

DOI: 10.7652/xjtuxb201910021

结合运动想象和动作观察的伸-握动作识别方法

王保增¹, 李大海², 张进华¹, 洪军¹, 仲文远¹

(1. 西安交通大学现代设计与转子轴承系统教育部重点实验室, 710049, 西安;
2. 西安航天动力试验技术研究所, 710100, 西安)

摘要: 为了获取单侧手部在伸-握动作下与运动想象直接相关的脑电信号(EEG)特征并实现精细动作有效识别,提出了结合运动想象和动作观察的单侧手部伸-握动作精细识别方法。首先,设计了结合运动想象和动作观察的复合范式,增强了伸-握动作所对应大脑皮层的激活程度,并探索了在运动想象、运动观察和复合范式下大脑皮层的激活规律;然后利用小波变换重构各个通道 EEG 并计算相应多尺度熵,并通过共空间模式获取伸-握动作所对应 EEG 特征;最后,利用线性判别式法从 EEG 特征中识别“伸开”和“握拳”精细动作。实验结果表明:相比单一实验范式的运动想象或动作观察,该方法在低频(5~20 Hz)时更能有效地激活运动区和枕区的神经元;同时,“伸开”动作对应 EEG 的多尺度熵明显大于“握拳”动作的熵值,实现了单侧手部伸-握动作精细意图感知,其平均正确率可达 85.7%。

关键词: 脑电信号;运动想象;动作观察;伸-握动作

中图分类号: R318.04 **文献标志码:** A **文章编号:** 0253-987X(2019)10-0151-08

A Recognition Method of Spread and Grasp Actions Combining Motion Imagination and Action Observation

WANG Baozeng¹, LI Dahai², ZHANG Jinhua¹, HONG Jun¹, ZHONG Wenyuan¹

(1. Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System, Xi'an Jiaotong University, 710049, Xi'an, China; 2. Xi'an Aerospace Propulsion Test Technology Institute, 710100, Xi'an, China)

Abstract: A recognition method for spread and grasp actions of a hand that combines motion imagination and action observation is proposed to obtain electroencephalogram (EEG) feature that is directly relevant to motor imagery of spread and grasp movements of the hand and to effectively identify fine actions. First, a compound paradigm that combines motor imagery and action observation (short for compound paradigm) is designed to enhance activation of the human cerebral cortex associated with the spread and grasp actions of a hand. Activation rules of the cerebral cortex are investigated under motor imagery, action observation and compound paradigm. Then, EEG is reconstructed for each channel by using a wavelet reconstruction and the multiscale entropy of EEG is calculated. EEG features of spread and grasp actions of the hand are extracted through a common spatial pattern. Finally, both the ‘spread’ and ‘grasp’ actions are identified from EEG features based on a linear discriminant method. Experimental results and comparisons with a single paradigm of motor imagery or action observation show that the

proposed method effectively activates neurons in motor cortex and occipital cortex in low frequencies (5-20 Hz), and the multi-scale entropy of ‘spread’ action from reconstructed EEG is obviously larger than that of ‘grasp’ action. The fine intention perception of spread and grasp actions of one hand is realized, and an average accuracy rate of 85.7% is achieved.

Keywords: electroencephalogram; motion imagination; action observation; spread and grasp action

手部运动功能障碍是脑卒中最常见后遗症之一,利用运动想象的脑机接口技术可辅助患者进行主动康复训练以达到运动功能恢复的目的^[1]。然而,单侧手部不同动作的运动想象所激活的大脑皮层脑区很近,很难发现 EEG 特征差异性,即单侧肢体不存在明显 ERD/ERS 现象,很难发现其在 EEG 中的激活规律^[2],因此,通过脑电信号(EEG)检测并识别单侧手部运动意图是一种挑战^[3]。

单侧手部伸-握功能障碍是日常生活中上肢远端最难恢复的精细动作之一^[4]。然而,一些学者对伸-握动作进行相关研究并从 EEG 中识别肢体动作。Schwarz 等让 15 名健康受试者执行手掌、钳状和横向抓握等伸-握运动,两两识别平均正确率为 72.4%^[5]。Ofner 等让 15 名健康受试者执行右手 6 种动作(肘关节弯曲和伸展、前臂旋后和内旋和手部伸开和握拳)的运动想象,其平均识别正确率分别达到 27%^[6]。Cho 等让 5 名健康受试者按照 19 寸 LED 显示器提示下对 5 种动作(左手伸开以及右手握拳、左旋、右旋和休息)进行运动想象,其识别正确率为 51.01%^[7]。由以上文献可知,伸-握动作在大脑皮层中激活不明显,这无疑增加了从 EEG 中识别伸-握动作的难度。然而,运动想象和动作观察均可激活神经元以实现大脑可塑性的目的^[8],有研究者指出动作观察或运动想象能激发相似的大脑活动,并提出在视频动作观察中辅助运动想象的范式能进一步加强神经元在大脑皮层激活^[9]。一般来说,动作观察和运动想象某一个动作会激活受抑制的大脑皮层神经元,这对运动功能障碍恢复和再学习是有利的。因此,亟需设计合理的单侧肢体精细动作运动想象范式以增强激活大脑皮层的程度。

针对单侧肢体伸-握精细动作在特定脑区 EEG 特征的新特点,有必要研究在伸-握动作下 EEG 特征的提取和识别方法。在 EEG 特征提取方面,共空间模式(CSP)被认为是最有效的两类特征提取算法,然而该算法缺少考虑 EEG 的频域信息和最优频带选择,影响了特征提取效果^[10]。为此,可通过离散小波变换(DWT)设置不同频带滤波器以重构各

通道对应的 EEG,再经过 CSP 算法对不同通道 EEG 的多尺度熵进行特征提取。在特征识别方面,线性判别分析(LDA)具有算法简单、运算速度快、不需要参数设置等优点,因此利用 LDA 算法构建基于 EEG 特征识别模型可有效地获得不同运动意图识别结果。

针对单侧手部动作所激活大脑皮层脑区很近及大脑皮层激活原则,本文设计了基于运动想象和动作观察相结合的复合范式(简称复合范式),扩充了训练任务类型并增强了伸-握动作对应大脑皮层激活程度,同时探索手部伸-握精细动作在不同范式下对大脑皮层的激活规律,并提出了基于 CSP 算法提取小波变换重构各通道 EEG 的多尺度熵特征,最后利用 LDA 对单侧手部伸-握动作精细意图感知,并获得理想识别结果。

1 实验范式设计

1.1 伸-握动作下的复合范式设计

通常来说,动作观察和运动想象存在一定区别。从宏观上看,动作观察重在对动作的观察和模仿,而运动想象偏重内心动作模拟或复现。从微观上看,前者存在一个换位感知的空间转换,而后者以自身为感知对象。因此,在同一个训练任务下,两种范式都能激活相似大脑皮层区域,而前者对枕区也存在明显激活现象,使得两者激活神经通路略有差别。不同训练任务下大脑皮层激活伴随着事件相关 EEG 幅值变化,与外界刺激任务是锁时的,故可叠加平均 EEG 检测 EEG 特征。通过复合范式激活大脑皮层,有助于增强患者运动功能障碍的恢复,同时也能促进脑功能重组。然而,仍然缺乏伸-握动作在运动观察、运动想象及复合范式下对大脑皮层的激活规律。

根据受试者大脑皮层激活程度与自身存储动作模式及场景有关原则,本文选取受试者在日常生活中常用“伸开”和“握拳”动作,不同实验范式参数如表 1 所示。

在伸-握动作下实验范式共分为 3 组,分别是动

表 1 在伸-握动作下不同实验范式参数

组别	简称	组数	时间/s
动作观察	AO	30	4
运动想象	MI	30	4
复合范式	CP	30	4

作观察(AO)、运动想象(MI)和复合范式(CP)。动作观察要求受试者观察视频中的动作;运动想象要求受试者想象刚刚消失视频中出现的动作;复合范式则要求受试者观察视频中的动作,并在视频消失后仍要不断地想象相应动作。根据受试者完成训练任务时间,选取运动观察视频长度为 4 s,同样,运动想象时间长度为 4 s,而复合范式时间长度为 4 s(由 2 s 动作观察和 2 s 运动想象组合而成)。每个受试者依次在 3 种实验范式下随机做 30 组伸-握动作训练。

1.2 在伸-握动作下训练实验

如图 1 所示,受试者在实验过程中坐在座椅上注视距离约为 75 cm 的显示器中的视频动作,并认真执行想象和观察相应动作任务。每个受试者按照实验流程依次完成在 MI、AO 和 CP 范式下的训练任务。



图 1 训练任务下 EEG 采集场景

在 3 种范式下手部伸-握动作训练任务及流程基本相同。以 CP 范式为例,其训练任务流程如图 2 所示。




图 2 复合范式下训练任务流程图

实验开始前,受试者在静息态下,采集 1 min 的 EEG 作为对照组。实验开始时,显示器背景首先为黑色,屏上指导语呈现 2 s,让受试者理解实验内容,紧接着受试者注视屏幕上白色十字光标 2 s,以提醒受试者注视屏幕中央。在第 4 s 时,屏幕上随机出现“伸开”或“握拳”动作,受试者观察相应动作 2 s 并理解所观察动作,随后屏幕上出现黑色背景,受试者继续想象消失动作 2 s 直到十字光标再次出现在屏幕中。如此反复,伸-握动作在屏幕中随机出现各 30 次,完成 CP 范式实验共计 244 s,结束本组实验后,受试者进入休息阶段。休息结束后,开始下一组实验。在 AO 范式中,注视十字光标消失后,观察随机出现视频动作 4 s,并直接出现十字光标,以进入下一个运动观察。在 MI 范式中,十字光标消失后,根据屏幕上观察视频动作 2 s,并在黑色背景出现后运动想象 4 s,然后直接出现十字光标,并进入下一次运动想象。每个受试者在 3 种范式下做训练实验,共计 180 个数据集(即每名受试者在 3 种范式下伸-握动作各执行 30 次)。

2 基于 EEG 的伸-握动作识别方法

2.1 脑电信号采集与预处理

本文选取 5 名健康受试者(3 男 2 女,年龄 22~27 岁),都没有神经相关疾病。实验前,受试者了解实验内容并签署知情书,并得到西安交通大学伦理道德委员会支持。EEG 采集是用 2 个并联 Syn-Amps2 放大器(Compumedics Ltd., VIC, Australia)连接 128 导脑电帽,电极安放位置按照 10—20 国际标准。所有导联采用 AgCL 电极,其阻抗均在 5 k Ω 以下。采样频率为 1 000 Hz,右耳乳突为参考电极。实验过程中受试者除做实验要求相关任务外,尽量避免身体其他部位运动以减少对 EEG 的干扰。通过 E-Prime 实现对 EEG 毫秒级精确打标,以保证后期数据处理时,确定每一个任务开始时所对应 EEG 的起始点。

为了提高 EEG 质量,首先对 EEG 进行预处理,如去除直流分量、人工查看数据以删除损坏通道和干扰严重数据段等,再重采样到 512 Hz、基线校正、重参考和利用巴特沃斯滤波器进行 0.5~45 Hz 带通滤波,最后利用独立成分分析去除眼电和肌电伪迹等干扰成分,并得到每名受试者均为相同的 115 通道所对应预处理后 EEG。

2.2 EEG 特征提取模型构建

根据小波分析具有多分辨率特征,将能量有限

的原始信号 $S'(t) \in L^2(R)$ 与子小波函数 $\varphi_{a,b}(t)$ 进行小波变换^[11],即

$$W(a,b) = \int_R S'(t) \varphi_{a,b}(t) dt \quad (1)$$

式中: a 为尺度因子, $a = a_0^j$; b 为平移因子, $b = nb_0 a^k$, $j, k \in \mathbf{Z}$ 。

对 a 和 b 离散化,则离散小波系数为

$$W(j,k) = \int_R S'(t) \varphi_{j,k}(t) dt \quad (2)$$

小波系数对应重构公式为

$$S(t) = \sum_{a,b} W(j,k) \bar{\varphi}_{j,k}(t) \quad (3)$$

设重构后离散信号 $S_1, S_2, \dots, S_H$ 共有 H 个通道和 N 个采样点,计算不同时间尺度下信号 $S(t)$ 的熵值^[12]。首先,对离散信号 $S(t)$ 进行粗粒化,可得

$$y_i^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} S(i), \quad 1 \leq j < \frac{N}{\tau} \quad (4)$$

式中: τ 为时间尺度。

其次,通过粗粒化新离散信号 y_i 构造 m 维向量 $\mathbf{S}_m(i) = \{y_i + K; 0 \leq K \leq m-1\}$, 序列长度 $M = \text{int}(N/\tau)$, 对任意一个 i 有与之对应的 $\mathbf{S}_m(i)$ 与其向量 $\mathbf{S}_m(j)$ 之间的距离 d_{ij} , $i, j = 1, M-m+1, i \neq j$; 再设定公差阈值 $r(r > 0)$, 并统计每个 i 对应 $d_{ij} < r$ 模版匹配数 $B^m(i)$, 计算 $B^m(i)$ 与距离总数 $M-m+1$ 比值的平均值

$$C^m(r) = (M-m+1)^{-1} \sum_{i=1}^{M-m+1} C_r^m(r) \quad (5)$$

当维数增加为 $m+1$ 时,重复以上方法,计算模版匹配数 $B^{m+1}(i)$ 与距离总数 $M-m$ 比值的平均值

$$C^{m+1}(r) = (M-m)^{-1} \sum_{i=1}^{M-m} C_r^{m+1}(r) \quad (6)$$

设定 M 值有限,则重复以上计算得到长度为 M 的样本熵估计值为

$$S_E(m, r, M) = -\ln[C^{m+1}(r)/C^m(r)] \quad (7)$$

最后,重复以上步骤,得到不同尺度下样本熵值,从而得到多尺度熵值。

由式(7)计算小波重构后各个通道对应 EEG 在不同尺度下对应的熵值作为 EEG 特征矩阵,以评价 EEG 在多个时间尺度上生理复杂性指数特征,并利用 CSP 对 EEG 进行特征提取^[13],其过程如下。

设两类 EEG 特征分别为 $H \times N$ 维矩阵 $\mathbf{X}_1$ 、 $\mathbf{X}_2$, 则每一类信号的归一化协方差为

$$R_i = \frac{\mathbf{X}_i \mathbf{X}_i^T}{\text{tr}(\mathbf{X}_i \mathbf{X}_i^T)}, \quad i = 1, 2 \quad (8)$$

式中: T 表示转置; tr 为矩阵 $\mathbf{X}_i \mathbf{X}_i^T$ 的对角元素和。

由平均方差矩阵 $\bar{\mathbf{R}}_1$ 和 $\bar{\mathbf{R}}_2$ 构造协方差矩阵之和 $\mathbf{R} = \bar{\mathbf{R}}_1 + \bar{\mathbf{R}}_2$, 并对 $\mathbf{R}$ 进行特征值分解

$$\left. \begin{aligned} \mathbf{R} &= \mathbf{U}_0 \mathbf{\Lambda} \mathbf{U}_0^T \\ \mathbf{W} &= \mathbf{\Lambda}^{-1/2} \mathbf{U}_0^T \end{aligned} \right\} \quad (9)$$

式中: $\mathbf{\Lambda}$ 为特征值对角阵; $\mathbf{U}_0$ 为对应的特征向量矩阵; $\mathbf{W}$ 为白化矩阵。

构造空间滤波器 1 和 2 分别为

$$\left. \begin{aligned} \mathbf{Q}_1 &= \mathbf{W}_1 \bar{\mathbf{R}}_1 \mathbf{W}_1^T = \mathbf{U}_1 \mathbf{\Lambda}_1 \mathbf{U}_1^T \\ \mathbf{Q}_2 &= \mathbf{U}_1 (\mathbf{I} - \mathbf{\Lambda}_1) \mathbf{U}_1^T \end{aligned} \right\} \quad (10)$$

当类别 1 对应的特征值 $\mathbf{D}_1^T$ 最大时,另一类特征值 $\mathbf{D}_2^T$ 最小,则信号投影方向为

$$\mathbf{F}_1 = \mathbf{D}_1^T \mathbf{W}; \quad \mathbf{F}_2 = \mathbf{D}_2^T \mathbf{W} \quad (11)$$

相应模式下投影为

$$\mathbf{Z}_1 = \mathbf{F}_1 \mathbf{X}_1; \quad \mathbf{Z}_2 = \mathbf{F}_2 \mathbf{X}_2 \quad (12)$$

为了使得到的信号特征更加明显,对投影后新的信号 $\mathbf{Z}_i$ 取平方值,并将能量的方差取对数作为最终的信号特征向量 $\mathbf{f}_i$,表达式如下

$$\mathbf{f}_i = \log \left(\frac{\text{var}(\mathbf{Z}_i^2)}{\sum_{i=1}^2 \text{var}(\mathbf{Z}_i^2)} \right) \quad (13)$$

式中: $\text{var}(\cdot)$ 为方差。

为了让 EEG 特征向量 $\mathbf{f}_1$ 和 $\mathbf{f}_2$ 更接近正态分布,对投影后特征的比值取对数运算,其结果作为不同类别 EEG 特征值。

2.3 伸-握动作识别模型构建

为了让 LDA 分类器在 EEG 特征中选择最好的投影方向,使得投影到超平面的类别最大限度地分开^[14],这里引入 Fisher 鉴别准则表达式

$$\mathbf{J}_{\text{fisher}}(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_b \mathbf{w}}{\mathbf{w}^T \mathbf{S}_w \mathbf{w}} \quad (14)$$

式中: $\mathbf{S}_b$ 为类间离散度矩阵; $\mathbf{S}_w$ 为类内离散度矩阵; $\mathbf{w}$ 为方向向量。

令 $\|\mathbf{w}^T \mathbf{S}_w \mathbf{w}\| = 1$, 在式(14)中加入拉格朗日乘子 λ 并求导可得

$$\mathbf{S}_b \mathbf{w} = \lambda \mathbf{S}_w \mathbf{w} \quad (15)$$

由于 $\mathbf{S}_w$ 可逆,则式(15)两边都乘 $\mathbf{S}_w^{-1}$, 可得

$$\mathbf{S}_w^{-1} \mathbf{S}_b \mathbf{w} = \lambda \mathbf{w} \quad (16)$$

由于 $\mathbf{S}_b = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T$ 和 $(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \mathbf{w} = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) * \lambda_w$, 其中 $\boldsymbol{\mu}_1, \boldsymbol{\mu}_2$ 分别为特征向量 $\mathbf{f}_1, \mathbf{f}_2$ 的均值向量,将 $\mathbf{S}_b$ 代入式(16)可得


$$\mathbf{w} = \mathbf{S}_w^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \quad (17)$$

由式(17)可知,通过 EEG 样本的均值和方差可求出最佳方向向量 $\mathbf{w}$ 。

3 结果及讨论

3.1 脑电特征分析与提取


LDA 分类原理是根据伸-握动作对应 EEG 特征寻找一个最优超平面,因此对“伸开”和“握拳”两种动作下 EEG 特征进行分析。为了更直观地显示受试者在做“伸开”和“握拳”动作时所对应的 ERD/ERS 在大脑皮层上的分布,通过对预处理后 EEG 进行离线谱图分析,以确定受试者在做伸-握动作时大脑皮层所产生的 EEG 特征规律。考虑不同实验范式 EEG 和个体受试者的差异性,对 EEG 特征分析时,提取并计算每名受试者分别在 MI、AO、CP 这 3 种实验范式下进行 30 次“伸开”和“握拳”动作所对应 EEG 的均值,并以受试者 1 的 EEG 为例进行特征分析。通过时-频分析绘制相应事件相关谱扰动(ERSP,用符号 P_{ERSP} 表示),并以运动区 C3 通道为例绘制时-频特征如图 3 所示。




(a)“伸开”动作的 ERSP (b)“握拳”动作的 ERSP
图 3 3 种范式下伸-握动作对应的 ERSP 图

在 MI 范式下,在做“伸开”动作时,5~20 Hz 频带的 ERSP 能量一直很高,而在做“握拳”动作时,在 0~1 s 时,5~20 Hz 频带 ERSP 能量高,而在 1~2 s 和 2.5~3 s 时间内一直处于低能量阶段。在 AO 范式下做“伸开”动作时,5~20 Hz 频带的 ERSP 能量很高,而在做“握拳”动作时,在 0~1 s 和 1~2 s 之间能量较低,且在 2.5~3.5 s 之间能量也相对较低。在 CP 范式下做“伸开”动作时,5~20 Hz 频带的 ERSP 能量很高,而在做“握拳”动作时,0~1 s 和 1~2 s 之间能量也相对较低。从时-频特征来看,“伸开”和“握拳”EEG 特征在 MI、AO 和 CP 范式下存在明显差异性,如在“握拳”动作下,图 3b 中矩形框内 1~2 s 之间能量明显较低,而在“伸开”动作下并无此现象。

从以上分析可知,伸-握动作下在 EEG 低频(5~20 Hz)信息中 0~1 s 或 1~2 s 之间能量存在显著差异,并且在 0~4 s 内绘制 3 种训练范式下的脑地形图,结果显示在 600 ms 处地形图差异性最明显,因此绘制在 600 ms 处脑地形图,结果如图 4 所示。



(a)“伸开”动作的脑地形图




(b)“握拳”动作的脑地形图

图 4 3 种范式下伸-握动作对应的脑地形图


除去头部周围干扰成分影响,在大脑皮层运动区和枕区相应能量变化明显。在 MI 范式下,在做“伸开”动作时,大脑皮层低能量在运动区,高能量区在左侧枕区;做“握拳”动作时,运动区能量增加,右枕区的能量降低明显。在 AO 范式中,做“伸开”动作时运动区两侧都处于低能量,中间能量较高,而枕区也存在高能量;做“握拳”动作时,运动区和枕区都处于高能量。在 CP 范式中,“伸开”和“握拳”动作的脑地形图存在明显差别,做“伸开”动作时运动区整个属于低能量且运动前区能量最低,而“握拳”动作时只有运动区右侧处于低能量,且两种动作对应枕区能量都相对高。从脑地形图上看,伸-握动作对应 EEG 在 ERD/ERS 特征上存在区别,但是规律并不像左右手运动想象那样明显,亟需探索单侧手部在伸-握动作下 EEG 特征显著的变化规律。

通过以上分析可知,在 CP 范式下 EEG 特征相对明显,但是不同动作对大脑皮层的激活程度并没有明确量化指标,而神经网络能反映受试者动作执行、运动想象以及心理活动对大脑的激活状态,大脑越活跃,其对应的脑功能网络连接越显著^[15]。通过脑功能网络工具(HERMES Toolbox)^[16]绘制在 3 种实验范式下 EEG 均值对应的脑功能网络,并以阈值 0.96 分别绘制相应脑功能连接图,结果如图 5 所示。

从图 5 中可以看出:在 MI 范式下,“伸开”和



(a)“伸开”动作的脑功能网络




(b)“握拳”动作的脑功能网络

图5 3种范式下伸-握动作对应脑功能网络

“握拳”动作在运动区和枕区有较少的脑网络连接；在 AO 范式下，两种动作下脑功能网络连接相对增多，主要集中在运动区和枕区；在 CP 范式中，伸-握动作对应脑功能网络无论在运动区还是枕区的连接都大幅度增加，显示在 CP 范式下伸-握动作对大脑皮层神经元激活最为强烈。

为了进一步研究 3 种实验范式下 EEG 特征变化规律，分别以运动区 C3 和 C4 通道为例研究在伸-握动作下 EEG 均值的多尺度熵，得到不同时间尺度下伸-握动作信号生理复杂性指数。在 3 种实验范式下对比尺度因子为 1~20 时的多尺度熵，结果如图 6 所示。



(a) C3 通道的多尺度熵 (b) C4 通道的多尺度熵

图6 3种范式下伸-握动作对应的多尺度熵

从图 6 中可以看出，在 3 种范式下“伸开”动作时通道 C3 和 C4 对应 EEG 的多尺度熵都大于“握拳”动作对应的多尺度熵，表明“伸开”动作对应的生理复杂性指数大于“握拳”动作指数，即在该动作下 EEG 多尺度局部瞬时特征发生了较大变化。但是，从多尺度熵值上看，MI 范式下伸-握动作在两个通

道上相差最少，特别是“伸开”动作下两者几乎存在交叉现象，而在 AO 和 CP 范式下，“伸开”和“握拳”动作对应的多尺度熵值差别明显，两个通道对应熵值差别大。对比 3 种范式下在各个尺度上的熵值，可明显区分不同动作下 EEG 多尺度熵。总体来看，伸-握动作在 1~6 尺度上熵值差别较大且相对稳定，考虑到最大限度利用 EEG 特征和计算速度，选择 1~6 尺度作为 EEG 特征。

基于以上 EEG 特征分析，通过 wavelet-CSP 提取多尺度熵值对伸-握运动意图进行分类。为了去除冗余信息和充分挖掘 EEG 中有用特征，故在 115 个通道中选取 FP1、FPz、FP2、AF3、AFz、AF4、F3、F1、Fz、F2、F4、FC3、FC1、FCz、FC2、FC4、C3、C1、Cz、C2、C4、CP3、CP1、CP2、CP4、P3、P4、PO3、PO1、POz、PO2、PO4、O1、Oz、O2 等 35 个通道对应 EEG。根据文献[17]，在 EEG 低频成分中含有大量运动信息，因此通过小波变换提取 EEG 中低频频带，首先，根据文献[18]以及经验选取小波基(db6)进行 Mallat 算法提取 EEG 特征，同时基于 EEG 中有效信息利用最大化原则，对伸-握动作下 EEG 进行 6 层小波分解，则重构小波系数对应前子频带范围为：A6(0~4 Hz)，D6(4~8 Hz)，D5(8~16 Hz)和 D4(16~32 Hz)。其次，选取低频频带 D5 和 D6 二个子频带进行重构，得到只包含低频(4~16 Hz)的 EEG，同时也去除了 EEG 高频成分中的干扰。

重构后得到每一任务下低频 EEG 矩阵(35 个通道×2 048 个数据点)，并分别计算对每一个通道所对应 1~6 尺度熵。对每一个受试者分别计算单次伸-握动作所对应 EEG 特征矩阵(35 个通道×6 个数据点)。利用式(9)和(11)分别计算出伸-握运动对应的协方差矩阵 R_1 和 R_2 ，并获得相应的空间滤波器 F_1 和 F_2 。经过对信号 $S(t)$ 进行小波变换、多尺度熵和共空间模式映射得到新特征向量 Z_1 和 Z_2 。为了得到更明显特征值，对 Z_1 和 Z_2 取平方得到信号能量变化，最后对信号能量取对数，得到接近正态分布的 EEG 特征值 f_1 和 f_2 ，同时增强不同动作下 EEG 特征之间的差异性。

3.2 伸-握动作识别结果与讨论

本文采用 LDA 模型进行训练和测试以实现伸-握动作在不同实验范式下有效分类。由于 EEG 伸-握动作数据集较少，为了防止 LDA 分类器出现过学习或者欠学习现象，对每名受试者在 3 种范式下 180 组数据集均采用 10 折交叉验证法划分 EEG 数据，并进行实验验证。

在训练 LDA 分类模型过程中,首先把 EEG 特征值 f_1 和 f_2 作为训练数据集输入到 LDA 训练模型中获得最优投影矩阵和分离平面,从而设计出最优 LDA 分类器。其次,在测试模型过程中,根据训练样本得到 LDA 分类器,将 10 折交叉验证剩余 EEG 作为测试样本进行模式分类,分别得到每名受试者在 3 种实验范式下对应的平均正确率及 5 名受试者的平均正确率均值,结果如图 7 所示。




图 7 3 种范式下伸-握动作的识别正确率

从图 7 可以看出:在 MI 范式下伸-握动作分类正确率最低,其均值为 74.9%,证明了 MI 范式能够实现伸-握动作识别;对于 AO 范式来说,其 EEG 分类平均正确率增加到了 80.6%,说明增加了视觉刺激后,提升了 EEG 特征差异性,该范式下伸-握动作的分类正确率得到一定提高;在 CP 范式下 EEG 识别率均高于其他两种实验范式,其平均正确率达到了 85.7%,从一定程度上说明该范式下伸-握动作对应的 EEG 特征差别较大。对于 5 名受试者来说, S1 在 3 种实验范式下正确率相对较高,因 S1 参与过大量的相关 EEG 实验并熟悉实验流程,而 S2 受试者年龄最大,反应相对较慢且在实验流程的理解上有困难,但也能实现伸-握动作的分类,同时各个受试者平均正确率的标准差并不大,说明本文所提方法具有很好的稳定性。

从正确率上来看, Tobing 通过右手完成伸开-抓取动作,并根据 EEG 进行模式识别,其测试正确率达到 70%^[19],而 Schwar 对单侧手掌和横向抓握伸-握动作分类正确率为 73.5%^[5]。本文所提出的方法在 MI 范式下伸-握动作对应 EEG 进行分类最高正确率可达到 76.8%,在 AO 范式下最高正确率为 82.6%,而在 CP 范式下最高正确率为 87.6%,其正确率在 3 种范式中最高,显示不同实验范式对伸-握动作分类结果存在较大影响。这可能是由于在 CP 范式中伸-握动作训练任务激活神经元明显,从而提高了该范式下伸-握动作分类正确率。

4 结 论

本文对受试者在 3 种范式下单侧手部伸-握动作精细意图识别进行研究,得出如下结论。

(1)提出了一种基于运动想象和运动观察相结合的复合范式用于手部训练,通过对 3 种范式 EEG 特征对比分析,在 CP 范式下扩充了训练任务类型并增强了伸-握动作对相应大脑皮层激活程度;同时,“伸开”动作对应 EEG 多尺度熵明显大于“握拳”动作对应熵值,为后续 EEG 识别提供了较好分类基础。

(2)提出一种基于小波变换和共空间模式相结合的特征提取算法,分别提取“伸开”和“握拳”动作下 EEG 多尺度熵,并利用 LDA 有效地识别出“伸开”和“握拳”动作。该算法可有效提取伸-握动作下 EEG 特征,从而让“伸开”和“握拳”动作平均准确率达到了 85.7%,证明该方法有效地实现了单侧伸-握动作精细意图识别。

本研究下一步将优化单侧伸-握动作下 EEG 特征提取模型参数,并提高 LDA 分类器解码性能,以进一步提高识别率。通过单侧手部伸-握精细动作意图识别,可实现主动对外部康复设备在线人机交互控制,以达到辅助康复训练的目的。

参考文献:

- [1] FROLOV A A, MOKIENKO O, LYUKMANOV R, et al. Post-stroke rehabilitation training with a motor-imagery-based brain-computer interface (BCI)-controlled hand exoskeleton: a randomized controlled multicenter trial [J]. *Frontiers in Neuroscience*, 2017, 11: 400.
- [2] PLOW E B, ARORA P, PLINE M A, et al. Within-limb somatotopy in primary motor cortex: revealed using fMRI [J]. *Cortex*, 2010, 46(3): 310-321.
- [3] XINYI Y, CARLO M. EEG classification of different imaginary movements within the same limb [J]. *Plos One*, 2015, 10(4): e0121896.
- [4] PARK W, JEONG W, KWON G H, et al. A rehabilitation device to improve the hand grasp function of stroke patients using a patient-driven approach [C]// 2013 IEEE 13th International Conference on Rehabilitation Robotics. Piscataway, NJ, USA: IEEE, 2013: 1-4.
- [5] SCHWARZ A, OFNER P, PEREIRA J, et al. Decoding natural reach-and-grasp actions from human EEG [J]. *Journal of Neural Engineering*, 2017, 15(1):

- 016005.
- [6] OFNER P, SCHWARZ A, PEREIRA J, et al. Upper limb movements can be decoded from the time-domain of low-frequency EEG [J]. *Plos One*, 2017, 12(8): e0182578.
 - [7] CHO J H, JEONG J H, SHIM K H, et al. Classification of hand motions within EEG signals for non-invasive BCI-based robot hand control [C]//2018 IEEE International Conference on Systems, Man, and Cybernetics. Piscataway, NJ, USA: IEEE, 2018: 515-518.
 - [8] ERTELT D, SMALL S, SOLODKIN A, et al. Action observation has a positive impact on rehabilitation of motor deficits after stroke [J]. *Neuroimage*, 2007, 36(2): T164-T173.
 - [9] 王刊. 观察运动与想象运动范式的脑电活动相关性研究 [J]. *电子设计工程*, 2015, 6(2): 24-26.
WHANG Kan. A brain's electrical activity correlation study between observation and imagination of hand movement [J]. *Electronic Design Engineering*, 2015, 23(6): 24-26.
 - [10] GUIDO D, BENJAMIN B, MATTHIAS K, et al. Combined optimization of spatial and temporal filters for improving brain-computer interfacing [J]. *IEEE Transactions on Bio-medical Engineering*, 2006, 53(11): 22-74.
 - [11] QUIROGA R Q, SCH RMANN M. Functions and sources of event-related EEG alpha oscillations studied with the wavelet transform [J]. *Clinical Neurophysiology*, 1999, 110(4): 643-654.
 - [12] JIA Y, GU H, LUO Q. Sample entropy reveals an age-related reduction in the complexity of dynamic brain [J]. *Scientific Reports*, 2017, 7(1): 79-90.
 - [13] UCHIYAMA E, TAKANO W, NAKAMURA Y. Multi-class grasping classifiers using EEG data and a common spatial pattern filter [J]. *Advanced Robotics*, 2017, 31(9): 468-481.
 - [14] LANGE G, LOW C Y, JOHAR K, et al. Classification of electroencephalogram data from hand grasp and release movements for BCI controlled prosthesis [J]. *Procedia Technology*, 2016, 26(3): 74-81.
 - [15] 徐晓晓, 喻婧, 雷旭. 想象未来的认知加工成分及其脑网络 [J]. *心理科学进展*, 2015, 23(3): 394-404.
XU Xiaoxiao, YU Jing, LEI Xu. Imagining the future: cognitive processes and brain networks [J]. *Advances in Psychological Science*, 2015, 23(3): 394-404.
 - [16] BRUNA, RICARDO, GUTIERREZ, et al. HERMES: towards an integrated toolbox to characterize functional and effective brain connectivity [J]. *Neuroinformatics*, 2013, 11(4): 405-434.
 - [17] ZHANG Jinhua, WANG Baozeng, LI Ting, et al. Non-invasive decoding of hand movements from electroencephalography based on a hierarchical linear regression model [J]. *Review of Scientific Instruments*, 2018, 89(8): 084303.
 - [18] 张小栋, 郭晋, 李睿, 等. 表情驱动下脑电信号的建模仿真及分类识别 [J]. *西安交通大学学报*, 2016, 50(6): 1-8.
ZHANG Xiaodong, GUO Jin, LI Rui, et al. A simulation model and pattern recognition method of electroencephalogram driven by expression [J]. *Journal of Xi'an Jiaotong University*, 2016, 50(6): 1-8.
 - [19] TOBING T, PRAWITO, WIJAYA S K. Classification of right-hand grasp movement based on EMOTIV Epoc + [C] // *Proceedings of the 2nd International Symposium on Current Progress in Mathematics and Sciences 2016*. Melville, NY, USA: AIP Publishing, 2017: 030069.

[本刊相关文献链接]

- 张黎明, 张小栋, 陆竹风, 等. 用于稳态视觉诱发电位特征频率提取的同步压缩短时傅里叶变换方法. 2017, 51(2): 20-26. [doi:10.7652/xjtuxb201702004]
- 李睿, 张小栋, 张黎明, 等. 面向假肢的场景动画稳态视觉诱发脑控方法. 2017, 51(1): 115-121. [doi:10.7652/xjtuxb201701018]
- 刘莲芝, 徐进, 徐燕芝, 等. 早期血管性痴呆患者的效应连接研究. 2016, 50(3): 146-150. [doi:10.7652/xjtuxb201603023]
- 徐光华, 张锋, 谢俊, 等. 稳态视觉诱发电位的脑机接口范式及其信号处理方法研究. 2015, 49(6): 1-7. [doi:10.7652/xjtuxb201506001]
- 郑杨, 王刚, 徐进, 等. 大脑皮层-肌肉交互作用与注意力关系的实验研究. 2014, 48(6): 134-138. [doi:10.7652/xjtuxb201406023]
- 董溯哲, 李晓玲, 姚磊, 等. 面向神经工效学的触控显示系统人机交互评价方法. 2014, 48(5): 123-128. [doi:10.7652/xjtuxb201405022]
- 赵梦璇, 李扩, 鲍刚, 等. 利用小波包的脑电源定位算法仿真研究. 2013, 47(12): 130-136. [doi:10.7652/xjtuxb201312022]

(编辑 刘杨)