

基于多时窗共空间模式的 HMM 运动想象脑电识别

蔡霄仙, 陈顺芝, 王江辉, 丁洋, 费克玲

(常州大学机械与轨道交通学院, 江苏常州 213164)

摘要: 运动想象脑电具有识别效果不佳及复杂时序信号建模困难的问题, 因此提出一种基于多时窗共空间模式的隐马尔可夫模型运动想象脑电识别方法; 首先将运动想象脑电划分为多个短时窗信号, 然后使用共空间模式提取特征序列, 以滤除脑电通道间的冗余信息, 最后采用前向-后相算法与 Viterbi 算法求解隐马尔可夫模型并完成分类识别; 将该方法在公开运动想象脑电数据集上进行实验, 得到 77.17% 的分类正确率, 相较隐马尔可夫模型算法提升了 5.74%, 验证了所提方法的有效性。

关键词: 多时窗; 共空间模式; 隐马尔可夫模型; 运动想象; 脑电识别

Motor Imagination EEG Recognition Based on HMM of Multi-Time Window Common Spatial Pattern

CAI Xiaoxian, CHEN Shunzhi, WANG Jianghui, DING Yang, FEI Keling

(School of Mechanical Engineering and Rail Transit, Changzhou University, Changzhou 213164, China)

Abstract: Aiming at the poor performance of motor imagery electroencephalogram (EEG) recognition and difficulty in modeling complex signals, a motor imagery EEG recognition method based on a hidden Markov model (HMM) of multi-time window common spatial pattern is proposed. Firstly, the motor imagery EEG is divided into different short time window signals, and then the common spatial pattern is used to extract the feature sequences, which can filter out the redundant information between EEG channels. Finally, the forward-backward algorithm and Viterbi algorithm are used to solve the hidden Markov model and complete the classification recognition. The proposed method is validated on a publicly available motor imagery EEG dataset, and the classification accuracy rate of the proposed method is 77.17%, which is 5.74% higher than that of the HMM algorithm, verifying the effectiveness of the proposed method.

Keywords: multi-time window; common spatial pattern; HMM; motor imagery; EEG recognition

0 引言

脑-机接口 (BCI, brain-computer interface) 可帮助受试者控制轮椅、假肢等设备, 提升生活质量^[1-2]。脑电 (EEG, electroencephalogram) 是 BCI 系统实现脑机通讯的信号依据, 其中运动想象 EEG 属于自发式脑电, 是受试者进行肢体不同部位的运动想象时所自发产生的 EEG 信号^[3-4]。BCI 通过对其进行解码, 可以将受试者的运动意图转化为控制命令, 实现对外部设备的控制。因此运动想象 EEG 能够为运动功能障碍患者提供康复训练交互的新方法, 具有极高的研究价值^[5]。

运动想象 EEG 信号解码是 BCI 想象任务识别的关键环节, 因其具有显著的非平稳、非线性特点, 信号的复杂性使 EEG 信号解码任务极具挑战性。目前学界用以研究运动想象脑电的信号分析方法一般都是针对信号的时域、频域、

时频域和空域进行的^[6-9]。Feng 等通过研究志愿者的想象任务进行的时间窗选择, 提出基于互相关的时窗选择算法, 多时窗分析脑电特征在时域上的动态变化, 该算法在不同的数据集上均能提取区分度高的特征^[10]。时域分析方法一般针对信号的波形进行特征提取, 虽然能够直观地对信号信息进行判断, 具有实时性, 但是特征较为单一, 忽视了脑电信号的频率信息。与时域分析不同的是, 特定的脑电信号往往会在特定的频段出现, 因此针对不同的频段进行研究也是脑电信号研究的常用方法之一。贾子钰等^[11]使用多尺度特征提取方法提取不同维度的特征, 构建挤压激励模型, 所得特征具有更强的表征能力。时频分析是研究脑电信号时应用最广泛的特征分析方法, 其同时具有时域分析和频域分析的优点。余青山^[12]使用双树复小波变换提取小波系数特征, 同时使用共空域模式 (CSP, common spatial pattern) 提取空间特征, 融合后送入支持向量机进行分

收稿日期: 2023-06-08; 修回日期: 2023-06-22。

基金项目: 常州大学教育教学研究课题 (GJY2021070); 2022 年江苏省研究生实践创新计划项目 (YPC22020099)。

作者简介: 蔡霄仙 (1998-), 男, 硕士研究生。

引用格式: 蔡霄仙, 陈顺芝, 王江辉, 等. 基于多时窗共空间模式的 HMM 运动想象脑电识别 [J]. 计算机测量与控制, 2023, 31(12): 277-283.

类, 实现多域特征提取与融合。对脑电信号进行空域特征提取也很常见。脑电信号有着多个电极通道, 若选取的通道数目过大, 通道之间会产生相互干扰, 严重影响系统的识别准确度和效率, 而特征频带的选取也决定了所提取空间特征的质量。孟明等^[13]提出块选择共空间模式, 在细分频段对信号进行局部化分析、构造数据块, 同时对通道和频段提取特征, 充分考虑了通道间的差异性。

在信号特征提取的基础上, 运动想象脑电解码问题被建模为具体想象任务的分类识别: 将来自空域、时域或时一频域的特征向量在相应的特征空间完成模式判别任务。为了分析运动想象脑电的动态变化规律, 动态模式识别方法^[14-15]被提出, 比如隐马尔可夫模型 (HMM, hidden markov model)、马尔可夫随机场模型以及条件随机场模型等。HMM 与传统的模式识别算法不同, 作为经典的概率图模型, 它表示一个含有隐藏未知参数的马尔可夫过程, 对于动态时间序列的数据有着更强的分析能力, 常用于时序数据建模。蔡怡^[16]等提出了基于支持向量机及隐马尔可夫混合模型 (SVM-HMM) 的模式判别方法, 通过 SVM 生成运动想象脑电概率序列, 并输入 HMM 进行模型训练与分类。

尽管上述方法能提取具有区分度的多域特征, 但参数调整较为繁琐。此外, 运动想象脑电是复杂的时序信号, 对长段脑电信号使用 HMM 建模时难以得到最佳模型。本文在上述研究的基础上, 提出一种基于多时窗共空间模式的隐马尔可夫模型运动想象脑电识别方法。首先对原始运动想象脑电进行分析, 采用多时窗方法划分出感兴趣的原始脑电时段, 然后通过 CSP 方法提取每段时窗信号的空域特征序列, 最后利用各时窗特征序列训练 HMM 模型, 避免长段信号在建模时无法表征复杂的状态变化。利用所得 HMM 模型对所提特征进行分类识别, 在公开运动想象脑电数据集上进行实验, 验证所提方法的有效性。

1 实验数据介绍

本研究所用数据来自格拉茨工业大学知识发现研究院 BCI 实验室提供的第四届 BCI 竞赛 2b 运动想象 EEG 数据集, 该数据集记录了 9 名受试者的采自 C3、C4、Cz 通道的 EEG 信号数据^[17]。其中 Cz 通道是参考通道, 与运动想象脑电的相关性较低, 因此在实际分析中只使用 C3 和 C4 通道的数据。信号采样频率为 250 Hz, 并进行了 0.5~100 Hz 的带通滤波和 50 Hz 的工频陷波滤波。每次实验开始时在电脑屏幕中央显示一个十字标识, 2 s 后设备会发出短暂的提示音, 第 3 s 时屏幕中的十字标识处出现带有方向的箭头, 箭头持续约 1.25 s。受试者需要在接下来的 4 s 内根据提示执行相应的运动想象任务。想象任务完成后, 受试者放松 1.5~2.2 s。单次运动想象实验的 EEG 信号采集范式如图 1 所示, 时长 7 s, 包含 1 750 个采样数据。每位受试者在完成左、右手运动想象任务时均进行 5 组实验, 其中前 3 组作为训练集, 包含左右手想象任务各 200 次, 后 2 组

作为测试集, 包含左右手想象任务各 160 次。

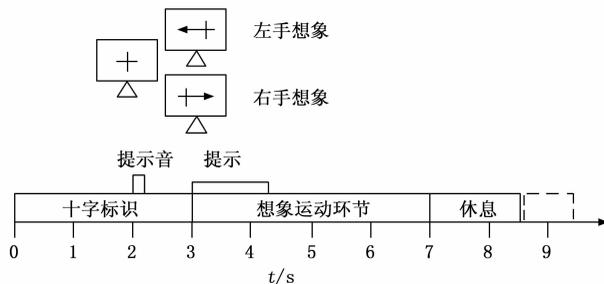


图 1 单次运动想象任务实验范式

2 基于多时窗分析的运动想象脑电识别模型

本文所构建的基于多时窗分析的运动想象脑电识别原理如图 2 所示, 主要分为 3 个部分: 1) 信号预处理, 运动想象脑电信号中混叠诸多背景噪声与工频干扰, 故将原始信号进行 0.5~30 Hz 带通滤波; 2) 将脑电划分为 6 个短时窗信号: tw_1 (2.5~4 s)、 tw_2 (3~4.5 s)、 tw_3 (3.5~5 s)、 tw_4 (4~5.5 s)、 tw_5 (4.5~6 s)、 tw_6 (5~6.5 s), 并使用共空间模式提取特征序列; 3) 训练各时窗运动想象脑电的隐马尔可夫模型, 利用所选寻优窗, 实现左手和右手运动想象任务的判别。

2.1 基于共空间模式的特征提取

共空间模式能够获取运动想象脑电空间信息, 因此常用于提取脑电特征^[18]。其核心思想是运用矩阵的对角化, 根据所用信号计算出一组区分度最高的空间滤波器, 令两类信号之间的方差差异最大, 以此获得表征能力强的特征向量^[19]。

假设目前使用的左右手运动想象信号在采集时使用了 N 个电极, 总共进行了 M 次想象任务, 其中左手任务 M_L 次, 右手任务 M_R 次。每次想象任务共包含 T 个数据点, 则左右手第 i 次想象任务的脑电数据可以用 $N \times T$ 矩阵表示:

$$X_L(i) = [x_L^1(i), x_L^2(i), \dots, x_L^j(i), \dots, x_L^T(i)]$$

$$X_R(i) = [x_R^1(i), x_R^2(i), \dots, x_R^j(i), \dots, x_R^T(i)] \quad (1)$$

式中, $x_L^j(i) = [x_L^{1-j}(i), x_L^{2-j}(i), \dots, x_L^{N-j}(i)]^T$, $x_R^j(i) = [x_R^{1-j}(i), x_R^{2-j}(i), \dots, x_R^{N-j}(i)]^T$, 分别表示左右手第 i 次想象任务中第 j 个数据点所有电极通道的脑电数据。

则对于该运动想象脑电信号, 构造对应的左右手运动想象空间滤波器步骤如下:

- 1) 计算运动想象任务脑电数据的平均分量, 并与原始信号数据做差值, 到归一化的左手想象数据 $V_L(i)$ 和右手想象数据 $V_R(i)$;
- 2) 计算左右手两分类任务数据的标准空间协方差矩阵 C_L 和 C_R , 得到复合协方差矩阵 C , $C=C_L+C_R$;
- 3) 对 C 进行特征分解, 得到特征值 φ 和特征向量 U , 进而计算白化矩阵 P , $P = \frac{1}{\sqrt{\varphi}} U^T$;

4) 将白化矩阵与左右手两分类任务数据的协方差矩阵相乘, 并进行特征分解, 得到相同的特征向量 \mathbf{B} ;

5) 根据特征向量 \mathbf{B} 和白化矩阵 \mathbf{P} 计算投影矩阵, 即空间滤波器 \mathbf{W} , $\mathbf{W} = \mathbf{B}^T \mathbf{P}$ 。

对特征值从大到小进行排序, 通常选取首尾的一组特征值对应的特征向量作空间滤波器。本文所用数据为左右手想象脑电, 因此需分别训练左手空间滤波器 \mathbf{W}_L 与右手空间滤波器 \mathbf{W}_R , 使用求得的空间滤波器对测试样本信号 X 提取特征向量 \mathbf{Z}_L 、 \mathbf{Z}_R , 其计算过程如式 (2) 所示:

$$\mathbf{Z}_L = \mathbf{W}_L \frac{X(i)X^T(i)}{\text{trace}(X(i)X^T(i))}$$

$$\mathbf{Z}_R = \mathbf{W}_R \frac{X(i)X^T(i)}{\text{trace}(X(i)X^T(i))} \quad (2)$$

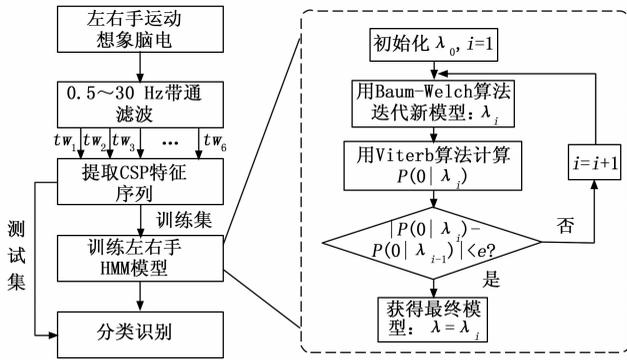


图 2 基于多时窗分析的运动想象脑电识别原理图

2.2 构建隐马尔可夫模型

HMM 是一种经典的双嵌入随机过程模型, 其对时序信号具有很强的建模能力^[20-21]。双随机过程之一是马尔科夫链, 它描述了状态 q 之间的统计对应关系, 另一个随机过程则描述了状态 q 和观测值 o 之间的统计对应关系, 如图 3 所示。

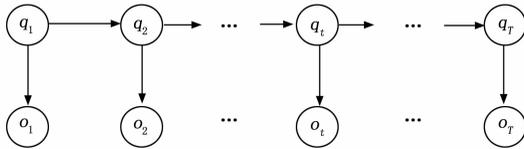


图 3 隐马尔可夫随机过程模型

假设一个马尔可夫过程有 N 个状态, 状态空间为 $\mathbf{S} = \{s_1, s_2, \dots, s_N\}$, 某一时刻 t 的状态取决于初始状态 q_1 和状态转移概率 \mathbf{A} 。初始状态的概率分布为 $\boldsymbol{\pi} = \{\pi_i = \mathbf{P}(q_1 = s_i)\} (1 \leq i \leq N)$, 状态转移概率矩阵为 $\mathbf{A} = \{a_{ij}\} (1 \leq i \leq N; 1 \leq j \leq N)$, 其中 $a_{ij} = \mathbf{P}(q_{t+1} = s_j | q_t = s_i)$ 代表从状态 s_i 转换到状态 s_j 的概率。

观测值输出概率 \mathbf{B} 用于描述状态和观测值之间的统计关系。 b_i 表示观测值的概率密度函数, 使用混合高斯概率密度函数进行计算。状态 s_i 在时间 t 输出 K 维观测序列 o_t 的概率为:

$$b_i(o_t) = \sum_{m=1}^M \left(c_{im} \frac{1}{2\pi^{K/2} |\mathbf{U}_{im}|^{1/2}} e^{-1/2(o_t - \boldsymbol{\mu}_{im})^T \mathbf{U}_{im}^{-1} (o_t - \boldsymbol{\mu}_{im})} \right) \quad (3)$$

式中, M 是混合高斯数。 c_{im} 、 $\boldsymbol{\mu}_{im}$ 和 \mathbf{U}_{im} 分别是状态 s_i 的第 m 个高斯的混合系数、均值向量和协方差矩阵。因此具有 N 个状态的隐马尔可夫模型可以用参数 $\boldsymbol{\lambda} = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 表示。

当状态转移概率矩阵 \mathbf{A} 和初始状态概率向量 $\boldsymbol{\pi}$ 已知时, 生成隐藏的状态序列。当观测概率矩阵 \mathbf{B} 已知时, 结合状态序列能够确定如何产生观测序列。因此, 隐马尔可夫模型具有两个关键的基本假设:

1) 齐次马尔可夫性: 假设隐藏的马尔可夫链在任意时刻 t 的状态均只与其前一时刻 $t-1$ 的状态有关联, 与其他时刻的状态和观测没有关联。

$$\mathbf{P}(q_t | q_{t-1}, o_{t-1}, \dots, q_1, o_1) = \mathbf{P}(q_t | q_{t-1})$$

2) 观测独立性: 假设任意时刻的观测值仅与该时刻的马尔可夫链的状态有关联, 与其他时刻的状态和观测没有关联。

$$\mathbf{P}(o_t | q_T, o_T, \dots, q_t, \dots, q_1, o_1) = \mathbf{P}(o_t | q_t)$$

基于上述两大基本假设, 可以进行 HMM 模型最优参数求解。当使用 HMM 进行模式判别时, 为了求得最优模型, 需要解决三大问题:

1) 观测序列概率估计: 模型 $\boldsymbol{\lambda} = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 确定, 其中 $\boldsymbol{\pi}$ 、 \mathbf{A} 、 \mathbf{B} 已知, 且观测序列也已知, 据此计算 HMM 生成观测序列的概率 $\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda})$ 。

2) 状态序列估计: 当给定模型 $\boldsymbol{\lambda} = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 和观测序列, 计算产生该观测序列的所有状态序列中概率最大的状态序列 \mathbf{Q} 。

3) HMM 模型参数估计: 当模型的隐状态数、观测状态数和观测状态序列均已知时, 估计最优的 HMM 参数 $\hat{\boldsymbol{\lambda}} = \{\hat{\mathbf{A}}, \hat{\mathbf{B}}, \hat{\boldsymbol{\pi}}\}$, 使输出概率 $\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda})$ 最大, 该问题又叫“学习问题”。

2.2.1 观测序列概率估计

由于产生观测序列 o_t 的状态序列并不唯一, 因此当参数 $\boldsymbol{\lambda} = (\boldsymbol{\pi}, \mathbf{A}, \mathbf{B})$ 已知时, 生成观测序列 o_t 的概率 $\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda})$ 为为每个状态序列产生观测序列 o_t 的概率之和:

$$\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda}) = \sum_{i=1}^L \mathbf{P}(o | q_i) \mathbf{P}(q_i) \quad (4)$$

其中: $q_i = [q_{i1}, q_{i2}, \dots, q_{it}, \dots, q_{iT}]$ 是一个隐状态序列, 由于 q_i 的长度为 T , 且在每个时刻 t , q_{it} 均有 N 个可能的状态, 因此 $L = N^T$, 计算代价太大。

为了减少计算的复杂度, 引入前向-后向算法。当 t 时刻时, 已产生观测序列 $o_1 \sim o_t$, 定义此时隐状态 s_j 的概率 $\alpha_t(j)$ 为为前向概率。前向算法是一种从前向后不断迭代计算相关概率的方法, 其递推式如下所示:

$$\alpha_t(j) = \left[\sum_{i=1}^N \alpha_{t-1}(i) a_{ij} \right] b_j(o_t) \quad (5)$$

与前向算法相对应的是后向算法, 该算法从后往前计算概率。当 t 时刻时, 已产生观测序列 (o_{t+1}, \dots, o_T) , 定

义此时隐状态 s_t 的概率为后向概率 $\beta_t(i)$ 。其递推式如下所示：

$$\beta_t(i) = \left[\sum_{j=1}^N \beta_{t+1}(j) a_{ij} \right] b_j(o_{t+1}) \quad (6)$$

将前向和后向算法相结合，可知在在 $1 \sim T$ 的任意时刻 t ，从 $0 \sim t$ 时刻可以使用前向算法， $t \sim T$ 时刻可以使用后向算法，其概率公式为：

$$\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda}) = \sum_{i=1}^N \alpha_i(i) \beta_i(i) \quad (7)$$

2.2.2 状态序列估计

根据状态概率定义式求解状态序列作为常规方法，其计算复杂度高，直接使用有一定难度。为了计算方便，一般使用 Viterbi 算法来求解状态序列估计。Viterbi 递推算法含有动态规划的思想，通过求取概率值最大的路径得到目标状态序列，此时不同的路径对应着不同概率的状态序列。

$[o_1, o_2, \dots, o_t]$ ，最优状态序列为 $[q_1, q_2, \dots, q_t]$ ，求解 $t+1$ 时刻观测序列 $[o_1, o_2, \dots, o_t, o_{t+1}]$ 的最优状态序列 $[q_1, q_2, \dots, q_t, q_{t+1}]$ 。当 t 时刻 q_1, q_2, \dots, q_{t-1} 已确定，且 $q_t = s_i$ 时，产生 $[o_1, o_2, \dots, o_t]$ 的概率 $\delta_t(i)$ 最大。定义变量 $\delta_t(i)$ 如下：

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P(q_1 q_2 \dots q_{t-1} q_t = s_i | o_1, o_2, \dots, o_t, \boldsymbol{\lambda}) \quad (8)$$

Viterbi 具体递推过程如下：

1) 初始化 $\delta_t(i)$ 和 $V_1(i)$ ，用二维数组 $V_t(j)$ 来记录每个 $\delta_t(i)$ 对应的最优状态。

2) 递推：

$$\delta_t(j) = [\max_{i=1 \sim N} (\delta_{t-1}(i) a_{ij})] b_j(o_t) \quad (9)$$

$$V_t(j) = \arg \max_{i=1 \sim N} (\delta_{t-1}(i) a_{ij}) \quad (10)$$

3) 终止：

$$\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda}) = \max_{i=1 \sim N} \delta_T(i) \quad (11)$$

$$q_T^* = \arg \max_{i=1 \sim N} \delta_T(i) \quad (12)$$

4) 由 q_{T+1}^* 通过搜索 $V_t(j)$ 进行反推，得到 q_t^* ，依次迭代，最后得到最优状态路径 $(q_1^*, q_2^*, \dots, q_T^*)$ 。

2.2.3 HMM 模型参数估计

为了得到最大的输出概率 $\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda})$ ，需要通过训练寻找最优模型参数 $\hat{\boldsymbol{\lambda}} = \{\hat{\mathbf{A}}, \hat{\mathbf{B}}, \hat{\boldsymbol{\pi}}\}$ 。在 $\boldsymbol{\lambda}$ 不断的迭代中， $\mathbf{P}(\mathbf{O} | \boldsymbol{\lambda})$ 最终会达到最大，此时对应的 $\boldsymbol{\lambda}$ 参数即为 HMM 最优模型参数。当观测序列已知而状态序列未知时，为了求解该学习问题，一般使用 Baum-Welch 算法。首先定义：

$$\xi_t(i, j) = \mathbf{P}(\mathbf{O}, q_t = s_i, q_{t+1} = s_j | \boldsymbol{\lambda}) \quad (13)$$

式中， $\xi_t(i, j)$ 表示当观测序列 \mathbf{O} 和模型参数 $\boldsymbol{\lambda}$ 均已知的情况下， t 时刻状态为 s_i ，而 $t+1$ 时刻状态为 s_j 的概率。

根据前向后向算法可得：

$$\xi_t(i, j) = [\alpha_t(i) a_{ij} b_j(r_{t+1}) \beta_{t+1}(j)] / \mathbf{P}(\mathbf{O} | \boldsymbol{\lambda}) \quad (14)$$

由此得到 t 时刻状态 s_i 的概率：

$$\begin{aligned} \beta_t(i) &= \mathbf{P}(\mathbf{O}, q_t = s_i | \boldsymbol{\lambda}) = \\ &= \sum_{j=1}^N \xi_t(i, j) = \alpha_t(i) \beta_t(i) \mathbf{P}(\mathbf{O} | \boldsymbol{\lambda}) \end{aligned} \quad (15)$$

由上式可得，从状态 s_i 转移出去的期望值数目为 $\sum_{j=1}^{T-1} \xi_t(i, j)$ ，从状态 s_i 转移到状态 s_j 的期望值数目是 $\sum_{t=1}^{T-1} \xi_t(i, j)$ 。因此得到 $\boldsymbol{\lambda}$ 参数估计公式：

$$\bar{\boldsymbol{\pi}} = \boldsymbol{\xi}_1(i) \quad (16)$$

$$\bar{a}_{ij} = \sum_{t=1}^{T-1} \xi_t(i, j) / \sum_{t=1}^{T-1} \xi_t(i) \quad (17)$$

$$\bar{b}_{jk} = \sum_{t=1, r_t = o_k}^{T-1} \xi_t(j) / \sum_{t=1}^{T-1} \xi_t(j) \quad (18)$$

通过上面的步骤更新参数，可以求出新的模型 $\bar{\boldsymbol{\lambda}} = \{\bar{\mathbf{A}}, \bar{\mathbf{B}}, \bar{\boldsymbol{\pi}}\}$ 。当迭代到 $\mathbf{P}(\mathbf{O} | \bar{\boldsymbol{\lambda}})$ 没有明显变大时，认为其达到最优，此时的 $\bar{\boldsymbol{\lambda}}$ 即为最优模型。

2.3 性能指标

为评估所提运动想象脑电识别方法的性能，本文采用的性能度量评价指标为准确率 Acc ，体现正确分类样本数占总样本个数的比例。其计算公式如式 (19) 所示：

$$Acc = (TP + TN) / (TP + FN + TN + FP) \times 100\% \quad (19)$$

其中： TP 、 TN 分别是被测试为正的样本数、被测试为正的负样本数， FP 、 FN 分别为被测试为负的正样本数和被测试为负的负样本数。

3 实验结果及分析

为验证本文所提方法进行运动想象脑电识别的可行性，将各受试者的 400 组数据作为训练集，320 组数据作为测试集进行实验。首先将原始运动想象脑电进行 0.5~40 Hz 带通滤波，并从第 2.5 s 开始依次截取时长 1.5 s，重叠 1 s (2.5~4 s, 3~4.5 s, ..., 5~6.5 s) 的脑电信号，记为 $tw_1 \sim tw_6$ ，然后分别对每段数据使用 CSP 进行空间滤波，将滤波完成的空间向量作为 HMM 的观测序列，接着使用前向-后向算法和 Baum-Welch 算法分别计算 HMM 模型的最优参数，最后使用 Viterbi 递推算法计算对应脑电信号特征的概率值，完成分类识别。由于本文研究的是左右手运动想象二分类问题，因此需要分别对左手想象和右手想象训练 HMM 模型。

实验过程中，使用左手运动想象与右手运动想象脑电信号训练集提取空域特征。为了得到适合分类的左右手运动想象特征，分别对 $tw_1 \sim tw_6$ 时窗脑电提取特征，分析不同时窗信号所提特征的差异。使用各时窗运动想象脑电信号提取的 CSP 特征差异明显，将受试者 5 的 6 个时窗信号所提特征经降维处理后画出二维散点图，如图 4 所示。其中，三角为左手运动想象特征，圆点为右手运动想象特征。图中每个点表示从每组训练数据集提取的特征值，若同类点呈聚集趋势，则说明该特征具有区分度。可以看出， tw_1 、 tw_5 、 tw_6 所提特征的特征分布较为分散，两类任务之间没有明显的间隔界限。相比之下 tw_2 的左手特征点分布紧密，且与右手特征分布存在一定的距离。而 tw_3 、 tw_4 所提特征的特征分布更为密集，同类想象任务特征点呈聚集趋势，不同类想象任务特征点之间则有明显分界。所提 CSP 特征在 tw_3 、 tw_4 时窗中均表现出明显的特征类间差异，具有较好的可分性。这是由于受试者在进行运动想象任务时，不同时间段的脑状态存在差异。在单次运动想象任务中，相比于大脑处于放松状态的前 3 s，当大脑处于运动想象状

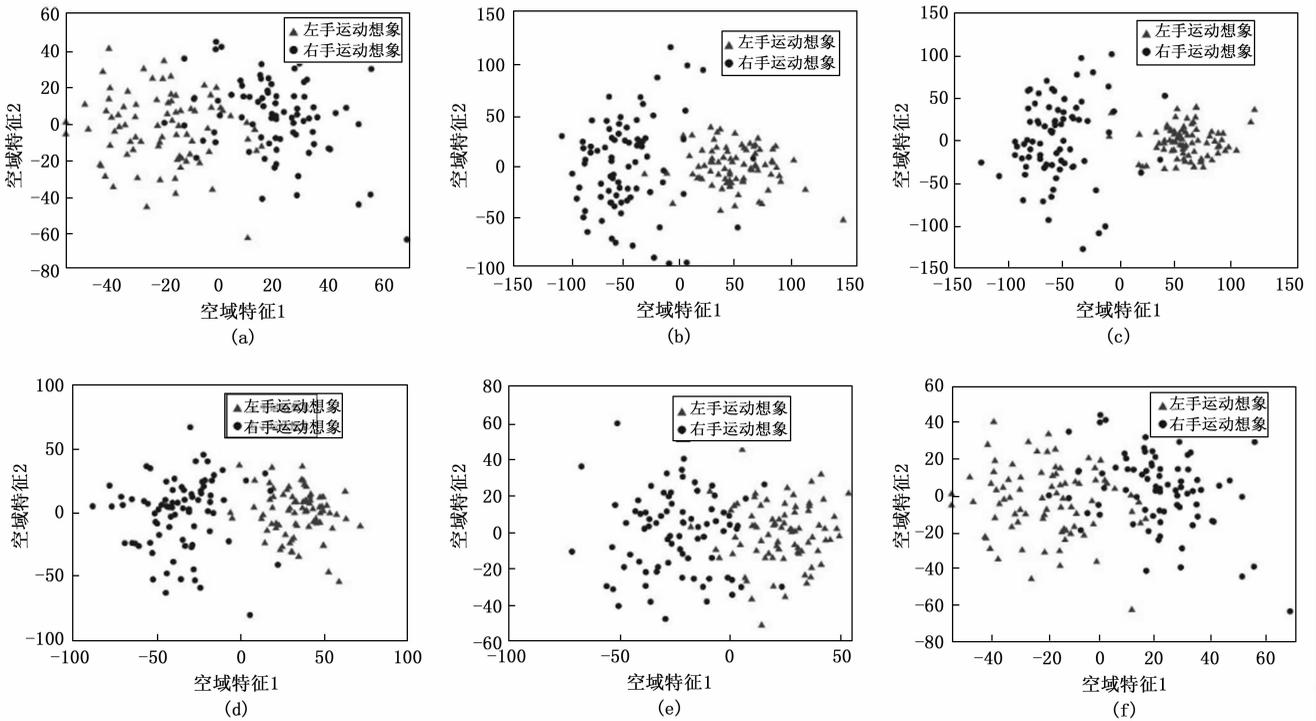


图 4 受试者 5 各时窗特征模式分布

态时, 产生的运动想象脑电包含更多的有效信息, 所提取的左右手空间特征具有更高的区分度。而大脑在度过了运动想象最剧烈的时间段后会逐渐放松, 此时产生的运动想象脑电所含有有效信息减少, 所提取的左右手空间特征区分度也会降低。

在训练 HMM 模型时, 状态数量会直接影响识别结果。状态数量过大, 训练代价也会越大, 而状态数量过小, 则会导致识别精度不足。通过预试验, HMM 模型状态数量定为 3, 初始状态转移概率矩阵 A 使用随机函数进行初始化, 得到 3×3 的状态矩阵。将已提取的左右手运动想象 CSP 特征构成特征序列, 使用 Baum-Welch 算法进行训练, 通过迭代计算, 求解模型参数。当模型训练完毕, 再将待识别的运动想象脑电信号特征序列分别输入左手模型和右手模型中, 计算出两个模型的概率值。作为参照, 本文还将未经 CSP 处理的脑电信号直接输入 HMM 进行训练与识别。

图 5 分别为使用不同方法时受试者 4 和受试者 8 的多时窗分类正确率。根据图 5 (a) 和 (b) 可以看到, 脑电的分类正确率在最初的两个时窗 tw_1 、 tw_2 逐渐升高, 在中间两时窗 tw_3 、 tw_4 会达到一个峰值, 之后在 tw_5 、 tw_6 时窗慢慢下降。受试者 4 的

分类正确率在 tw_4 上甚至能达到 98.75%。这对应于受试者进行一次运动想象任务时的脑电状态变化, 即从一开始的平静状态转换为运动想象状态, 最后又逐渐恢复平静状态。HMM 方法和本文方法的识别结果均能够观察到该现象。同时本文方法的平均分类正确率也比 HMM 方法要高, 验证了本文所提脑电识别方法的有效性。受试者 4 脑电分类正确率的变化情况说明了相比其他时窗, 针对时窗 tw_3 、 tw_4 提取的空域特征序列对原始脑电具有更强的表征能力, 在这段时间受试者大脑正处于运动想象状态, 脑活动加剧, 所提取的空域特征具有更高的区分度。

因此, 使用不同方法对 tw_3 和 tw_4 时窗特征序列进行模型训练与分类识别, 其平均分类结果如表 2 所示。

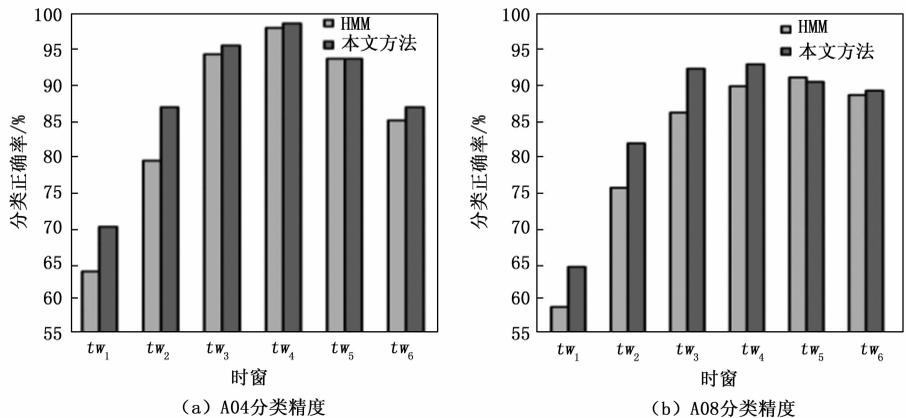


图 5 不同方法多时窗分类结果对比

表 2 不同方法分类性能比较 %

受试者	HMM	本文方法
A01	56.57	63.13
A02	55.94	57.92
A03	60.94	66.88
A04	96.25	97.19
A05	85.94	97.51
A06	62.82	64.69
A07	66.88	80.32
A08	88.13	92.82
A09	69.38	74.07
平均	71.43	77.17

从表 2 可以看出, 对于左右手运动想象脑电信号, 直接使用 HMM 训练模型得到的分类准确率相比使用多时窗 CSP 特征训练 HMM 得到的分类准确率更低。由于个体的生理状况各不相同, 使用同一种方法进行实验时, 不同受试者得到的分类正确率存在显著差异, 其中使用本文方法时, 最优受试者的分类正确率比表现最差的受试者高出了接近 40%。受试者 5 使用本文方法所得分类正确率达到了 97.51%, 相比使用 HMM 方法提高了 11.57%。即使是分类效果较差的受试者 1 和 2, 使用本文方法所得分类正确率也比使用 HMM 方法分别提高了 6.56% 和 1.98%。总体而言, 使用 HMM 方法得到的平均分类正确率为 71.43%, 而使用本文方法得到的平均分类正确率为 77.17%, 提高了 5.74%。

图 6 给出了每一位受试者分类效果最好的时窗的分类正确率柱状图, 图中折线代表不同方法在所有时窗取得的平均分类正确率。如图所示, 除了受试者 9 用 HMM 方法获得的分类正确率高于本文方法, 对于其他受试者来说本文所提方法获得的分类效果更好。即使使用同一种算法对于不同的受试者而言, 其分类准确率也有较大差异。运动想象任务的识别性能不仅取决于受试者进行想象任务时心理活动的质量, 也与特征提取方法密切相关。从平均正确率来看, 本文所提方法相比 HMM 方法有明显提升。此外, 对于运动想象心理活动质量较差的受试者 (如受试者 1、受

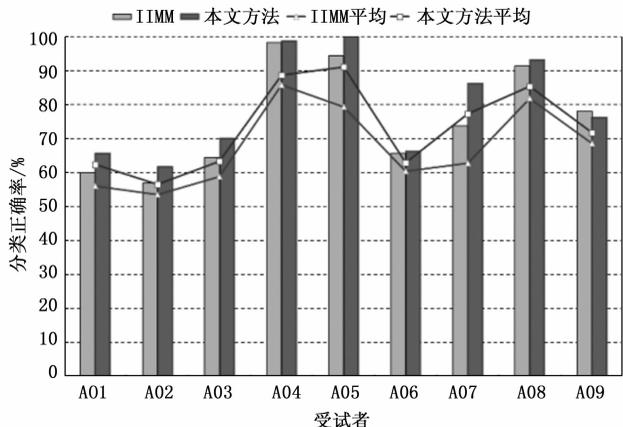


图 6 不同方法最佳时窗分类结果对比

试者 2), 本文所提方法在左右手想象任务识别中的准确率相较 HMM 法皆有所提高。

4 结束语

运动想象脑电是一种非线性、非平稳复杂时序信号, 如何有效地对运动想象脑电进行建模和模式判别已成为当前的研究热点。本文针对运动想象脑电信号的解码问题, 提出一种基于多时窗分析的运动想象脑电识别方法。通过共空间模式提取多时窗运动想象脑电的空间特征, 减少了通道间的信息冗余。使用多个短时窗脑电特征分别训练隐马尔可夫模型, 解决了长段脑电信号在训练隐马尔可夫模型时存在的复杂信息表征度不足的问题, 得到了能够有效识别运动想象脑电的隐马尔可夫模型, 其分类正确率相比单独使用 HMM 方法提高了 5.74%, 验证了本文方法的有效性。

参考文献:

- [1] VIDAL J J. Toward direct brain-computer communication [J]. Annu. Rev. Biophys., 1973, 2: 157 - 180.
- [2] CLERC M. Brain computer interfaces, principles and practise [J]. Biomed. Eng. Online, 2013, 22 (12): 424.
- [3] SCHLOGL A, LEE F, BISCHOF H, et al. Characterization of four-class motor imagery EEG data for the BCI-competition 2005 [J]. J. Neural. Eng., 2005, 2 (4): 14 - 22.
- [4] RONG Y Y, WU X J, ZHANG Y M. Classification of motor imagery electroencephalography signals using continuous small convolutional neural network [J]. Int. J. Imaging Syst. Technol., 2020, 30 (3): 653 - 659.
- [5] 田贵鑫, 陈俊杰, 丁鹏, 等. 脑机接口中运动想象的执行与能力的评估和提高方法 [J]. 生物医学工程学杂志, 2021, 38 (3): 434 - 446.
- [6] PFURTSCHELLER G, NEUPER C, RAMOSER H, et al. Visually guided motor imagery activates sensorimotor areas in humans [J]. Neurosci. Lett., 1999, 269: 153 - 156.
- [7] PFURTSCHELLER G, NEUPER C, SCHLOGL A, et al. Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters [J]. IEEE Trans. Rehabil. Eng., 1998, 6 (3): 316 - 325.
- [8] AGGARWAL S, CHUGH N. Signal processing techniques for motor imagery brain computer interface: A review [J]. Array, 2019: 100003.
- [9] AMIN H U, MALIK A S, AHMAD R F, et al. Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques [J]. Australas. Phys. Eng. Sci. Med., 2015, 38 (1): 139 - 149.
- [10] FENG J, YIN E, JIN J, et al. Towards correlation-based time window selection method for motor imagery BCIs [J]. Neural Networks, 2018, 102: 87 - 95.
- [11] 贾子钰, 林友芳, 刘天航, 等. 基于多尺度特征提取与挤压激励模型的运动想象分类方法 [J]. 计算机研究与发展, 2020, 57 (12): 2481 - 2489.
- [12] 余青山, 陈希豪, 席旭刚. 基于 DTCWT 和 CSP 的脑电信号特

征提取 [J]. 大连理工大学学报, 2016, 56 (1): 70 - 76.

[13] 孟 明, 尹 旭, 高云园, 等. 运动想象脑电的块选择共空间模式特征提取 [J]. 控制理论与应用, 2021, 38 (3): 301 - 308.

[14] YAMAWAKI N, WILKE C, LIU Z, et al. An enhanced time-frequency-spatial approach for motor imagery classification [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2006, 14 (2): 250 - 254.

[15] ZHANGS Q, CAOC Y, ANDREW Q, et al. Dynamic analysis on simultaneous iEEG-MEG data via hidden Markov model [J]. NeuroImage, 2021: 117923.

[16] 蔡 怡. 频率同步特征与 SVM/HMM 混合模型在脑-机接口中的应用研究 [D]. 重庆: 重庆大学, 2015.

[17] TANGERMANN M, MULLER K, AERTSEN A, et al. Review of the BCI competition IV [J]. Front Neurosci., 2012 (6): 55.

之外, 还提出了簇生成和簇分裂机制, 簇生成是在网络中簇规模过小并且两个簇的通信半径相互覆盖时对它们进行合并, 避免网络资源的浪费。当网络中簇的规模过大时, 就会执行簇分裂操作, 将规模过大的簇分裂成若干个规模正常的小簇, 簇内成员通过生成一个随机数来随机加入簇, 保证车辆节点在簇分裂时加入到每个簇的概率是一样的。仿真结果分析表明, 论文提出的算法相比于经典的 MOBIC 分簇算法, 可以更好地提升簇结构的稳定性、降低网络通信开销、提升网络性能。

根据得到的仿真数据, 孤立节点数量的值未达到预期目标, 簇维护算法仍有待优化, 如当节点在要脱离簇前提前预选一个簇头, 待它脱离后就加入该簇。而且, 由于节点的通信半径是有限制的, 因此车联网中网络不会处处被簇所覆盖, 当车辆节点一直处于两个簇通信半径外时, 它将一直以孤立节点的身份存活于网络中直至离去, 如何减少这种孤立节点的数量也是研究的下一步目标。

参考文献:

[1] 刘小洋, 伍民友. 车联网: 物联网在城市交通网络中的应用 [J]. 计算机应用, 2012, 32 (4): 900 - 904.

[2] YAN X, ZHANG H, WU C. Research and development of intelligent transportation systems [C] // 2012 11th International Symposium on Distributed Computing and Applications to Business, Engineering & Science (DCABES), IEEE, 2012: 363 - 372.

[3] 赵 明, 王英姿. 车联网下大数据安全采集机制研究 [J]. 计算机测量与控制, 2020, 28 (10): 200 - 204.

[4] 吴黎兵, 范 静. 一种车联网环境下的城市车辆协同选路方法 [J]. 计算机学报, 2017, 40 (7): 1600 - 1613.

[5] 林 峰, 丁鹏举. 车联网中协作数据分发方案研究 [J]. 计算机工程, 2021, 47 (8): 29 - 36.

[6] 戴泽华, 张连连. 基于车联网的公路收费无感支付方法 [J]. 计算机仿真, 2023, 40 (7): 105 - 108.

[7] LIN C R, GERLA M. Adaptive clustering for mobile wireless networks [J]. IEEE Journal on Selected Areas in Communica-

of the BCI competition IV [J]. Front Neurosci., 2012 (6): 55.

[18] CRISTIAN F B, JAVIER M, ANTELIS B, et al. Comparative analysis of spectral and temporal combinations in CSP-based methods for decoding hand motor imagery tasks [J]. J. Neurosci. Meth., 2022 (371): 109495.

[19] HUANG Y T, JING J, REN X, et al. Multi-view optimization of time-frequency common spatial patterns for brain-computer interfaces [J]. Journal of Neuroscience Methods, 2022, 365: 109378.

[20] 孙即祥. 现代模式识别 [M]. 北京: 高等教育出版社, 2008.

[21] COHEN A. Hidden Markov models in biomedical signal processing [C] // Proc. 20th International Conference EMBS/IEEE, Hongkong, 1998: 1145 - 1150.

tions, 1997, 15 (7): 1265 - 1275.

[8] 孙雨耕, 王瑞丰. 自组网络的分簇算法 [J], 天津大学学报, 2005, 38 (8): 711 - 716.

[9] CHITI F, FANTACCI R, GU Y, et al. Content sharing in internet of vehicles: two matching-based user-association approaches [J]. Vehicular Communications, 2017, 8 (4): 35 - 44.

[10] 薛 拯, 刘 洋. 车联网下基于模糊逻辑的簇头选择与数据传输策略研究 [J]. 小型微型计算机系统, 2020, 41 (7): 1458 - 1463.

[11] 张海波, 刘子琪. 活跃度感知的社交车辆分簇算法 [J]. 浙江大学学报 (工学版), 2022, 56 (5): 1044 - 1054.

[12] BASU P, KHAN N, LITTLE T D C. A mobility based metric for clustering in mobile ad hoc networks [C] // International Conference on Distributed Computing Systems. IEEE Computer Society, 2001: 413 - 423.

[13] CAI M, RUI L, LIU D, et al. Group mobility based clustering algorithm for mobile ad hoc networks [C] // Network Operations & Management Symposium. IEEE, 2015: 181 - 193.

[14] HALIM I T A, FAHMY H M A. Mobility prediction-based efficient clustering scheme for connected and automated vehicles in VANETS [J]. Computer Networks, 2019 (150): 217 - 233.

[15] MASLEKAR N, BOUSSEDJRA M, MOUZNA J, et al. C-DRIVE: Clustering based on direction in vehicular environment [C] // Intelligent Vehicles Symposium. IEEE, 2011: 1 - 5.

[16] SOOD M, KANWAR S. Clustering in MANET and VANET: a survey [C] // 2014 International Conference on Circuits, Systems, Communication and Information Technology Applications (CSCITA). IEEE, 2014: 375 - 380.

[17] 刘越甲. 车联网路口场景下分簇算法的研究 [D]. 北京: 北京交通大学, 2016.

[18] 夏玮玮. 荒漠场景应用的车联网及其分簇路由算法 [J]. 通信学报, 2012 (10): 166 - 174.

[19] 朱晓姝. OMNET++ 仿真工具的研究与应用 [J]. 大连工业大学学报, 2010, 29 (1): 62 - 65.

[20] 高 宏, 刘开华, 潘 勇. 基于 OMNET++ 的 leach 协议的仿真与改进 [J]. 电子设计工程, 2012, 20 (19): 63 - 65.