

• 生物信息专栏 •

基于多层脑功能网络特征的动作意图识别



常文文*, 聂文超, 袁月婷, 闫光辉, 杨志飞, 张冰涛, 张学军

(兰州交通大学电子与信息工程学院 兰州 730070)

【摘要】基于脑电信号完成对步态特征的解码分析并就动作意图做出可靠识别和预测, 是基于脑机接口的人机混合康复训练系统和智能助行机器人中的核心问题。为实现对站立、坐下以及静止状态这些最基本步态过程的分类识别, 提出了基于多层脑功能网络分析的特征表示方法, 结合对各类脑功能网络特征的统计分析, 确定对不同动作敏感的网络特征量, 并结合支持向量机、线性判别分析、逻辑回归以及朴素贝叶斯算法完成对不同动作过程的分类识别。实验结果表明, 所提出的方法可较好地实现对上述动作意图的识别, 针对 13 名被试者对站立、坐下和静止状态的识别准确率均高于 71%, 最高达到 77%。对多层动态脑功能网络的分析结果表明, 下肢运动过程的发生会弱化脑区间的相互依赖关系, 导致网络拓扑连接结构变得逐渐稀疏。研究结果对理解下肢运动过程中大脑认知过程变化, 开展基于脑机接口的下肢康复策略研究和康复系统开发具有一定的参考价值。

关键词 分类; 脑电信号; 脑功能网络; 运动意图; 同步似然分析

中图分类号 TP391; R496

文献标志码 A

doi:10.12178/1001-0548.2022292

Action Intention Recognition Based on Multi-layer Functional Brain Network

CHANG Wenwen*, NIE Wenchao, YUAN Yueting, YAN Guanghui, YANG Zhifei,
ZHANG Bingtao, and ZHANG Xuejun

(School of Electronic and Information Engineering, Lanzhou Jiaotong University Lanzhou 730070)

Abstract The decoding analysis of gait features based on electroencephalogram (EEG) and the reliable recognition and prediction of motion intention are the core problems of brain-computer interface (BCI) based human-machine hybrid rehabilitation training system and intelligent walking robot. In order to realize the recognition of the most basic gait processes such as standing, sitting and resting states, this study proposes a feature representation method based on multi-layer functional brain network using EEG. Combined with the statistical analysis of various network features, these parameters sensitive to different movements are determined, and support vector machine, linear discriminant analysis, logistic regression and naive bayes algorithms are applied to complete the classification of different actions. Experiment results show the proposed method can realize the recognition of the three actions, and the recognition accuracy of standing, sitting and resting state is higher than 71% and the highest accuracy is 77% for 13 subjects. Multi-layer brain network analysis shows the motion action of lower limb can weaken the interdependence between brain regions, resulting the sparsification of the topology structure. This study has certain reference value for understanding the changes of brain cognitive process during lower limb movement, carrying out BCI based rehabilitation strategies, and developing corresponding rehabilitation systems.

Key words classification; electroencephalography (EEG); functional brain network; motion intention; synchronization likelihood

在康复训练过程中, 使用机器人设备比传统的人工康复更具优势, 能增加患者训练的动机和自主训练的机会, 从而提高康复训练的质量和效果。在步态康复方面, 外骨骼和智能助行机器人被广泛应

用, 并取得了良好的效果^[1-2]。随着脑机接口 (brain computer interface, BCI) 技术的发展, 基于 BCI 的主动式康复可以通过更快、更有力地检测大脑的运动意图来改进康复策略, 提高康复效果, 是未来神

收稿日期: 2022-08-25; 修回日期: 2022-11-26

基金项目: 国家自然科学基金 (62062049, 61962034); 甘肃省科技计划 (21ZD8RA008); 甘肃教育厅产业支撑计划 (2022CYZC-38)

作者简介: 常文文 (1987-), 男, 博士, 副教授, 主要从事脑机交互、脑电信号分析和模式识别等方面的研究。

*通信作者: 常文文, E-mail: changww2013@126.com

经康复系统发展的趋势^[3-4]。理解大脑认知活动和运动过程之间的关系, 对于发展基于脑机接口的主动康复技术具有重要作用。

目前的研究主要通过测量脑电信号 (electroencephalogram, EEG) 对运动意图进行特征解码和模式识别研究^[1,5], EEG 测量由于其简单、便携和高时间分辨率, 被广泛应用于运动意图的检测中。文献 [6-7] 表明, EEG 中包含了丰富的步态和运动信息, 而针对行走和步态等下肢运动意图的解码研究刚刚起步。在步态过程中最基本的一个动作过程就是起立和坐下, 文献 [3] 开发了一种实验协议, 完成了对被试者在起立—坐下和屈膝—伸展动作过程中脑电信号和肌电信号的同步采集, 通过事件相关同步/去同步 (event related synchronization/desynchronization) 和慢皮层电位以及与下肢相关的肌电模式分类来分析被试的动作意图, 并结合支持向量机和人工神经网络完成对不同运动阶段的分类识别, 得到了很好的效果。文献 [6] 通过对 EEG 信号中低频波段信号的解码, 研究了 10 名被试者从坐姿到站姿以及从站姿到坐姿转变过程中对应的脑电信号特征, 在保留 EEG 数据丰富的统计特征基础上, 结合高斯混合模型 (Gaussian mixture model, GMM), 从时间嵌入的低频 EEG 信号中成功识别“站到坐”和“坐到站”的动作意图, 也证实了类似基于 BCI 的下肢解码技术在外骨骼康复机器人中应用的可行性。文献 [4] 同样专注于动作执行前的皮层慢电位, 对 Delta 波段在运动意图解码中的可行性展开分析, 基于动作开始前 1.5 s 的慢波数据, 通过设计自我触发和外界提示触发两种模式对起立、坐下和安静 3 种状态下的 EEG 信号特征展开分析, 通过伪迹子空间重构算法消除对 EEG 信号中的高幅噪声, 通过构建时间嵌入的 EEG 特征向量并应用 Fisher 判别分析降低其时空特征的维数, 最后结合 GMM 分类器完成对 3 种状态的识别, 得到了较好的效果。文献 [8] 最早基于高密度的 EEG 测量, 就被试在站立和行走过程中执行视觉反应任务时的大脑认知过程做了详细研究, 对 EEG 数据的独立分量分析显示, 在站立、慢走和快走期间的视觉事件相关电位在不同运动条件下没有差异, 证明了在运动过程中记录和认知有关的大脑活动的可行性。文献 [9] 对被试者在坐着、站立和行走过程中从事某种认知任务时大脑认知负荷的变化过程进行研究, 基于干电极的脑电信号采集,

通过设计听觉诱发的事件相关电位分析, 发现与坐着相比, 行走时 P3 显著降低, 表明行走时的认知负荷高于其他两项活动, 而坐着和站着的 P3 无显著差异。文献 [10] 提出了一种基于熵的信号复杂度度量方法, 并通过共空间模式滤波器选择了可用于特定动作分类的特征量, 最后利用线性判别分类器实现对站立和行走动作的识别。综上所述可以看出, 有关运动意图的解码研究主要集中为两种信号, 一种是事件相关的同步/去同步电位, 另一种是运动相关脑电位 (movement related potentials, MRPs)^[1,4]。此外, 文献 [8-9] 针对不同动作过程中认知能力变化的研究, 实现了对该类动作的有效检测和识别。但是, 这些研究主要集中在感觉运动脑区少数电极通道的慢电位上, 缺乏从全脑角度出发的空间域特征信息表示以及相应的识别方法研究。

步态是一个复杂的认知和运动控制过程, 下肢动作也涉及全脑各个脑区的协调和配合, 在一个站立或坐下动作完成之前, 人的大脑必然表现出一定的特征信息, 可以通过对该类特征信息的解码最终确定其运动意图^[4]。这些信息除了通过上述皮层慢电位的表征之外, 通过对脑区间相互依赖关系的动态变化过程分析, 有望揭示运动意图解码的新特征^[11-12]。文献 [13] 就站立和行走过程中的脑功能网络特征展开分析, 发现相比站立状态, 行走过程中感知运动脑区的功能连接会减弱。文献 [11] 就是否有外骨骼辅助下运动过程中的脑功能网络特征展开分析, 也表明了基于图论的脑网络分析方法在步态康复研究过程中具有一定的特殊作用。文献 [12] 通过构建功能性脑网络, 对脑创伤性病人行走过程中的平衡性问题展开分析, 也证明了基于脑功能网络的空间域信息对表征步态特征具有特殊效果。针对动作意图检测开展多角度、深层次的分析和探究显然是必要的。为此, 本文设计了从静坐到站立、然后再到静坐的动作转换实验, 并同步采集了被试者的脑电信号, 通过构建多层脑功能网络, 就动作执行前后脑区间依赖关系的动态变化过程展开分析, 并就不同动作对应多层网络特征参数进行了统计分析。

1 实验设计

为实现对站立、坐下和静止状态的识别, 结合统计差异的网络特征参数和机器学习算法, 本文提出了一种该类动作意图识别方法, 其技术路线图如图 1 所示。

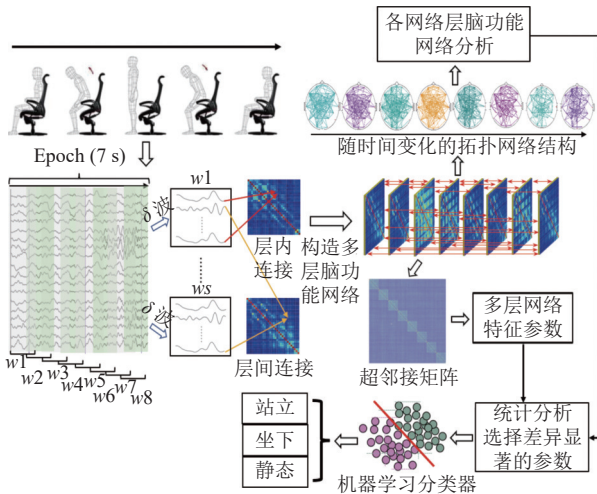


图 1 本文技术路线图

1.1 实验方案

13 名被试者完成此次实验，被试者均为在校学生，身体健康，没有任何的精神疾病病史，均为右利手，实验之前和被试者签署了实验知情协议书。实验过程中被试者坐在显示器前，显示器显示计时时间，要求被试者先静坐 1 分钟，然后被试者起立，由静坐转为站立，被试者站立持续 1 分钟，之后被试者坐下，由站立转为静坐，静止持续 1 分钟，依次反复交替完成上述动作，如图 2 所示^[9]。




图 2 站立-静坐实验过程示意图

在该过程中全程记录被试者的脑电信号，持续 10 min 为实验的一个 Session，每名被试者总共完成 6 个 Session 的数据采集，各 Session 中间休息 1~2 min。

1.2 数据采集和预处理

整个动作实验过程中的数据采集使用 SAGA 32+脑电采集系统(荷兰 TMSi 公司)，在线采样频率为 1 024 Hz，在线采样频段为 0~200 Hz，数据记录中采用平均参考模式，额顶处为接地电极。该系统除了采集 30 通道的脑电信号之外，还有 4 组附加通道，通过附加通道接入了两组外接传感器，其中一组是惯性测量单元(inertial measurement unit, IMU)传感器，将其固定在被试者左上腿位置，另一组是 4 路足底压力传感器(FSR 型压力传感器)，以足底压力鞋垫的形式固定在被试者左脚下方，通

过 IMU 和足底压力传感器数据，来确定起立和坐下的起始时间点，实现和脑电数据的同步，传感器安装位置如图 3 所示。



图 3 足底压力鞋垫和传感器位置固定示意图

实验中记录的信号包括 30 通道脑电信号、4 路足底压力传感器数据以及 IMU 数据，所有数据的预处理均在 EEGLAB 中完成。对所有被试者的处理逐个进行，首先将每名被试者所有 Session 数据整合到一起，然后对数据降采样到 250 Hz，并完成 0.1~48.0 Hz 的带通滤波，使用 Cleanline 工具完成对信号的线性滤波，根据 SAGA 系统电极位置完成对所有脑电信号通道的电极定位，并剔除坏电极和无关通道。在完成数据读入的基本处理后，对 IMU 的各路数据进行低通滤波(Butterworth 滤波器，截止频率 10 Hz)，并借助下肢上 IMU 和脚后跟的足底压力信号确定每个站立动作和坐下动作的起始时间点，作为 EEG 信号事件的标记点(将事件标记为起立、坐下和静态 3 个状态)。根据该标记点完成对所有数据的截断，为了讨论动作前后的脑电特征，每个 Epoch 的长度设置为动作起始点之前 4.5 s 到之后的 2.5 s，最后得到 356 个 Epoch 数据段，所有的 Epoch 数据段都进行了基线校准。然后通过视觉检查剔除受伪迹影响较大的 Epoch 数据段，利用运行独立成分分析(run independent component analysis, RUNICA)操作完成对所有信号的 ICA 分解，并基于半自动的独立成分分析选择(semi-automated selection of independent component analysis, SASICA)工具包完成对伪迹成分的判断，并剔除其中的伪迹成分，主要包括眨眼、眼动、肌肉伪迹以及由于动作过程引起的其他伪迹成分。在 ICA 剔除伪迹之后，如有需要，对坏电极进行插值处理，最后对所有数据进行平均重参考，从而完成数据的预处理过程。

2 研究方法

2.1 同步似然分析

行走是人类一项复杂的认知活动，涉及视觉

判断、运动控制、空间感知和规划等多个方面, 需要整个大脑不同脑区间的协调和配合。在一个动作执行之前, 通常大脑就表现出一定的动作意图, 通过讨论动作执行前后相当时间内不同脑区间的相互依赖关系, 有助于全面了解动作执行过程中大脑的活动状态, 并有望发现针对动作意图检测的新特征。基于多层脑功能网络的复杂网络分析方法为此类动作过程对应脑区间依赖关系的研究提供了工具。

表征脑电信号之间相互依赖关系的度量方法有很多种^[14], 其中同步似然分析 (synchronization likelihood, SL) 被广泛应用于非线性和非平稳信号间依赖关系的分析中, 特别适合于脑电信号的分析, 对 EEG 信号中的线性和非线性特征都具有较好的表征能力, 且对容积传导等问题具有较好的鲁棒性^[15-16]。SL 是神经生理学数据中估计广义同步性的常用指标, 它的理论依据是系统在某一时刻的状态可通过一个插值向量来表示, 当该状态再次出现时, 可以用一个相似的插值向量来对其进行表示。因此, 本文采用 SL 来构建不同通道脑电信号之间的相互依赖关系, 从而构建多层脑功能网络。分为以下 4 个步骤。

1) 对来自通道 C 的 EEG 信号 $x_{C,i}(i=1,2,\dots,N, N$ 为样本点数) 进行重建, 得到 m 维空间嵌入之后的信号:

$$\mathbf{X}_{C,i} = (x_{C,i}, x_{C,i+l}, x_{C,i+2l}, \dots, x_{C,i+(m-1)l}) \quad (1)$$

式中, l 为时间延迟。同理, 对通道 D 的 EEG 信号进行重构得到 $\mathbf{X}_{D,i}$ 。

2) 对通道 C 上的第 i 个样本, 设定各向量之间彼此的距离小于 s 的概率为:

$$P_{C,i}^s = \frac{1}{2(\omega_2 - \omega_1)} \sum_{\substack{j=1 \\ \omega_1 < |i-j| < \omega_2}}^N \theta(s - |\mathbf{X}_{C,i} - \mathbf{X}_{C,j}|) \quad (2)$$

式中, $|\cdot|$ 表示两个相空间矢量的欧氏距离; θ 为 Heaviside 阶梯函数, 满足当 $x \leq 0$ 时, $\theta(x) = 0$, 当 $x > 0$ 时, $\theta(x) = 1$; 对时间窗的控制通过 ω_1 和 ω_2 来控制, 且满足 $\omega_1 \ll \omega_2 \ll N$ 。

3) 定义通道 C 上在采样点 i 处的临界距离为: $s_{C,i} : P_{C,i}^{s_{C,i}} = p_{\text{ref}}$, 其中有 $p_{\text{ref}} \leq 1$; 同样可确定通道 D 中信号的邻接距离: $s_{D,i} : P_{D,i}^{s_{D,i}} = p_{\text{ref}}$ 。

4) 在完成上述步骤之后, 就可以实现对通道 C 和通道 D 之间 EEG 信号同步似然指数 SL 的计算, 其表示的是通道 C 信号和 D 信号同时重现其

状态向量的可能性, 即当 $\mathbf{X}_{C,j}$ 和给定 $\mathbf{X}_{C,i}$ 之间的距离小于邻接距离 $s_{C,i}$, 同时 $\mathbf{X}_{D,j}$ 和 $\mathbf{X}_{D,i}$ 之间的距离也小于 $s_{D,i}$ 的可能性。本文在计算 SL 时, 对应参数依次设置为: $l=10$ 、 $m=10$ 、 $\omega_1 = 100$ 、 $\omega_2 = 400$ 、 $p_{\text{ref}} = 0.01$ 。

2.2 多层脑功能网络构建

对某段时间内脑功能网络拓扑结构动态关系的一种表征就是对该时间段内信号按一定时间窗进行截断, 依次构建功能网络并形成超邻接矩阵, 然后借助多层网络分析方法进行特征分析。为了通过脑功能网络来表征站立、坐下以及静止状态的脑信号特征, 首先提取了和运动意图相关的 delta 慢波信号, 如图 1 所示, 然后根据站立和坐下以及静止状态的时间点, 将 3 类状态对应的 delta 波段信号分割为 $[-4.5 \text{ s}, 2.5 \text{ s}]$ 的 Epoch 数据段 (长度为 7 s), 并以 3.5 s 的时长作为时间窗, 0.5 s 的步长对每个 Epoch 依次进行截断, 从而得到 8 个时间段的子窗口 (依次为 w_1, w_2, \dots, w_8), 这样对一个 Epoch 样本进行操作, 就可以得到 $30 \times 875 \times 8$ 的数据样本, 然后对每个窗口内以及每对窗口间使用 SL 来计算两个通道间的相互依赖关系。图 4 为层间和层内各通道 SL 计算示意图, 通过层间和层内各通道之间 SL 计算最终可以得到多层网络结构并以超邻接矩阵的形式表示。




图 4 多层脑功能网络构建

图 5 为 3 种状态下所有被试、所有 Epoch 数据段对应超邻接矩阵的总平均显示, 该矩阵为 240×240 的 SL 值矩阵表示, 对角线位置为 8 个子窗口 ($w_1 \sim w_8$) 的窗内连接关系 (层内连接), 而上三角或下三角矩阵为不同子窗口之间的连接关系 (层间连接), 可以看到层内连接强度要远高于层间连接。由于图示超邻接矩阵中 SL 为总平均值, 3 种状态之间的差异并不明显。为此, 图 6 计算了该超邻接矩阵中 SL 的总平均值, 可以看到 3 种状态之间, SL 均值在动作发生期间要高于静止状态, 且坐下和起立动作对应均值接近, 但是统计分析并没有发现 3 种状态之间存在显著差异。

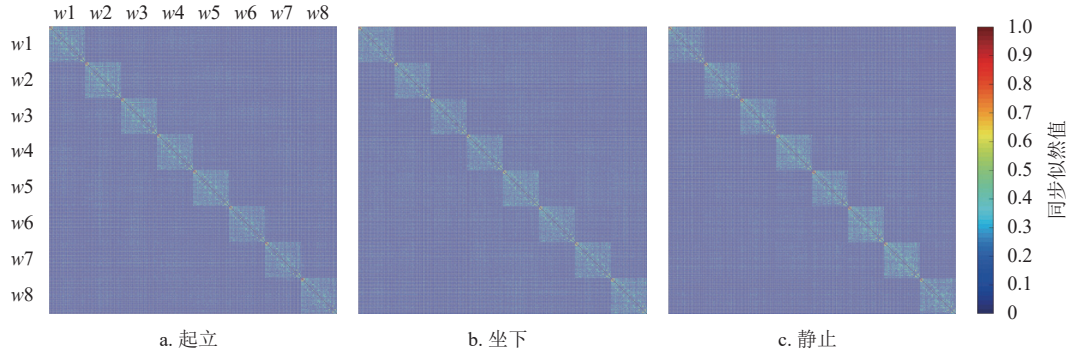


图 5 3 种状态对应 EEG 信号 SL 超邻接矩阵




图 6 3 种状态 SL 超邻接矩阵总平均值

2.3 多层脑功能网络特征参数分析

为了就整个动作过程对应的特征量进行量化分析, 本文重点讨论 4 类多层网络特征参数, 首先是层-层相关系数 (layer-layer correlation, LLC), 将其定义为两个网络层之间的皮尔逊相关系数^[17-18], 用于表示各网络层之间, 特别是不同子窗口对应网络层之间的相关性程度。为了就多层网络中不同层之间整合和分离程度进行度量, 文献 [17] 引入了一个度量指标, 该指标量化了第 m 层中的链路关系仍然存在于第 n 层中的条件概率 (conditional probability, CP), 将其定义为:

$$P(A_{m,ij}|A_{n,ij}) = \frac{\sum_{ij} A_{m,ij} A_{n,ij}}{\sum_{ij} A_{n,ij}} \quad (3)$$

式中, $A_m(m=1,2,\dots,8)$ 为层内邻接矩阵。如果 P 值较高, 表示各层之间整合关系较强, 而如果各层之间关系相对比较独立, 则 P 值较低。此外, 不同层之间的分离特征也可以用多层模块值来进行量化, 文献 [19-20] 将其定义为:

$$Q(\gamma, \omega) = \frac{1}{2\mu} \sum_{ijm} \left[\left(A_l - \gamma_l \frac{k_i^l k_j^l}{2 \sum_l k_i^l} \right) \delta(A_{il}, A_{jl}) + \delta(i, j) \omega_{jml} \right] \delta(A_{il}, A_{jm}) \quad (4)$$

可以看到 Q 值受到参数 γ 和 ω 的控制, 它们分别决定了网络结构中的时间连通性和空间连通性。式中, μ 是多层网络中的整体链路权重; γ_l 对应于第 l 层的拓扑分辨参数; ω_{jml} 是节点 j 在第 l 层和第 m 层之间的时间耦合参数; $k_i^l = \sum_j w_{ij}^l$ 是节点 i 在第 l 层上的连接强度。节点 i 和节点 j 在同一个模块时, $\delta(A_{il}, A_{jl})$ 和 $\delta(A_{il}, A_{jm})$ 的取值为 1, 否则取值为 0。

最后, 多层网络还可以使用多层参与系数 (multilayer participant coefficient, MPC) 来量化其特征。该系数与熵有关, 主要用来量化给定节点 i 的链路是均匀分布在各个层中, 还是主要集中在一个或几个层中^[17-18]。节点 i 的 MPC 值被定义为:

$$\text{MPC}_i = \frac{M}{M-1} \left[1 - \sum_{l=1}^M \left(\frac{k_i^l}{o_i} \right)^2 \right] \quad (5)$$

式中, $o_i = \sum_{l=1}^M k_i^l$ 是节点 i 跨越 M 个层的整体连接强度。当节点 i 的所有连接边都位于同一个层时, $\text{MPC}_i=0$, 仅当节点 i 在 M 个层中的每个层上具有完全相同的边数时, $\text{MPC}_i=1$ 。将整个多层网络的 MPC 值定义为各个节点该值的总平均为:

$$\text{MPC} = \frac{1}{N} \sum_{i=1}^N \text{MPC}_i \quad (6)$$

2.4 阈值选择和单层脑功能网络特征参数分析

上述 SL 值构成的超邻接矩阵表征了层内和层间的相互依赖关系, 是对同一时间段或不同时间段各通道之间相互依赖关系的一种表征, 在这种连接

关系中也存在着大量的弱连接边, 可能是由于噪声或其他非特征性相互作用造成的, 并不能有效表征不同动作状态下脑区间的真实依赖关系。因此, 在一般性问题的讨论过程中, 需要设定一个合适的阈值对上述超邻接矩阵中的连接边权值进行筛选, 保留在不同状态间具有一定区分度的重要连接边。为此, 首先将 3 种状态对应 SL 超邻接矩阵权值展平, 并组合在一起构成一个一维向量, 然后通过选择该向量取值分布图上的上分位点作为最终的阈值点, 图 7 为该向量的频率直方图分布以及确定的阈值 (阈值 $T=0.1$)。

对上述 3 种状态对应所有超邻接矩阵使用本阈值进行重点权值边的筛选, 发现由于层间连接都较弱, 保留下的重点连接边都表征了层内各通道之间的连接关系。因此, 对各层内连接以单层网络的方法进行对比分析, 重点考虑了各层网络的度、聚集系数、全局效率、同配系数、传递性系数和节点的介数中心性^[14,21]。网络中最基本的一个参数就是节点度 (degree, D), 定义为与该节点相连的边的权值之和, 并将网络中所有节点度值的平均作为网络的度 (average degree, AD)。同时, 主要对网络的聚集系数 (clustering coefficient, C)、全局效率 (global efficiency, GE)、网络的同配系数 (assortativity coefficient, ASS)、网络的传递性系数 (transitivity, Tra) 以及节点的介数中心性 (betweenness centrality, BC) 等网络参数展开分析。

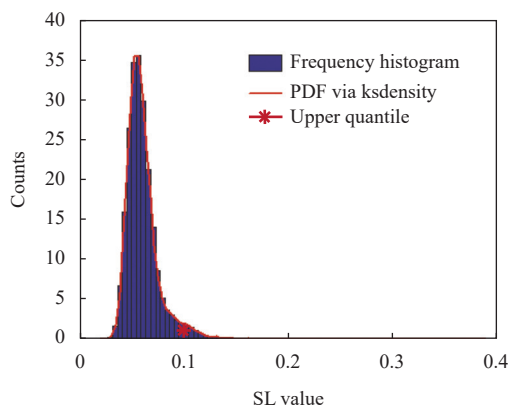


图 7 3 种状态对应 SL 超邻接矩阵值统计分布

3 结果分析与讨论

3.1 多层脑功能网络特征

在得到如图 5 所示各状态对应的超邻接矩阵之

后, 本文分别计算了各 Epoch 片段对应的超邻接矩阵的 4 种多层网络特征参数, 图 8 为对应的 Q 值和 MPC 值, 可以看出 Q 值保持在 0.8 左右, 而 MPC 值在 0.9 以上, 两组参数值都较高, 表明不管是静止状态, 还是起立和坐下动作, 各网络层之间的连接关系较为密切, 整个动作过程中大脑活动表现出很强的连续性。对 3 种状态之间的统计分析也发现, Q 值在 3 种状态间有较为明显的差异 (t -test, $p<0.05$), 而 MPC 值并没有表现出显著性差异。

图 9 分别对应 3 种状态下各网络层之间条件概率 CP 矩阵和层-层相关系数 LLC 矩阵。可以看到各层之间的 CP 值都普遍较高, 均在 0.6 以上, 表明各子窗口对应网络层之间存在较强的整合关系, 不管是相邻时间窗的网络层 (如 w_1 和 w_2), 还是间隔较远的时间窗的网络层 (如 w_1 和 w_8), 各层之间均存在较为紧密的联系, 但是 3 种状态之间并无显著差异。相比之下, 图 9 中两层之间相关性值情况有所不同, 可以看到两层之间的 LLC 值随着两层间距离的增加而降低, 表现出相邻层有较高的 LLC 值, 而间隔较远的层之间有较低的 LLC 值。为了能够找到可应用于不同运动状态分类的特征量, 对 LLC 值同样进行了统计分析, 图 9 中标记为两种状态之间存在统计性显著差异的情况 (t -test, $p<0.05$, 其中 “*” 为起立 vs. 坐下, “★” 为起立 vs. 静态, “▲” 为坐下 vs. 静态)。可以看到, 对于总平均后的 LLC 矩阵值并没有明显不同, 但是统计分析发现在 w_4 和 w_6, w_7, w_8 之间, 以及 w_6 和 w_7, w_8 之间的相关性存在统计性显著差异, 这可能和站立和坐下动作开始的时间点有一定关系。特别是从 w_4 子窗口开始, 出现了起立和坐下的动作起始点, 因此和后续子窗口的网络在层相关性上表现出显著性差异。




图 8 不同状态超邻接矩阵对应 Q 值和 MPC 值




图 9 不同状态对应网络层-层相关系数矩阵

3.2 阈值筛选后网络特征

为了突出上述网络连接中的重点连接边，将阈值设定为 0.1，完成对上述 3 种状态所有 Epoch 数据网络权值的筛选，大于该阈值的连接边保留，小于该阈值的连接边权值设置为 0。权值筛选后的网络最终为各层内连接网络，层间连接权值相对较小，因此均被忽略。图 10 为 3 种状态各子窗口对应阈值筛选后总平均网络连接拓扑图。可以看出，3 种状态在 8 个时间窗上拓扑结构变化比较平稳，对站立和坐下状态，均从 w4 开始，网络连接较之前的 w1、w2、w3 开始变得稀疏，并且一直持续到

最终的 w8，这和图 10 中网络层之间相关系数显著性差异结果一致。本文认为这主要是由于在整个时间窗的移动过程中，站立和坐下动作的起始点最开始均出现在 w4 窗口，而在站立和坐下过程中的动作电位相应地影响了不同脑区间的这种依赖关系，且在动作完成之后的一段时间内，这种依赖关系得到了一定程度上的保持。从图中也可看出，在静止状态下，网络拓扑结构保持平稳，不同脑区间的拓扑关系几乎没有发生变化，整个网络拓扑结构的变化同起立及坐下状态有一定区别，但无法通过该动态拓扑图来区分起立和坐下状态。




图 10 3 种状态各子窗口对应脑功能网络拓扑连接

为了便于进行量化分析，确定可用于不同状态

识别的新特征量，本文重点分析了 3 种状态下各窗

口对应的网络特征参数。如表 1 所示, 分别计算了聚集系数 C 、全局效率 E 、平均度 AD 、同配系数 Ass 、介数中心性 Bet 和网络传递性系数 Tra 这 6 类基本的网络特征参数。其中, “*” 表示 t -test, $p < 0.05$ 。由表可知, 动作状态对应网络特征

参数在 8 个递进子窗上整体呈现出变小的趋势, 但是变化差异很小, 而在静止状态网络参数变化没有明显的趋势性。对上述各网络参数在 3 种状态之间的统计分析表明, 只有 $w7$ 窗口对应的网络传递性系数 Tra 表现出显著的统计性差异。

表 1 各状态对应的网络特征参数

状态	参数	w1	w2	w3	w4	w5	w6	w7	w8
起立	C	0.124 5	0.120 9	0.120 8	0.118 0	0.114 9	0.108 8	0.106 7	0.107 7
	E	0.109 6	0.112 8	0.109 8	0.108 1	0.106 6	0.097 9	0.097 4	0.097 7
	AD	9.781 4	9.812 3	9.534 9	8.899 2	8.778 2	7.717 2	7.234 5	6.960 6
	Ass	0.092 9	0.079 3	0.028 3	0.033 5	0.021 5	0.017 1	0.008 5	0.013 3
	Tra	25.441 0	22.570 3	20.246 4	20.525 4	17.585 6	17.612 6	*19.783 9	16.091 5
	Bet	0.141 5	0.138 8	0.142 1	0.139 6	0.137 3	0.130 7	0.125 7	0.125 8
坐下	C	0.119 9	0.121 3	0.114 0	0.115 0	0.120 4	0.113 3	0.111 0	0.116 5
	E	0.108 9	0.108 1	0.105 6	0.108 0	0.111 5	0.105 1	0.104 0	0.104 3
	AD	10.339 0	9.967 7	9.288 8	9.290 8	9.191 5	8.154 9	7.982 3	7.802 0
	Ass	0.059 1	0.031 6	0.010 4	0.010 9	0.014 5	0.042 6	0.041 9	0.036 1
	Tra	23.725 3	21.102 8	21.448 5	20.327 3	18.326 1	18.218 7	*16.336 9	14.642 3
	Bet	0.134 7	0.136 4	0.129 5	0.133 2	0.137 0	0.129 8	0.129 9	0.136 8
静态	C	0.114 6	0.115 0	0.114 2	0.119 0	0.112 4	0.120 4	0.121 2	0.118 2
	E	0.099 0	0.101 7	0.100 4	0.107 6	0.102 0	0.112 1	0.111 4	0.103 0
	AD	9.081 8	9.221 0	8.706 2	9.363 6	8.414 3	8.656 4	8.496 2	7.462 5
	Ass	0.086 2	0.022 0	0.032 1	0.035 7	0.067 3	0.072 0	0.015 0	0.018 9
	Tra	22.662 6	19.360 2	18.969 7	17.288 3	16.364 7	17.798 9	*17.051 3	15.771 2
	Bet	0.139 2	0.139 2	0.138 9	0.141 4	0.136 9	0.146 4	0.147 5	0.145 1

3.3 机器学习分类

通过上述对各网络特征参数的对比和统计分析, 本文选择了多层网络特征参数 Q 、有显著差异的层间相关系数 LLC 以及 $w7$ 子窗口对应网络传递性系数 Tra 构成特征向量:

$$V_{para} = (Q, LLC^*, Tra_{w7}) \quad (7)$$

使用支持向量机 (support vector machine, SVM)、逻辑回归 (logistic regression, LR)、线性判别分析 (linear discriminat analysis, LDA) 和朴素贝叶斯 (navive bayes, NB) 4 类机器学习算法对该特征向量进行测试, 完成对两类状态的识别, 在机器学习分类过程中将 70% 的数据作为训练集, 剩余 30% 作为测试集。图 11 为 5 折交叉验证得到的平均分类准确率。可以看到, 针对两类状态的分类准确率均在 71% 以上, 其中 SVM 分类器的效果最好, 针对站立和坐下、站立和静态以及坐下和静态的分类准确率分别达到 74.4%, 77.0% 和 76.9%, 证明了该方法的有效性。

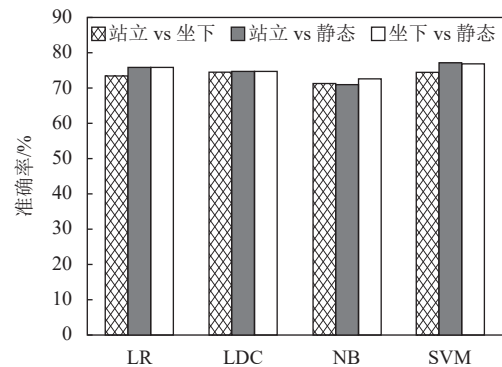


图 11 不同分类器对应分类结果

4 结束语

本文通过设计静坐到站立的动作转换实验, 完成对被试者在起立、坐下和静止状态下对应不同脑区脑电信号的同步似然分析, 通过构建动作执行前后 8 个时间窗口上的脑功能网络, 以超邻接矩阵表示的多层网络形式展开对不同动作状态下网络拓扑结构的特征分析。基于对多层网络特征和各子窗口

网络参数的统计分析, 确定对不同动作状态敏感的网络特征参数, 并使用 SVM、LR、LDA 以及 NB 等分类算法实现对起立、坐下和静止状态的分类识别, 分类准确率最高达到 77%, 证明了基于动作前后动态网络特征进行下肢运动意图检测和识别的可行性。针对多层动态脑功能网络的分析结果表明, 站立和坐下动作的发生会弱化脑区间的相互依赖关系, 从而导致网络拓扑连接结构变得逐渐稀疏, 该结果也为基于脑电的动作意图检测提供了新思路, 对开展基于脑机接口的下肢助行和康复机器人的开发具有一定的参考价值。

致谢: 本文得到了兰州交通大学天佑青年托举人才计划的基金资助, 同时也感谢博睿康开放课题 (BRKOT-LZJTU-20220329C) 对文章的支持。

参 考 文 献

- [1] HAMACHER D, HEROLD F, WIEGEL P, et al. Brain activity during walking: A systematic review[J]. *Neuroscience and Biobehavioral Reviews*, 2015, 57: 310-327.
- [2] LENNON O, TONELLATO M, FELICE A D, et al. A systematic review establishing the current state-of-the-art, the limitations, and the DESIRED checklist in studies of direct neural interfacing with robotic gait devices in stroke rehabilitation[J]. *Frontiers in Neuroscience*, 2020, 14: 578.
- [3] VILLA-PARRA A C, DELISLE-RODRIGUEZ D, LOPEZ-DELIS A, et al. Towards a robotic knee exoskeleton control based on human motion intention through EEG and sEMG signals[J]. *Procedia Manufacturing*, 2015, 3: 1379-1386.
- [4] BULEA T C, PRASAD S, KILICAESLAN A, et al. Sitting and standing intention can be decoded from scalp EEG recorded prior to movement execution[J]. *Frontiers in Neuroscience*, 2014, 8: 376 (1-19).
- [5] GWIN J T, GRAMANN K, MAKEIG S, et al. Electro-cortical activity is coupled to gait cycle phase during treadmill walking[J]. *NeuroImage*, 2011, 54: 1289-1296.
- [6] BULEA T C, PRASAD S, KILICARSLAN A, et al. Classification of stand-to-sit and sit-to-stand movement from low frequency EEG with locality preserving dimensionality reduction[C]//Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Piscataway: IEEE, 2013: 6341-6344.
- [7] HE Y, LUU T P, NATHAN K, et al. Data descriptor: A mobile brain body imaging dataset recorded during treadmill walking with a brain-computer interface[J]. *Scientific Data*, 2018, 5: 180074.
- [8] GRAMANN K, GWIN J T, BIGDELY-SHAMLO N, et al. Visual evoked responses during standing and walking[J]. *Frontiers in Human Neuroscience*, 2010, 4: 202.
- [9] SWERDLOFF M, HARGROVE L. Dry EEG measurement of P3 to evaluate cognitive load during sitting, standing, and walking[EB/OL]. [2021-12-27]. <https://doi.org/10.21203/rs.3.rs-1138956/v1>.
- [10] TORTORA S, ARTONI F, TONIN T, et al. Discrimination of walking and standing from entropy of EEG signals and common spatial patterns[C]//The IEEE International Conference on Systems, Man, and Cybernetics. Piscataway: IEEE, 2020: 2008-2013.
- [11] LI J, THAKOR N, BEZERIANOS A. Brain functional connectivity in unconstrained walking with and without an exoskeleton[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2020, 28(3): 730-739.
- [12] HANDIRU V S, ALICAR A, HOXHA A, et al. Graph-theoretical analysis of EEG functional connectivity during balance perturbation in traumatic brain injury: A pilot study[J]. *Human Brain Mapping*, 2021, 1: 1-21.
- [13] LAU T M, GWIN J T, FERRIS D P. Walking reduces sensorimotor network connectivity compared to standing[J]. *Journal of NeuroEngineering and Rehabilitation*, 2014, 11: 14.
- [14] RUBINOV M, SPORNS O. Complex network measures of brain connectivity: Uses and interpretations[J]. *NeuroImage*, 2010, 52: 1059-1069.
- [15] 李莉, 陈静静, 郑旭媛. 基于同步似然分析的阿尔茨海默症静息态脑电功能网络连接特性的研究[J]. *生物医学工程学报*, 2015, 32(5): 952-957.
- [15] LI L, CHEN J J, ZHENG X Y. Study on brain functional connectivity using resting state electroencephalogram based on synchronization likelihood in Alzheimer's disease[J]. *Journal of Biomedical Engineering*, 2015, 32(5): 952-957.
- [16] STAM C J, VANDIJK B W. Synchronization likelihood: An unbiased measure of functional synchronization in multivariate data sets[J]. *Physica D*, 2002, 163: 236-241.
- [17] BATTISTON F, NICOSIA V, LATORA V. Structural measures for multiplex networks[J]. *Physical Review E*, 2004, 89: 32804.
- [18] MANDKE K, MEIER J, BROOKES M J, et al. Comparing multilayer brain networks between groups: Introducing graph metrics and recommendations[J]. *NeuroImage*, 2018, 166: 371-384.
- [19] MUCHA P J, RICHARDSON T, MACON K, et al. Community structure in time-dependent, multiscale, and multiplex networks[J]. *Science*, 2010, 328: 876-878.
- [20] PEDERSEN M, ZALESKY A, OMIDVARNIA A, et al. Multilayer network switching rate predicts brain performance[J]. *PNAS*, 2018, 115(52): 13376-13381.
- [21] STAM C J, REIJNEVELD J C. Graph theoretical analysis of complex networks in the brain[J]. *Nonlinear Biomedical Physics*, 2007, 1(3): 1-19.

编辑 刘飞阳