, 39(3): 612-619.
- [13] KHOSHNOUD S, NAZARI M A, SHAMSI M. Functional brain dynamic analysis of ADHD and control children using nonlinear dynamical features of EEG signals [J]. Journal of Integrative Neuroscience, 2018, 17(1): 11-18.
- [14] 杨磊, 杨帆, 何艳. 采用样本熵自适应噪声完备经验模态分解的脑电信号眼电伪迹去除算法 [J]. 西安交通大学学报, 2020, 54(8): 177-184.
- YANG Lei, YANG Fan, HE Yan. An electroencephalogram artifacts removal algorithm for electroencephalogram signals based on sample entropy-complete ensemble empirical mode decomposition with adaptive noise [J]. Journal of Xi'an Jiaotong University, 2020, 54(8): 177-184.
- [15] CAI Jiayue, WANG Yuheng, LIU Aiping, et al. Novel regional activity representation with constrained canonical correlation analysis for brain connectivity network estimation [J]. IEEE Transactions on Medical Imaging, 2020, 39(7): 2363-2373.
- [16] 王忠民, 蔡兰兰, 范琳. 基于传递熵关键因果连接的情感识别方法 [J]. 计算机应用研究, 2021, 38(9): 2614-2618.
- WANG Zhongmin, CAI Lanlan, FAN Lin. Emotion recognition method based on key causal connection of transfer entropy [J]. Application Research of Computers, 2021, 38(9): 2614-2618.
- [17] 樊强, 周律, 范永晨, 等. 不同情绪状态下脑网络的信息流向研究 [J]. 动力学与控制学报, 2022, 20(1): 60-67.
- FAN Qiang, ZHOU Lü, FAN Yongchen, et al. Information flow under different emotional states in brain network [J]. Journal of Dynamics and Control, 2022, 20(1): 60-67.
- [18] 聂振华, 杨卫星, 程良彦, 等. 联合移动主成分分析与传递熵的桥梁损伤识别方法 [J]. 振动工程学报, 2020, 33(5): 1062-1072.
- NIE Zhenhua, YANG Weixing, CHENG Liangyan, et al. Bridge damage detection based on moving principal component analysis combining with transfer entropy [J]. Journal of Vibration Engineering, 2020, 33(5): 1062-1072.
- [19] ASSAF A, BILGIN M H, DEMIR E. Using transfer entropy to measure information flows between cryptocurrencies [J]. Physica: A Statistical Mechanics and Its Applications, 2022, 586: 126484.
- [20] HE Jiayi, SHANG Pengjian. Comparison of transfer entropy methods for financial time series [J]. Physica: A Statistical Mechanics and Its Applications, 2017, 482: 772-785.

- [21] YAO Wenpo, WANG Jun. Multi-scale symbolic transfer entropy analysis of EEG [J]. *Physic:A Statistical Mechanics and Its Applications*, 2017, 484: 276-281.
- [22] 吴建宁, 徐海东, 王珏. 基于过完备字典稀疏表示的多通道脑电信号压缩感知联合重构 [J]. *电子与信息学报*, 2016, 38(7): 1666-1673.
- WU Jianning, XU Haidong, WANG Jue. A new joint reconstruction algorithm of compressed sensing for multichannel EEG signals based on over-complete dictionary approach [J]. *Journal of Electronics & Information Technology*, 2016, 38(7): 1666-1673.
- [23] FOGELSON N, DIAZ-BRAGE P. Altered directed connectivity during processing of implicit versus explicit predictive stimuli in Parkinson's disease patients [J]. *Brain and Cognition*, 2021, 152: 105773.
- [24] NÜRNBERGER M, KLINGNER C, WITTE O W, et al. Mismatch of visual-vestibular information in virtual reality: is motion sickness part of the brains attempt to reduce the prediction error? [J]. *Frontiers in Human Neuroscience*, 2021, 15: 757735.
- [25] GUEVARA ERRA R, MATEOS D M, WENNBORG R, et al. Statistical mechanics of consciousness: maximization of information content of network is associated with conscious awareness [J]. *Physical Review:E*, 2016, 94(5): 052402.
- [26] HUANG C S, PAL N R, CHUANG C H, et al. Identifying changes in EEG information transfer during drowsy driving by transfer entropy [J]. *Frontiers in Human Neuroscience*, 2015, 9: 570.
- [27] YE Fei, SUN Ziyang, YANG Donghui, et al. Cortico-muscular coupling analysis based on improved LSTM and transfer entropy [J]. *Neuroscience Letters*, 2021, 760: 136012.
- [28] 谢平, 杨芳梅, 陈晓玲, 等. 基于多尺度传递熵的脑肌电信号耦合分析 [J]. *物理学报*, 2015, 64(24): 248702-0-248702-10.
- XIE Ping, YANG Fangmei, CHEN Xiaoling, et al. Functional coupling analyses of electroencephalogram and electromyogram based on multiscale transfer entropy [J]. *Acta Physica Sinica*, 2015, 64(24): 248702-0-248702-10.
- [29] 谢平, 杨芳梅, 李欣欣, 等. 基于变分模态分解-传递熵的脑肌电信号耦合分析 [J]. *物理学报*, 2016, 65(11): 118701-1-118701-9.
- XIE Ping, YANG Fangmei, LI Xinxin, et al. Functional coupling analyses of electroencephalogram and electromyogram based on variational mode decomposition-transfer entropy [J]. *Acta Physica Sinica*, 2016, 65(11): 118701-1-118701-9.
- [30] GAO Yunyuan, WANG Xiangkun, POTTER T, et al. Single-trial EEG emotion recognition using granger causality/transfer entropy analysis [J]. *Journal of Neuroscience Methods*, 2020, 346: 108904.
- [31] 李素姣, 刘苏, 蓝贺, 等. 脑肌电信号同步耦合分析方法研究进展 [J]. *生物医学工程学杂志*, 2019, 36(2): 334-337, 342.
- LI Sujiao, LIU Su, LAN He, et al. Research progress on analysis methods in electroencephalography-electromyography synchronous coupling [J]. *Journal of Biomedical Engineering*, 2019, 36(2): 334-337, 342.
- [32] SCHALK G, MCFARLAND D J, HINTERBERGER T, et al. BCI2000: a general-purpose brain-computer interface (BCI) system [J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51(6): 1034-1043.
- [33] CHO H, AHN M, AHN S, et al. EEG datasets for motor imagery brain-computer interface [J]. *Giga-Science*, 2017, 6(7): gix034.
- [34] 戴雯, 金晖, 彼末一之. 目标设置在不同肌肉强度的短期运动训练中对大脑运动皮层突触可塑性影响研究 [J]. *中国体育科技*, 2021, 57(9): 46-54.
- DAI Wen, JIN Hui, KANOSUE K. Goal-Setting induced changes in synaptic plasticity on motor cortex after both comfortable and strong muscle activity of short-term motor practice [J]. *China Sport Science and Technology*, 2021, 57(9): 46-54.
- [35] BAŞAR E, GÜNTEKIN B. Chapter 19: review of delta, theta, alpha, beta, and gamma response oscillations in neuropsychiatric disorders [J]. *Supplements to Clinical Neurophysiology*, 2013, 62: 303-341.
- [36] LI Wanqing, MAI Xiaoqin, LIU Chao. The default mode network and social understanding of others: what do brain connectivity studies tell us [J]. *Frontiers in Human Neuroscience*, 2014, 8: 74.
- [37] DECETY J, GRÈZES J, COSTES N, et al. Brain activity during observation of actions. Influence of action content and subject's strategy [J]. *Brain*, 1997, 120(10): 1763-1777.
- [38] BREWER J A, WORHUNSKY P D, GRAY J R, et al. Meditation experience is associated with differences in default mode network activity and connectivity [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2011, 108(50): 20254-20259.
- [39] 贾小云, 王丽艳, 陈景霞, 等. 基于时频域组合特征的脑电信号情感分类算法 [J]. *科学技术与工程*, 2019, 19(33): 290-295.

- JIA Xiaoyun, WANG Liyan, CHEN Jingxia, et al. Emotional classification algorithm of electroencephalogram signals based on time-frequency combination characteristics [J]. Science Technology and Engineering, 2019, 19(33): 290-295.
- [40] 董寅冬, 任福继, 李春彬. 基于线性核主成分分析和 XGBoost 的脑电情感识别 [J]. 光电工程, 2021, 48(2): 12-20.
- DONG Yindong, REN Fuji, LI Chunbin. EEG emotion recognition based on linear kernel PCA and XGBoost [J]. Opto-Electronic Engineering, 2021, 48(2): 12-20.
- [41] 陈黎, 龚安民, 丁鹏, 等. 基于欧式空间-加权逻辑回归迁移学习的运动想象 EEG 信号解码 [J]. 南京大学学报(自然科学), 2022, 58(2): 264-274.
- CHEN Li, GONG Anmin, DING Peng, et al. EEG signal decoding of motor imagination based on Euclidean space-weighted logistic regression transfer learning [J]. Journal of Nanjing University (Natural Science), 2022, 58(2): 264-274.
- [42] BAZÁN P R, BIAZOLI C E Jr, SATO J R, et al. Motor readiness increases brain connectivity between default-mode network and motor cortex; impact on sampling resting periods from fMRI event-related studies [J]. Brain Connectivity, 2015, 5(10): 631-640.
- [43] WANG R W Y, CHANG Weili, CHUANG Shangwen, et al. Posterior cingulate cortex can be a regulatory modulator of the default mode network in task-negative state [J]. Scientific Reports, 2019, 9(1): 7565.

(编辑 陶晴 刘杨)