doi:10.3772/j.issn.1002 -0470.2026.06.007

基于 EEG 的 Cbi-BPNN 模型在线预测“坐-站-走”姿态变换研究①

寿萧凯② 蔡世波 都明宇③

(浙江工业大学机械工程学院 杭州 310023)

摘 要 本文目的是提出一种“坐-站-走”姿态变换在线预测方法,为更好地控制下肢康复机器人提供理论支撑。首先,通过滤波、动态基线校正等方法对脑电信号进行在线预处理;然后,使用定向共空间模式(directional common spatial pattern, DCSP)、相关系数(correlation coefficent, CC)、曲线拟合(curve fitting, CF)、希尔伯特-黄变换(Hilbert-Huang transform, HHT)、离散小波变换(discrete wavelet transform, DWT)等方法在线提取多维度特征;最后,设计了一种级联式反向传播神经网络(cascaded by two back propagation neural network,Cbi-BPNN)模型进行“坐-站-走”姿态变换在线预测。本文招募8名受试者在特定范式下分别开展“坐-站-走”姿态变换脑电信号采集实验和在线预测系统验证实验,对比了8种姿态变换预测特征组合以及5种分类模型。实验结果表明,使用DCSP-CC-CF-HHT-DWT混合特征的姿态变换预测模型的离线分类准确率最高为76.09%,该模型可以在实际运动前200 ms左右实现在线预测,最高准确率为65.00 %。

关键词 运动准备电位; 在线预测; “坐-站-走”姿态变换; 共空间模式; 反向传播神经网络

脑卒中患者在康复中后期需要进行有辅助的“坐-站-走”等姿态变换康复训练,使用外骨骼等康复机器人辅助进行康复训练是已被证明的有效方式[1]。但是,如果康复训练过程中人-机之间频繁发生拮抗,将会对患者的依从性和主动参与康复训练的积极性带来很大的影响[2]。考虑到信号处理、模型推理、驱动器响应等时延问题,对“坐-站-走”等姿态变换进行不少于150 ms的大步长在线预测[3],进而为外骨骼机器人提供超前于患者实际运动的控制指令,是外骨骼机器人完成患者自主运动过程按需辅助的重要前提。

人体运动意图的无创感知途径包括两类,一类是惯性测量单元[4]、足底压力[5]等物理传感器,这类传感器需要在人体实际运动发生后才能采集到相关信号,一般很难在实际运动开始前进行运动预测;另一类是表面肌电信号[6]、脑电(electroencephalogram,EEG)信号等电生理信号,其中,表面肌电信号仅在人体实际运动前30 ~150 ms出现[7],也很难满足姿态变换大步长在线预测与机器人实时控制需求。

截止目前,无创脑机接口(brain computer interface,BCI)已被证明是最有前景的人体运动意图感知途径。Kalunga 等人[8]使用稳态视觉诱发电位(steady-state visual evoked potentia, SSVEP)控制上肢外骨骼进行康复辅助。Li 等人[9]使用触觉刺激的P300信号对抓握机器人进行控制。Tang 等人[10]通过左右手运动想象(motor image, MI)任务,结合虚拟现实(virtual reality, VR)场景进行手部康复任务。Jeong 等人[11]基于右臂6个空间方向上的伸展MI任务,对上肢康复辅助外骨骼进行控制。Choi 等人[12]通过起立、坐下、行走3类运动任务实现下肢外骨骼机器人的控制。SSVEP、P300、MI在脑卒中急性期/

① 浙江省重点研发项目(2023C03159),国家自然科学基金(62373326,U23A20338)和国家重点研发计划项目(2022YFC3601702)资助。
② 男,1997年生,硕士;研究方向:康复机器人及穿戴式采集设备设计;联系人,E-mail: shou974328490@163.com。
③ 通信作者,E-mail: dumingyu@zjut.edu.cn。
(收稿日期:2025 -03 -03)

亚急性期患者的运动康复训练过程中已有较多的应用,效果良好。但是,SSVEP、P300 属于运动不相干 EEG 信号,诱发过程需要提供外部刺激,长时间使用会导致患者的感受器疲劳;MI 则基于部分运动相关 EEG 信号,具有较强的模糊性,需要使用者预先进行大量练习。这些使用要求对于依从性较好的急性期/亚急性期患者来说尚且具有一定的困难,对于康复期患者来说更显累赘。

运动准备电位(readiness potential,RP)是人体运动开始前 1.0 s 大脑运动皮层自发产生的缓慢负向电位[13]。与 SSVEP、P300、MI 相比,RP 与即将到来的行为具有更高的相关性[14-15],且无需外部刺激和大量训练即可识别[16]。因此,通过运动前脑电预测患者运动意图,可以为外骨骼机器人提供实时性更好的控制指令。Bulea 等人[17]使用高斯混合模型分类器预测 3 种类型的运动任务,即“起立”、“坐下”和“静止”,平均准确率为 78.00%。Jochumsen 等人[18]提取了 RP 的互相关系数和功率谱密度作为随机森林的输入,对“坐到站”“站到坐”“直线行走”“上楼”“侧走”“后退”6 类运动任务进行预测,预测准确率为 54.00%。Ody 等人[19]基于运动前 800 ms的 EEG 信号对人体是否运动进行了预测,预测准确率达到 85.00%。以上研究虽然使用了运动前脑电对人体运动进行了预测研究,但是并没有提及在线预测提前于实际运动的时间。

针对上述问题,本文提出了一种基于运动前 EEG 信号与级联式反向传播神经网络(cascaded by two back propagation neural network,Cbi-BPNN)模型的“坐-站-走”姿态变换在线预测方法,更好地实现人机实时交互运动控制,激发患者主动参与康复训练积极性。本文主要研究内容及创新点如下。

(1)提出了一种动态基线校正方法,校正长时间采集 EEG 信号过程中直流分量变化导致的信号漂移问题。

(2)提出了一种定向共空间模式(directional common spatial pattern,DCSP)算法,减少了空间滤波器的随机信号输入,增强了 2 类姿态变换 EEG 信号的特征差异。

(3)设计了一种基于“坐-站-走”姿态变换在线预测方法的在线预测系统,在特定范式下,可以在人体运动前 200 ms 左右预测动作,其最高在线预测准确率为 65.00%。

1　方　法

本文通过对目标运动前的 EEG 信号进行特征提取,并作为 Cbi-BPNN 模型的输入,对人体的“站到坐”和“站到走”2 种姿态变换进行二分类的预测,预测方法流程图如图1所示,其中 μ 为均值,Var为

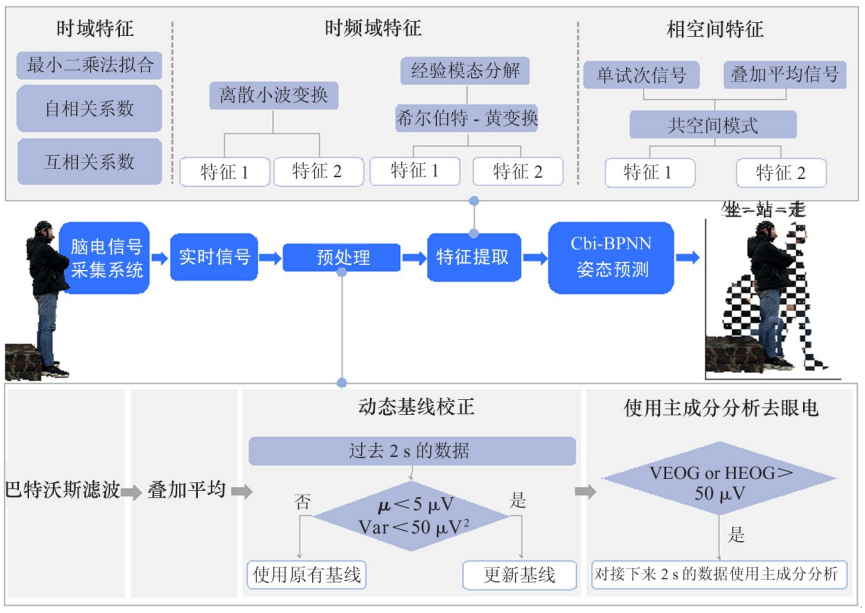

图 1　基于运动前脑电与 Cbi-BPNN 模型的“坐-站-走”姿态变换在线预测流程图

方差,HEOG 和 VEOG 分别为水平眼电(horizonta electro-oculogram,HEOG)和垂直眼电(vertical electro-oculogram,VEOG)。首先,对实时采集 EEG 信号使用巴特沃斯滤波器进行滤波[20],通过改进的动态基线校正方法减少信号漂移,在线特征提取时没有涉及到运动时脑电,因此仅对干扰可能最大的眼电伪迹通过主成分分析(principal component analysis,PCA)方法进行减少[21]。其次,使用本文改进的 DCSP 方法在线提取相空间特征,利用相关系数(correlation coefficent,CC)和曲线拟合(curve fit,CF)方法在线提取时域特征[22],利用希尔伯特-黄变换(Hilbert-Huang transform,HHT)和离散小波变换(discrete wavelet transform,DWT)在线提取时频特征[23]。最后,将上述混合特征作为 Cbi-BPNN 模型的输入,对人体的“坐-站-走”姿态变换进行在线预测。该方法对实时 EEG 信号的预处理和特征提取所花费的时间在 150 ms 左右,DCSP 方法占用了全部计算时间的 80.00%。

1.1 初始设置

本文首先设置“站到坐”和“站到走”2 类任务的标准信号,作为特征提取的参考信号。假设 $\boldsymbol{X}_1$,$\boldsymbol{X}_2$,…,$\boldsymbol{X}_j$ 是 j 类任务的实验采集 EEG 信号矩阵,其大小均为 $N \times T \times n$,其中 N 为通道数,T 为采样点数,n 为试次数;$\boldsymbol{Y}$ 是实时采集 EEG 信号矩阵,其大小为 $N \times T$。计算如式(1)和式(2)所示。

$$\boldsymbol{r}_j = \frac{\sum_{i=1}^{N}\sum_{j=n_0}^{n_1}\boldsymbol{X}}{N \times (n_1 - n_0)} \tag{1}$$

$$\boldsymbol{P} = \frac{\sum_{i=1}^{N}\boldsymbol{Y}}{N} \tag{2}$$

式中:$\boldsymbol{r}_j$ 为标准信号集合 $\boldsymbol{R}\{\boldsymbol{r}_1, \boldsymbol{r}_2, \cdots, \boldsymbol{r}_j\}$ 中 j 类任务的标准信号,$\boldsymbol{P}$ 为单通道实时信号,$\boldsymbol{X}\{\boldsymbol{X}_1, \boldsymbol{X}_2, \cdots, \boldsymbol{X}_j\}$ 为 j 类任务的 EEG 信号集合,n_0 和 n_1 的取值在 1 到 n 之间。然后,对最优时间窗内的信号进行特征提取和组合,作为分类模型的输入,通过对比不同组合的分类准确率,选择在线特征提取方法。

1.2 在线预处理

本文通过在线预处理算法得到高信噪比的 EEG 信号。首先,使用 0.1 ~ 30.0 Hz 的三阶巴特沃斯带通滤波器对原始信号作滤波处理,去除超低频直流分量和高频噪音,并尽可能避免 delta 频段(1.0 ~ 3.0 Hz)和 alpha 频段(8.0 ~ 12.0 Hz)的信号失真。然后,通过动态基线校正寻找相对稳定的数据段并更新基线,与传统固定基线校正相比,该方法可以在系统长时间运行的情况下更有效地减少直流分量变化对信号整体的影响。假设 $\boldsymbol{X}_T(t)$ 是长度为 T 的一维脑电信号,t 为采样点。将 $\boldsymbol{X}_T(t)$ 均分为 n 段并计算每段脑电信号的均值,通过计算相邻信号段均值的差值得到均值差向量 $\boldsymbol{\mu}$,再计算 $\boldsymbol{X}_T(t)$ 的方差 Var。设置一个目标均值差向量 $\boldsymbol{\mu}_b$ 和目标方差 Var_b,将均值差向量 $\boldsymbol{\mu}$ 和方差 Var 与 $\boldsymbol{\mu}_b$ 和 Var_b 进行比较来决定可否更新基线。计算如式(3) ~式(5)所示。

$$\mu_i = \frac{\sum_{t=((i-1)\times T/n)+1}^{i\times T/n}\boldsymbol{X}_i(t)}{T/n} \tag{3}$$

$$\boldsymbol{\mu} = \{\mu_i - \mu_{i-1}\} \tag{4}$$

$$\mathrm{Var} = \frac{\sum_{t=1}^{T}\left(\boldsymbol{X}_T(t) - \sum_{t=1}^{T}\frac{\boldsymbol{X}_T(t)}{T}\right)^2}{T} \tag{5}$$

式中:$\boldsymbol{X}_i(t)$ 为 $\boldsymbol{X}_T(t)$ 均分后的第 i 段脑电信号,μ_i 为第 i 段脑电信号的均值,当数据段的 $\boldsymbol{\mu} < \boldsymbol{\mu}_b$ 且 $\mathrm{Var} < \mathrm{Var}_b$ 时,使用该数据段可进行基线更新。当 HEOG 或 VEOG 检测幅值超过 50 μV 时,通过 PCA 进行眨眼或眼飘伪迹去除。通过以上预处理方法可以有效减少 EEG 信号采集过程中的大幅值眼电伪迹影响,提高短时间窗内实时 EEG 信号的信噪比,使其更接近离线分析时的高质量 EEG 信号,最大程度保证模型分类性能在线与离线一致。

1.3 在线特征提取

本文通过 CF 结合 PCA 提取时域上的曲线拟合特征 CF{CF1, CF2},其中 CF1$\{d_1, d_2, \cdots, d_j\}$ 中 d_j 为第 j 类标准趋势向量与实时趋势向量之间的欧氏距离特征,CF2$\{e_1, e_2, \cdots, e_j\}$ 中 e_j 为第 j 类标准趋势向量的张量矩阵与实时趋势向量的张量矩阵的主成分差值。首先,使用最小二乘法对 $\boldsymbol{P}$ 和 $\boldsymbol{R}$ 中的每个列向量进行四次函数曲线拟合,得到实时趋势向量 $\boldsymbol{PQ}$ 和标准趋势向量集合 $\boldsymbol{RQ}$,单个向量的长度为 T;其次,对每个趋势向量分别作张量积可得实时趋势

矩阵 ***PM*** 和标准趋势矩阵集合 ***RM***；然后，使用 PCA 分别提取 ***PM*** 和 ***RM*** 的 4 个方差贡献率在 0.85 以上的主成分及对应特征值；最后，计算 ***PQ*** 和 ***RQ*** 的欧氏距离以及 ***PM*** 和 ***RM*** 的主成分特征相似度。计算如式(6)～式(7)所示。

$$d_j = \sqrt{\sum_{y=1}^{T} (\boldsymbol{PQ}_y^2 + \boldsymbol{RQ}_{jy}^2)} \tag{6}$$

$$e_j = \boldsymbol{Peig} - \boldsymbol{Reig}_j \tag{7}$$

式中：$\boldsymbol{PQ}_y$ 为实时趋势向量的第 y 个元素，$\boldsymbol{RQ}_{jy}$ 为第 j 类标准趋势向量的第 y 个元素，***Peig*** 为实时趋势矩阵的主成分特征值，$\boldsymbol{Reig}_j$ 为第 j 类标准趋势矩阵的主成分特征值。本文通过让 ***P*** 进行自相关计算，然后对 ***P*** 和 ***R*** 进行笛卡尔积，并让每个向量对内的向量进行互相关计算，可得到时域上的相关系数特征 $\mathrm{CC}\{c_1, c_2, \cdots, c_j\}$，其中 c_j 为第 j 类标准信号与实时信号的笛卡尔矩阵向量互相关计算得到的相关系数。

利用 DWT 进行时频变换，再分区块提取时频域上的小波变换特征 $\mathrm{DWT}\{A, Atf\}$，其中，A 为幅值特征，Atf 为时频系数特征。该方法可有效降低时频矩阵复杂度，提高在线特征提取速度。使用 CMOR 小波作为小波基，对 ***P*** 进行 DWT，得到大小为 $f \times T$ 的时频矩阵 ***TF***，其中 f 为频段数，T 为采样点数。然后对矩阵行列作 n 等分，得到 n^2 个子矩阵。最后对各个子矩阵的幅值最大的元素进行提取并将该元素对应的时频系数进行线性叠加平均。计算如(8)和式(9)所示。

$$A = \frac{\sum_{i=1}^{n^2} a_i \times \max(\boldsymbol{TF}_i)}{n^2} \tag{8}$$

$$Atf = \frac{\sum_{i=1}^{n^2} (t_i \times T_{\max i} + f_i \times F_{\max i})}{n^2} \tag{9}$$

式中：$\boldsymbol{TF}_i$ 为时频矩阵 ***TF*** 的第 i 个子矩阵，a_i 为相应权重，$T_{\max i}$ 和 $F_{\max i}$ 为第 i 个子矩阵幅值最大的元素的行列数，t_i 和 f_i 为相应权重。对 ***P*** 进行经验模态分解得到本征模函数集合，然后通过 HHT 得到其时频矩阵，提取时频矩阵中的幅值最大及最小的元素作为时频域上的 HHT 特征。

本文提出一种改进共空间模式(common space pattern，CSP)[24]的 DCSP 算法，通过增加标准信号集合 $\boldsymbol{R}\{\boldsymbol{r}_1, \boldsymbol{r}_2, \cdots, \boldsymbol{r}_j\}$，将空间滤波器的其中一个输入通道设定为固定对照基准，减少了传统 CSP 算法因双输入通道均为变化信号所造成的两类信号特征差异小的问题。该算法让实时信号 ***P*** 和标准信号 $\boldsymbol{r}_j$ 可以通过 CSP 算法计算两者之间的差异性，进而明确实时信号 P 更接近何种任务态信号。该算法可使用短时间窗提取到 EEG 信号相空间上的特征 DCSP，减少了在线特征提取的计算时间，算法结构如图 2 所示。该算法包括 3 个步骤：对多种任务的预处理信号 $\boldsymbol{X}_j$ 分别计算叠加平均值得到标准信号集合 ***R***；计算实时信号 Y 的叠加平均值得到单通道实时信号 ***P***；对 ***P*** 和 ***R*** 作笛卡尔积，并让每一对向量通过 CSP 空间滤波器，得到相空间上实时信号和不同标准信号之间分离度最大的 i 个特征。

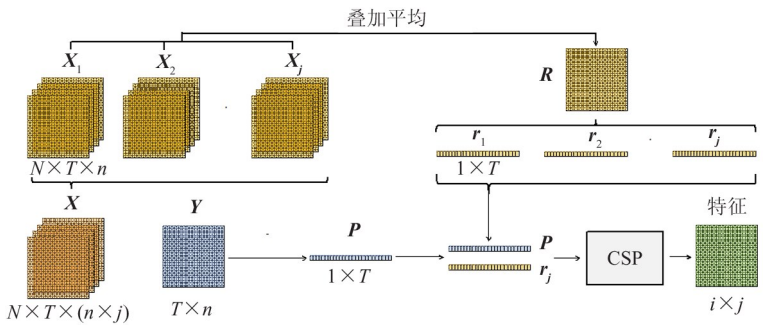

图 2　DCSP 算法的体系结构

1.4　Cbi-BPNN 模型

Cbi-BPNN 模型包括 2 个 BPNN[25]，分别进行运动意图识别和姿态变换预测，2 个网络的模型训练超参数如表 1 所示。当第 1 个 BPNN1 网络识别到

表 1　模型训练超参数表

	超参数名	选择数值
BPNN1	输入特征数	10
	隐藏层 1 神经元数	16
	隐藏层 2 神经元数	8
	学习率	0.010
	批量大小	40
	训练轮次	200
BPNN2	输入特征数	10
	隐藏层 1 神经元数	8
	隐藏层 2 神经元数	4
	学习率	0.001
	批量大小	10
	训练轮次	200

运动意图后,才会激活第 2 个 BPNN2 网络进行姿态变换预测。

这 2 个 BPNN 网络均包括 1 个输入层,2 个隐藏层和 1 个输出层,前 3 层使用 ReLU 激活函数,输出层则使用 Sigmoid 激活函数。第 1 个 BPNN1 网络的 2 个隐藏层分别设置了 16 个神经元和 8 个神经元,第 2 个 BPNN2 网络的 2 个隐藏层分别设置了 8 个神经元和 4 个神经元,网络结构如图 3 所示。为验证本文提出的Cbi-BPNN模型在运动意图识别和“坐-站-走”姿态变换预测中的有效性,在本文提取到的脑电信号特征数据集上进行验证实验,对比已有研究中使用过的高斯混合模型(gaussian mixture model, GMM)[17]、随机森林(random forest, RF)[18]2 种分类模型以及 K 最临近(K-nearest neighbor, KNN)、支持向量机(support vector machine, SVM)、深度神经网络(deep neural network, DNN)、长短期记忆网络(long short-term memory network, LSTM)4 种经典分类模型。

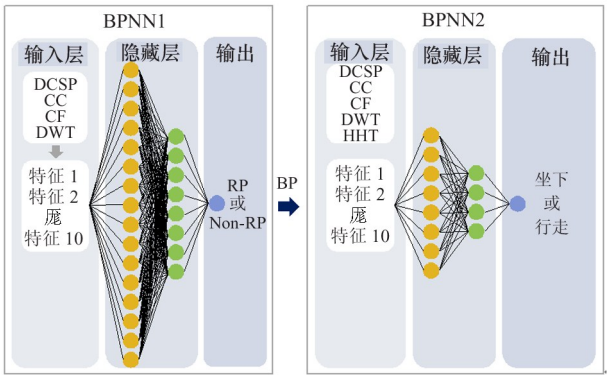

图 3　Cbi-BPNN 模型的体系结构

2　实　验

为训练上述模型并验证上述方法的有效性,本文开展了2个实验。一个是脑电数据采集实验,用于采集运动准备相关脑电数据并用于后续特征数据集的构建和模型的训练;另一个是在线预测系统验证实验,将预测模型结合在线预处理和特征提取方法在一定范式下对人体实际“坐-站-走”姿态变换进行预测,以验证该方法在实际预测中的有效性。

2.1　实验设备和被试

本文搭建了包含 iRecorder W16 脑电信息采集系统和一个 HWT901B-CAN 惯性测量单元(inertial measuring unit, IMU)在内的脑电与姿态变换信息同步采集系统。上位机为一台电脑,其配置为微软 Windows 10 操作系统,11th Gen Intel(R) Core(TM) i7-11800H CPU, NVIDIA GeForce RTX 3060 Laptop GPU,如图 4 所示,其中的上位机还同时作为模型训练平台使用。实验过程中,将 iRecorder W16 脑电信息采集系统中的 16 导联脑电帽佩戴至被试者头上,根据国际10-20标准选择VEoG、HEoG、FP1、FP2、

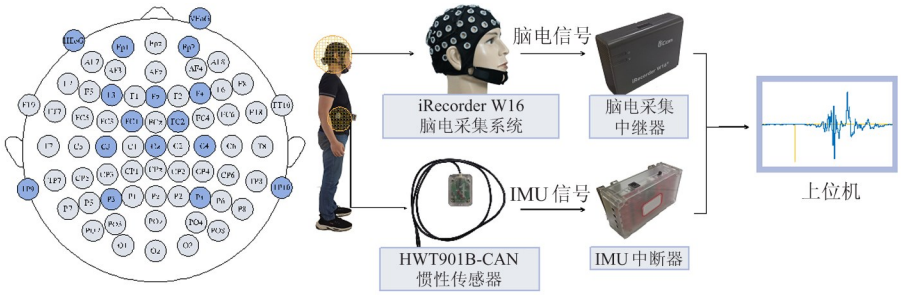

(a) 电极在头皮上的位置分布　　(b) 实验采集设备布置示意图

图 4　实验平台构成示意图

Fz、F3、F4、FC1、FC2、Cz、C3、C4、P3、P4、TP9、TP10 作为脑电采集位置，其中 VEoG、HEoG 为眼电电极，TP9、TP10 为双乳突参考电极，以覆盖了中央前回（运动区）的 Fz、F3、F4、FC1、FC2、Cz、C3、C4 作为分析电极，脑电信号的采样频率为500.00 Hz，使用灵敏度为 0.05 μV 的中继器将脑电信号通过蓝牙传输到上位机。

在在线预测验证实验中，额外使用束缚带将 HWT901B-CAN 惯性测量单元放置于被试者腰部，通过中继器将采样频率为 100.00 Hz 的腰部冠状轴角速度信号通过 WiFi 传输到上位机，使用上位机软件实现 IMU 信号和脑电信号的时间轴同步。

邀请了 8 名健康的志愿者参与本文研究，年龄为 24～27 岁，均为右利手，视听能力正常，近期无肌肉骨骼疾病且不存在明显神经损伤。所有被试者都事先签署了知情同意书，并明确知悉他们的参与是自愿的，且可以在任何时候选择退出，实验前详细说明实验目的和实验内容，在征得志愿者同意后开始相关实验。本文严格遵守受试者隐私的保护，所有数据均以匿名形式处理和存储。本文已经获得伦理委员会的批准（KY2022-173）。

2.2　实验范式设计

2.2.1　脑电数据采集实验

在一个安静恒温的室内，被试者按实验要求放松端坐，并平视前方 4 m 处的屏幕。要求被试者根据实验中的提示进行 5 组实验，每组实验包含 20 次运动任务，单次运动任务时长为 15.0 s，每组实验之间有 5 min 休息时间。当 t = 0.0 s 时屏幕出现白色十字和动作提示，提醒被试者进入实验预备阶段；随后 t = 0.0～10.0 s 时要求被试者保持身体静止并注视十字，并且按照被试者自己的意识随时按下标签按键并同时进行规定动作；当 t = 10.0 s 时语音提示被试者结束单次任务；最后 t = 10.0～15.0 s 时被试者保持休息状态，然后进入下一次运动任务。实验整体时序如图 5所示。要求 8 名被试者各自进行 1 次该实验，预期可采集 800 组多被试者脑电信号，其中 7 人的脑电信号（700 组）用于训练多被试预测模型而其余 1 人的脑电信号（100 组）用于测试，并进行八折交叉验证。其中一名被试者要求额外重复进行 8 次该实验，预期可采集到 800 组单被试者脑电信号，随机选取其中 80% 的数据进行单被试者预测模型的训练，剩余 20% 的数据对模型进行测试，并进行五折交叉验证。选择自主运动前 0.5 s 内的单被试及多被试脑电信号分别作为单被试及多被试运动意图识别模型的运动准备标签数据来源，随机选取相同数量的其余时间窗的单被试及多被试脑电信号分别作为单被试及多被试运动意图识别模型的非运动准备标签数据来源，随机选取其中 80% 的数据进行模型的训练，剩余20% 的数据对模型进行测试，并进行五折交叉验证。

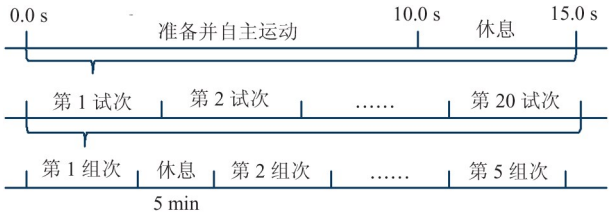

图 5　姿态变换脑电采集实验时间序列

2.2.2　“坐-站-走”姿态变换在线预测系统验证实验

该实验用于验证该系统在特定范式下在线预测的提前时间以及预测的准确率。在一个安静恒温的室内，要求被试者放松端坐，平视前方 4 m 处黑板上的十字。被试者需要根据实验中的提示音进行 20 次运动任务，单次运动任务时长为 11.0 s。当 t = 0.0 s时出现语音提示，被试者进行实验预备阶段；随后 t = 0.0～8.0 s 内被试者保持身体静止并注视十字；之后在 t = 8.0 s 时出现提示音并持续 1.0 s，t = 2.1 s时激活预测模型，使用 0.5 s 的滑动窗口对接下来的数据进行特征提取并作为模型输入进行预测，直到给出预测结果或 t = 4.0 s 时关闭预测模型。当模型预测出结果时会在实验员的屏幕上显示对应的结果。t = 9.0 s 时提示音结束，同时被试者开始随机进行坐或走的运动任务，运动要求在 2.0 s 内完成；然后进入下一次运动任务，实验整体时序如图 6所示。要求 8 名被试者各自进行 1 次该实验，预期可获得 160 组多被试者模型的预测结果。其中一名被试者要求额外重复进行 8 次该实验，预期可获得 160 组单被试模型的预测结果。本实验同步记录腰部冠状轴角速度信号和根据预测结果产生的脉冲信号，如图7所示，其中实线框内为“站到坐”信

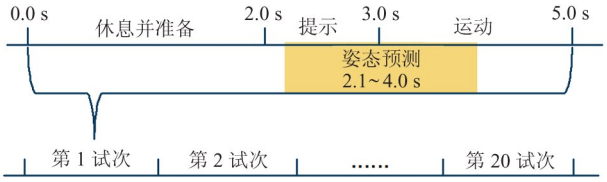

图 6　在线预测系统验证实验时间序列

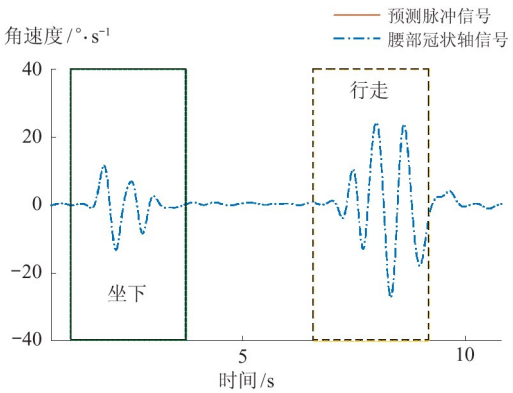

图 7　腰部冠状轴角速度信号和预测脉冲信号

号变化,虚线框内为“站到走”信号变化,角速度信号出现第 1 个明显波峰前的一半幅值点定义为实际运动开始时间点。

3　结　果

3.1　不同时间窗口选择

为获得特征提取的最优时间窗,本文对多个被试者的 2 类姿态变换的脑电信号进行叠加平均,并绘制对应的时频图和时域图,如图 8 所示。结果表明皮质运动区脑电信号的 delta 频段能量在运动前会不断上升,而 alpha 频段能量在运动前0.50 s(即 -0.50 s)左右会有所下降,时域信号在 -0.40 s 左右开始出现缓慢下降。本文选择 4 个滑动窗口的 EEG 信号特征作为 BPNN 模型的输入并多次进行五折交叉验证,所有验证中模型输出标签与实际标签一致的概率的平均,即平均分类准确率如图 9 所示。可以看出模型平均分类准确率随时间窗的延后而逐步提高,并从 -0.25 s 开始显著提升。

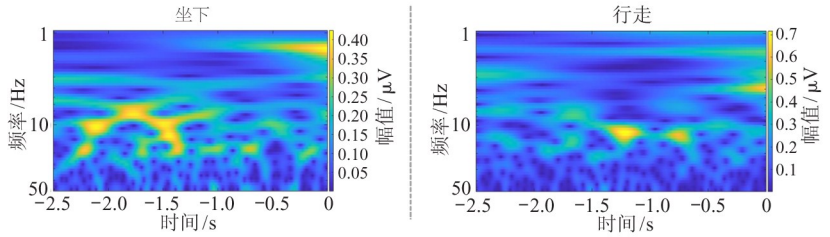

(a) 多试次叠加平均后 -2.5~0.0 s 时间区间上的 1.0~50.0 Hz 二类姿态变换时频图

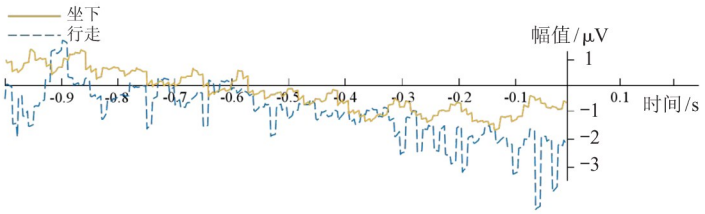

(b) 运动区多试次多通道叠加平均后 -1.0~0.0 s 二类姿态变换时频图

图 8　2 类姿态变换的脑电信号叠加平均后的时频图及时域图

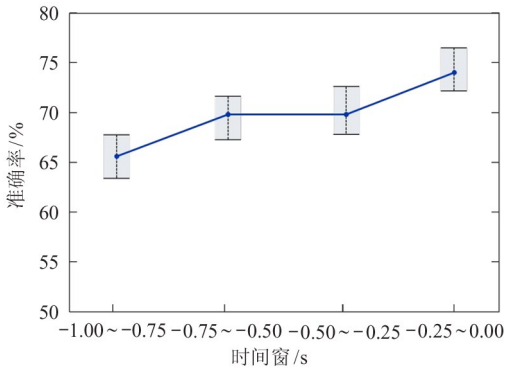

图 9　不同时间窗的 EEG 信号特征作为 BPNN 模型输入得到的平均分类准确率

3.2　特征组合对 BPNN 模型性能的影响

为获取能够有效进行运动意图识别和姿态变换预测的特征组合,本文将提取的 10 个运动意图识别特征和 10 个姿态变换预测特征按照提取方法进行分组。组间进行交叉混合作为 BPNN 的输入,并进行 4 次五折交叉验证,每种特征组合得到了 20 次模型分类准确率,其平均分类准确率如图 10 所示。实验结果表明将运动意图识别特征 DCSP + CC + CF +

DWT 和姿态变换预测特征 DCSP + HHT + CC + CF + DWT 作为模型输入得到的单被试模型分类准确率最高(平均准确率分别为 73.68% 和 72.96%);将运动意图识别特征 DCSP + CC + DWT 和姿态变换预测特征 DCSP + HHT + CC + CF + DWT 作为模型输入得到的多被试分类准确率最高(平均准确率分别为 71.46% 和 58.78%)。本文还对分类准确率最高的最优特征组合和其余特征组合进行配对 T 检验,显著性结果如图 10 所示,其中 $p < 0.050$ 标注为 *,$p < 0.010$ 标注为 **,$p < 0.005$ 标注为 ***。结果表明,使用上述最优特征组合和使用其余特征组合所得到的分类准确率均具有显著性差异。综合考量后,本文将 DCSP + CC + CF + DWT 和 DCSP + HHT + CC + CF + DWT 作为单被试运动意图识别特征和姿态变换预测特征,多被试分类特征则分别选择 DCSP + CC + DWT 和 DCSP + HHT + CC + CF + DWT。

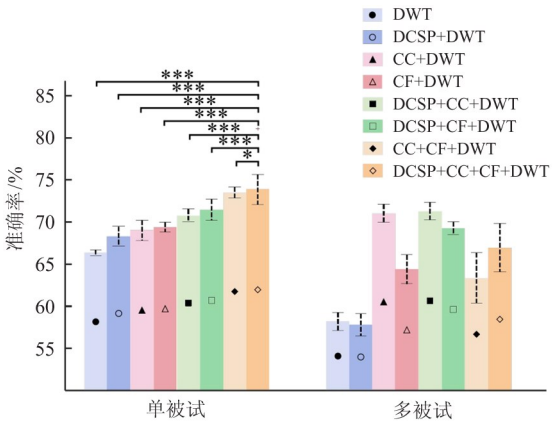

(a) 运动意图识别平均分类准确率

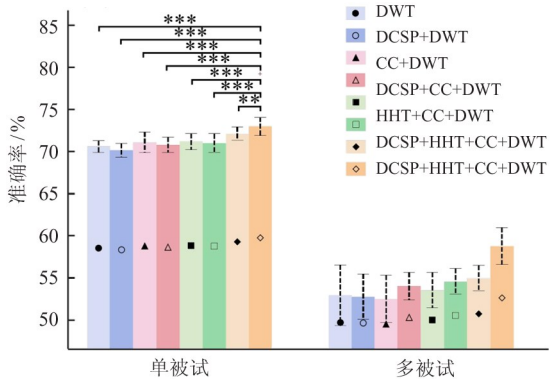

(b) 姿态变换预测平均分类准确率

图 10　不同类型特征组合下的运动意图识别及姿态变换预测准确率

3.3　BPNN 模型与不同模型的性能对比

为证明 BPNN 模型分别在运动意图识别和姿态变换预测中的可行性,本文将上述最优特征组合作为 KNN、SVM、DNN、LSTM、GMM、RF、BPNN 模型的输入,分别进行运动意图识别和姿态变换预测,各模型平均分类准确率如图 11 所示。实验结果显示,在单被试及多被试的运动意图识别和姿态变换预测分类中,BPNN 模型均具有最高的分类准确率(平均准确率分别为单被试 73.68% 和 72.96%;多被试 67.21% 和 58.78%)。本文还对 BPNN 模型的分类准确率和其余模型在相同情况下的分类准确率进行配对 T 检验,显著性结果如图 11 所示,其中半数以下情况具有显著性标记为 *,半数以上情况具有显著性标记为 **,全部情况具有显著性标记为 ***。结果表明,BPNN 模型比其余模型在相同情况下的分类准确率上具有显著性差异。

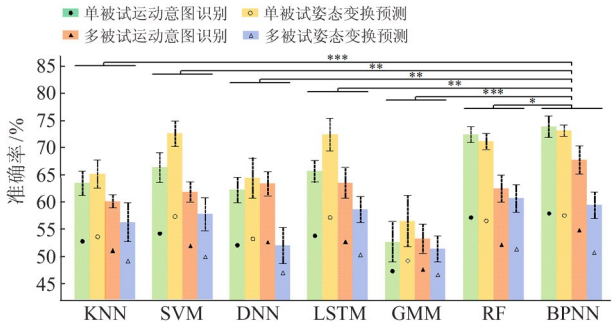

图 11　7 种分类器在不同情况下的平均分类准确率

3.4　离线模型的性能评估

本文使用多特征组合作为 BPNN 模型输入,分别得到运动意图识别和姿态变换预测模型,得到准确率最高的模型的混淆矩阵图,如图 12 所示,混淆矩阵中的预测标签与实际标签一致的概率分别为真阳性率(true positive rate, TPR)和真阴性率(true negative rate, TNR),反之则为假阳性率(false positive rate, FPR)和假阴性率(false negative rate, FNR)。图 12(a)和图 12(b)分别表示单被试运动识别模型和姿态变化预测模型的混淆矩阵,其中 RP 表示识别到运动意图,Non-RP 表示不存在运动意图或被试者已处于运动状态,“坐下”表示“站到坐”,“行走”表示“站到走”,2 个模型的 TPR、FNR、FPR、TNR 分别为 80.00%、20.00%、18.00%、82.00% 和

77.00%、23.00%、21.00%、79.00%。图 12(c)和图 12(d)分别表示多被试运动识别模型和姿态变化预测模型的混淆矩阵,2 个模型的 TPR、FNR、FPR、TNR 分别为 63.00%、37.00%、30.00%、70.00% 和 68.00%、32.00%、42.00%、58.00%。总体看来,单被试模型的分类准确率要远高于多被试模型。

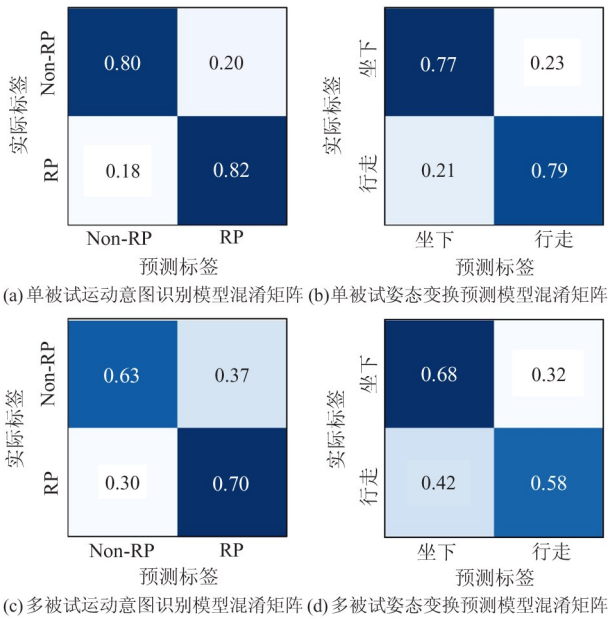

(a)单被试运动意图识别模型混淆矩阵 (b)单被试姿态变换预测模型混淆矩阵

(c)多被试运动意图识别模型混淆矩阵 (d)多被试姿态变换预测模型混淆矩阵

图 12　运动意图识别及姿态变化预测最高准确率模型的混淆矩阵

3.5　在线预测系统的可行性分析

为了验证 Cbi-BPNN 模型结合在线信号预处理算法和在线特征提取算法对实际人体姿态变换的预测提前时间及准确率,进行了 8 组单被试模型和多被试模型的验证实验,其中单被试模型的验证人员是提供了单被试脑电特征的被试者,而多被试模型的验证人员是没有提供任何脑电特征的被试者。在线预测准确率如表 2 所示,其中单被试 G01 组次实验的预测时序图如图 13 所示,其中错误预测的试次由深色矩形突出显示,局部视图展示了系统的预测

表 2　单被试及多被试的在线预测实验结果

实验组次	预测准确率	
	单被试	多被试
G01	0.65	0.40
G02	0.55	0.45
G03	0.60	0.50
G04	0.50	0.45
G05	0.55	0.40
G06	0.60	0.50
G07	0.50	0.35
G08	0.50	0.55
平均	0.56	0.45

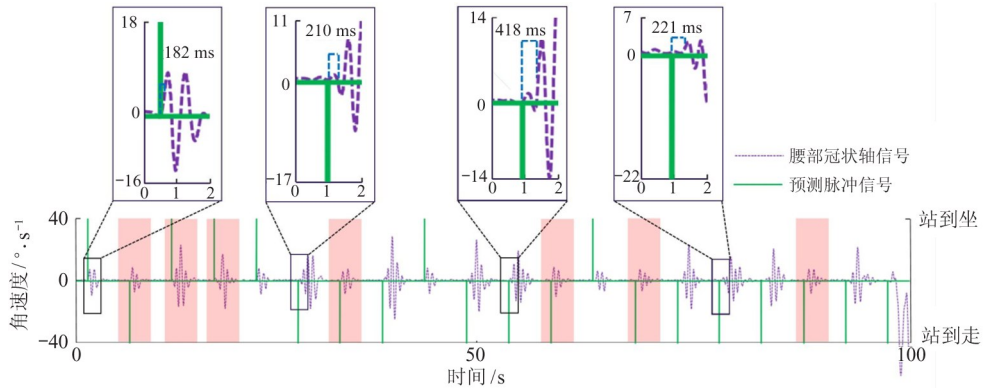

图 13　单被试 G01 组次在线预测实验的预测时序图

时间,即脉冲信号产生时间点到实际运动开始时间点的间隔。结果表明,全部试次的预测超前时间在 200 ms左右,单被试在线预测最高准确率为 65.00%,平均准确率为 55.63%,而多被试在线预测最高准确率为 55.00%,平均准确率 45.00%,单被试的在线预测准确率要高于多被试预测准确率。

4　讨　论

EEG 信号具有高时间分辨率,因此特征提取所用时间窗的选择在很大程度上影响最终模型分类精度的好坏。为确定最优的特征提取时间区间,本文对运动前短时间内脑电信号的时频图、脑电地形图、

时域图进行分析,如图 8 所示。然后,参考基于 EEG 信号的人体姿态变换识别、癫痫患者发病检测、机械振动信号分析等实验中的非线性非平稳信号处理及特征提取方法,在各个试次脑电信号的 4 个时间区间内(-1.00 ~ -0.75 s, -0.75 ~ -0.50 s, -0.50 ~ -0.25 s, -0.25 ~0.00 s)提取特征并作为 BPNN 模型的输入得到分类准确率,如图 9 所示。可以看出 -0.50 s 后时域信号出现明显负波,并且使用 -0.25 s后的特征进行模型分类得到分类准确率很高。为了确保 RP 的信息尽可能不丢失,同时减少计算量,本文选择提示前 0.50 s 内的数据进行运动意图识别和姿态变换预测。本文进一步使用滤波、动态基线校正、PCA 等在线预处理方法提高时间窗内 EEG 信号的信噪比,其中 PCA 算法相较于独立成分分析(independent component analysis,ICA)无法在不影响 EEG 信号的前提下有效去除各类微弱的眼电伪迹。本文在离线分析中使用 ICA 方法去除眼电伪迹也取得了不错的效果,但受到在线计算时间的限制,PCA 算法相对于 ICA 是更快速有效的在线眼电伪迹去除方法。

不同实验范式的脑电信号在多个维度上的表现形式有着不同差异,因此对不同维度特征提取算法的选择会直接影响所提取特征的离散度,进而间接影响最终模型的分类准确率。本文除了本研究中提到的 DCSP、CC、CF、DWT、HHT 特征提取方法外,还额外使用了李雅普诺夫指数估计[26]、功率谱密度估计、快速傅里叶变换等方法共提取得到 29 个运动意图识别特征和 29 个姿态变换预测特征,通过绘制散点分布发现多数特征的散点分布呈现出大面积混叠,仅有少量特征的散点分布有明显区分,根据散点的混叠面积大小和极值差异,最终保留 10 种运动意图识别特征和 10 种姿态变换预测特征。本文按照特征提取方法对保留的特征进行分组,并将组间特征交叉混合输入到 BPNN 中训练得到模型分类准确率,如图 10 所示,结果表明使用 DCSP-CC-CF-HHT-DWT 特征组合作为模型输入得到分类准确率最高。DWT 和 HHT 特征可有效提供信号时频域上的局部信息,但其通常会降低时频分辨率导致单个维度上的信息丢失[23]。CC 和 CF 特征能有效反映信号时域上的趋势及相关性,但对多数时间范围内的非线性非平稳信号表征能力有限[22]。DCSP 特征对于混沌和非线性系统有良好的表征能力,但难以很好地反映出线性周期信号的信息[24]。大脑作为一个混沌非线性系统,通常会产生非线性非平稳的 EEG 信号,但处于任务态时,EEG 信号却会趋于相对稳定,因此使用时域、时频域和相空间特征混合可以弥补彼此的不足,对 EEG 信号进行多维度表征,进而使模型获得更高的分类准确率。

机器学习算法的选择会直接影响到最终模型的分类准确率,因此确定一种可适用于“坐-站-走”姿态变换在线预测的机器学习算法至关重要。为验证 BPNN 在运动意图识别和姿态变换预测中的性能,本文将上述最优混合特征作为 7 种分类器的输入并进行性能比较,图 11 所示结果表明,所有情况下 BPNN 模型均获得最高准确率。目前还没有任何一种机器学习算法可以普遍应用于所有问题,算法需要根据具体应用对模型速度和精度的要求进行选择,LSTM 适用于处理时间序列数据,对于时序特征的提取有一定优势,但本文中的分类对象不存在时间上的先后关系,因此 LSTM 在本文的分类问题上性能不佳[27]。DNN 能够学习到复杂的特征表示,在大规模数据集上表现优秀,若使用降维前的数据作为 DNN 模型的输入,其分类性能表现最好,但是,本文需要进行在线预测,对特征进行降维处理,并且对模型作了结构简化,最终导致 DNN 模型性能下滑[28]。BPNN 不依赖于复杂的内部结构,使其相比于 DNN 更适合于在线预测,且在处理小批量简单特征上相较传统分类器 SVM、KNN 更具有优势[25]。在其他研究中所用到的分类模型 GMM 和 RF 对本文数据集的分类性能均劣于 BPNN。因此,本文综合考虑在线预测情况下模型的速度和精度,最终选择 BPNN 作为单被试运动意图识别和姿态变换预测的机器学习算法。

为验证在线预测系统在人体实时姿态变换时的预测可行性、准确性以及泛化性,本文通过“坐-站-走”在线预测系统验证实验采集到 IMU 信号和预测脉冲信号,如图 13 所示。由于不同被试的身体状况、动作习惯等有所差异,使得从不同被试者采集到

的 RP 的幅值和潜伏期也会有明显不同,导致 EEG 信号的个体差异性大,基于 EEG 信号的分类模型泛化能力低下,使得多被试在线预测准确率要低于单被试在线预测。其中单被试在线预测准确率低于离线模型,原因在于在线信号处理难以提取出接近理论信号的高信噪比 EEG 信号,且被试状态、动作执行等随机因素导致在线提取的特征有别于离线特征。

本文尽管得到了不错的结果,但依然存在着局限性。首先,虽然是面向康复中后期患者所开展的研究,但是所选择被试者全部为健康人,在未来的实验中,可以同医院康复科进行合作并采集康复患者的相关脑电信号,训练更贴近患者的模型;其次,“坐-站-走”姿势转换在线预测系统只能预测特定范式下的人体姿势,随着受试者数量的增加,模型的预测准确率显著降低,后续的研究可以进一步改进模型的泛化性;最后,本文的预测超前时间在 200 ms 左右,但理论上运动准备电位在运动前 1.0 s 左右产生,因此后续应该在更早的时间点提取特征,以训练出超前时间更长的预测模型。

5 结 论

本文提出了一种“坐-站-走”姿态变换在线预测方法。首先,使用滤波、动态基线校正、主成分分析等方法对实时采集 EEG 信号进行在线预处理;然后,使用 DCSP、CC、CF、DWT、HHT 算法对预处理信号进行在线特征提取;最后,将混合特征作为 Cbi-BPNN 模型的输入,对“坐-站-走”姿态变换进行在线预测。通过实验验证,本文选用的 DCSP-CC-CF-HHT-DWT 姿态变换预测特征作为 BPNN 模型输入,得到的离线分类准确率在姿态变换预测中最高,为76.09%;该模型的在线预测准确率最高为 65.00%,并且预测超前时间为 200 ms 左右。总的来说,预测人体下一时刻的“坐-站-走”姿态变换,有助于控制穿戴式外骨骼机器人辅助脑卒中康复中后期患者进行自主运动,为智能穿戴式外骨骼康复机器人的未来发展提供方向。

参考文献

[1] Deng H, Durfee W K, Rheude B S, et al. Complex versus simple ankle movement training in stroke using telerehabilitation: a randomized controlled trial[J]. Physical Therapy, 2012,92(2):197 - 209.

[2] Su D, Hu Z, Wu J, et al. Review of adaptive control for stroke lower limb exoskeleton rehabilitation robot based on motion intention recognition[J]. Frontiers in Neurorobotics, 2023,17:1186175.

[3] Kilteni K, Houborg C, Ehrsson H H. Rapid learning and unlearning of predicted sensory delays in self-generated touch[J]. Elife, 2019,8:e42888.

[4] Yi C, Zhang S, Jiang F, et al. Enable fully customized assistance: a novel IMU-based motor intent decoding scheme[J]. IEEE Transactions on Cognitive and Developmental Systems, 2021, 15(4): 2089 - 2098.

[5] 曹恒, 贺成坤, 孟宪伟, 等. 下肢外骨骼服传感靴的结构优化分析[J]. 工程设计学报, 2010,17(1): 35 - 39,65.

[6] 胡少康, 张道辉, 赵新刚, 等. 基于特征工程与级联森林的中风患者手部运动肌电识别方法[J]. 机器人, 2021,43(5):526 - 538.

[7] 丁其川, 熊安斌, 赵新刚, 等. 基于表面肌电的运动意图识别方法研究及应用综述[J]. 自动化学报, 2016,42(1):13 - 25.

[8] An Z, Wang F, Wen Y,et al. A real-time CNN-BiLSTM-based classifier for patient-centered AR-SSVEP active rehabilitation exoskeleton system[J]. Expert Systems with Applications,2024, 255:124706.

[9] Li M, Chen J, He B, et al. Stimulation enhancement effect of the combination of exoskeleton-assisted hand rehabilitation and fingertip haptic stimulation[J]. Frontiers in Neuroscience,2023, 17:1149265.

[10] Tang Z, Wang H, Cui Z,et al. An upper-limb rehabilitation exoskeleton system controlled by MI recognition model with deep emphasized informative features in a VR scene[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023,31:4390 - 4401.

[11] Jeong J, Shim K, Kim D, et al. Brain-controlled robotic arm system based on multi-directional CNN-BiLSTM network using EEG signals[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering,2020,28(5): 1226 - 1238.

[12] Choi J,Kim K T,Jeong J H,et al. Developing a motor imagery-based real-time asynchronous hybrid BCI controller for a lower-limb exoskeleton[J]. Sensors,2020,20(24): 7309.

[13] Schurger A, PakJ, RoskiesA L. What is the readiness potential? [J]. Trends in Cognitive Sciences, 2021, 25(7):558 - 570.

[14] Travers E, Khalighinejad N, Schurger A, et al. Do readiness potentials happen all the time? [J]. NeuroImage, 2020,206:116286.
[15] Travers E, Friedemann M, Haggard P. The readiness potential reflects planning-based expectation, not uncertainty, in the timing of action[J]. Cognitive Neuroscience, 2021,12(1):14 - 27.
[16] Schultze-Kraft M,Jonany V,Binns T S,et al. Suppress me if you can: neuro feedback of the readiness potential[J]. Eneuro,2021, 8(2):0425.
[17] Bulea T C, Prasad S, Kilicarslan 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.
[18] Jochumsen M, Niazi I K. Detection and classification of single-trial movement-related cortical potentials associated with functional lower limb movements [J]. Journal of Neural Engineering,2020,17(3):035009.
[19] Ody E, Kircher T, Straube B, et al. Pre-movement event-related potentials and multivariate pattern of EEG encode action outcome prediction[J]. Human Brain Mapping,2023,44(17):6198 - 6213.
[20] Wu H, Qi J, Purwanto E. Multi-scale feature and multichannel selection toward Parkinson's disease diagnosis with EEG[J]. Sensors, 2024,24(14):4634 - 4634.
[21] Ríos B A M, Leal C O M. Real-time EEG-based emotion recognition for neurohumanities: perspectives from principal component analysis and tree-based algorithms [J]. Frontiers in Human Neuroscience, 2024,18:1319574.
[22] Ahirwal M K, Kumar A, Singh G K,et al. Performance prediction of adaptive filters for EEG signal[J]. IET Science, Measurement and Technology,2017,11(5):525 - 531.
[23] Bahadur I N, Boppana L. Efficient architecture for ocular artifacts removal from EEG: a novel approach based on DWT-LMM[J]. Microelectronics Journa,2024,1:106284.
[24] ParkY, Chung W. Optimal channel selection using correlation coefficient for CSP based EEG classification[J]. IEEE Access,2020,8:111514 - 111521.
[25] Poorani S, Balasubramanie P. Seizure detection based on EEG signals using asymmetrical back propagation neural network method[J]. Circuits, Systems, and Signal Processing, 2021,40(9):4614 - 4632.
[26] übeyli E D. Lyapunov exponents/probabilistic neural networks for analysis of EEG signals[J]. Expert Systems with Applications, 2010,37(2):985 - 992.
[27] Nagabushanam P, Thomas George S, Radha S. EEG signal classification using LSTM and improved neural network algorithms [J]. Soft Computing, 2020, 24 (13): 9981 - 10003.
[28] Tragoudaras A, Antoniadis C., Massoud Y. Enhancing DNN models for EEG/ECoG BCI with a novel data-driven offline optimization method[J]. IEEE Access, 2023,11: 35888 - 35900.

Online prediction of sit-stand-walk posture transformation by EEG-based Cbi-BPNN model

Shou Xiaokai, Cai Shibo, Du Mingyu
(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

The purpose of this paper is to put forward an online prediction method for 'sit-stand-walk' posture transformation, which can provides theoretical support for better control of lower limb rehabilitation robot. Firstly, the electroencephalogram(EEG) signals were preprocessed online by filtering and the dynamic baseline correction method. Secondly, the multi-dimensional features were extracted online using the improved directional common spatial pattern (DCSP), correlation coefficient (CC) calculation, curve fitting (CF), Hilbert-Huang transform (HHT) and discrete wavelet transform (DWT). Finally, the sit-stand-walk posture transformation was predicted online by the model which is cascaded by two back-propagation neural network (Cbi-BPNN). In this paper, eight subjects were recruited to carry out the sit-stand-walk posture transformation EEG signals acquisition experiment and the verification experiment of the online prediction system. Eight feature combinations and five classification models for posture transformation prediction were also compared. The experimental results show that using the hybrid features of DCSP-CC-CF-HHT-DWT as the inputs of the posture transformation prediction model can obtain the highest offline accuracy of 76.09%. The model can predict human posture transformation about 200 ms before the actual movement with the highest online accuracy of 65.00%.

Key words: readiness potential, online prediction, sit-stand-walk posture transformation, common spatial pattern, back propagation neural network