

· 生物电子学 ·

脑-机接口中新的脑电数据分类方法

唐 艳, 柳建新, 龚安栋

(中南大学信息物理学院 长沙 410083)

【摘要】根据自发脑电的特点,将HMM-AR模型算法运用到脑电状态的分类中,证明它是一种非常有用的分析脑-机接口方法。将Laplacian filter、ICA和HMM-AR方法相结合,用想象左右手运动的BCI数据进行识别,得到了很好的分类结果,有效地区分脑电中运动与非运动两种状态。该算法能够在运动开始后1 s内检验到脑电信号的变化,从而证明了该算法在BCI的实用性,达到了良好的识别效果。

关键词 脑-机接口; 脑电信号; 隐马尔科夫-自回归算法; 独立成分分量

中图分类号 R18

文献标识码 A

doi:10.3969/j.issn.1001-0548.2009.06.030

New Method of Classifying EEG Signals in Brain-Computer Interfaces

TANG Yan, LIU Jian-xin, and GONG An-dong

(Department of Info-Physics Engineering, Central South University Changsha 410083)

Abstract Distinguishing the states of “movement” or “rest” in electroencephalogram (EEG) plays an important role in the domain of brain computer interface (BCI). According to the electroencephalogram feature, Hidden Markov model (HMM)-AR might be a useful tool in EEG pattern classification. The method which jointly employs Laplacian filter, ICA transform, and HMM-AR is presented for EEG pattern classification. The hybrid method is confirmed through the classification of EEG that is recorded during the imagination of a left or right hand movement. The results illustrate the algorithm can availably classify the two brain states of movement and rest. The algorithm for cue movement determination has been designed resulting in detecting the movements within one second interval. it prove the algorithm feasibility in BCI data sets.

Key words brain-computer interface; electroencephalogram; hidden Markov AR models; independent component analysis

目前,脑-机接口成为研究的热点问题,大多数研究集中在从EEG中区分几种命令^[1-2]。事实上,使用者通常只在少数情况下需要发送命令,大部分时间系统都应处于“空闲”状态,因此,脑-机接口应用于实践的首要任务是解决系统连续运行问题。在执行BCI任务时,如何检验到信号的变化、确定任务识别开始是完善BCI系统的关键^[3]。当测试者开始想象运动时,其相应的脑电频率会发生变化,并且这种变化会维持一段时间。因此在脑电发展过程中,信号具有若干平稳片段的非平稳性质。文献[4]使用时频分析方法来分析该问题。

本文主要考虑把Kalman滤波和AR系数引入到HMM建模中,从而得到一种新颖的模拟非平稳动态时间序列HMM-AR模型。该模型能够自动把时间序列分割为离散动态区域,从而进一步研究脑电信号

在时间上的分割,实现识别思维脑电的开始,为BCI实践提供指导意义。

1 HMM-AR模型

文献[5-6]提出了HMM-AR模型,该算法的中心思想是隐状态由Markovian动态模型产生,观察值由Kalman-AR模型产生。

1.1 HMM-AR模型的状态空间表示

HMM-AR模型是假定每个隐状态产生的观测变量都来源于AR模型。具有 n 个离散隐状态 $[s_1, s_2, \dots, s_n]$ 的HMM-AR模型可以用状态空间方法表示为^[7]:

$$P(q_t = S_j | q_{t-1} = S_i) = r_{ij} \quad (1)$$

$$P(y_t | q_t = S_i) = N(y_t - F_i \hat{a}_i, \sigma_i^2) \quad (2)$$

式中 q_t 为 t 时刻的状态; r_{ij} 为存储在状态转移概率

收稿日期: 2008-04-16; 修回日期: 2009-01-13

基金项目: 湖南省自然科学基金(07JJ6045)

作者简介: 唐 艳(1975-),女,博士,副教授,主要从事生物信号方面的研究。

矩阵 \mathbf{A} 中的状态转移概率; $\hat{\mathbf{a}}_i$ 为第 i 个状态的AR系数列向量; $\mathbf{F}_i = -[y_{t-1}, y_{t-2}, \dots, y_{t-p}]$; σ_i^2 为第 i 个状态估计的观测噪声; $\hat{\mathbf{y}}_t^i = \mathbf{F}_i \hat{\mathbf{a}}_i$ 为第 i 个状态观测变量的预测值。

HMM中的初始状态概率分布为:

$$P(q_t = S_j) = \pi_j \quad (3)$$

式中 π_j 为矢量 $\boldsymbol{\pi}$ 的第 j 个元素。

为了描述HMM-AR的学习算法, 定义符号 \mathbf{B} 表示观测模型参数, 整个HMM用 $\lambda = \{\boldsymbol{\pi}, \mathbf{A}, \mathbf{B}\}$ 表示。为了训练HMM, 必须计算在给定 t 时刻观测变量序列的情况下状态 S_i 出现的概率, 即:

$$P(q_t = S_i | \mathbf{y}_1^T) = \gamma_t(i) \quad (4)$$

式中 \mathbf{y}_1^T 为 t 时刻长度为 T 的观测序列。给定一个特定的观测序列, 则计算状态 S_i 过渡到状态 S_j 的概率如下:

$$P(q_t = S_i, q_{t-1} = S_j | \mathbf{y}_1^T) = \zeta_t(i, j) \quad (5)$$

式中 $\gamma_t(i)$ 和 $\zeta_t(i, j)$ 可利用前向和后向算法得到。

1.2 在线参数估计的EM算法

根据EM算法可以导出HMM-AR模型一般的参数估计方法, EM算法通过辅助函数最大化的方法进行最大似然学习。HMM-AR模型的EM辅助函数为:

$$Q = \sum_i \sum_t \gamma_t(i) \lg P_{\lambda}(y_t | q_t) \quad (6)$$

式中 $P_{\lambda}(y_t | q_t)$ 为在当前模型下, 给定状态 q_t 时观测到 y_t 的概率。对于AR模型, 给定HMM模型的状态 q_t 、观测到时间序列 \mathbf{y}_t 的概率为:

$$P_{\lambda}(y_t | q_t) = \frac{1}{\hat{\sigma}_t \sqrt{2\pi}} \exp \left[-\frac{(y_t - \hat{\mathbf{y}}_t^q)^2}{2\hat{\sigma}_t^2} \right] \quad (7)$$

将 $\hat{\mathbf{y}}_t^i = \mathbf{F}_i \hat{\mathbf{a}}_i$ 代入到式(6)中可得:

$$Q = \sum_i \sum_t \gamma_t(i) [-\frac{(y_t - \hat{\mathbf{y}}_t^i)^2}{2\hat{\sigma}_t^2} - \lg \hat{\sigma}_t] \quad (8)$$

对于每一个状态的AR系数都可以通过使下式最小化得到:

$$E_i = \sum_t \gamma_t(i) (y_t - y_t^i)^2 \quad (9)$$

这是一个典型的加权平方和问题, 每一个权值 $\gamma_t(i)$ 是 t 时刻HMM处于状态 i 时的概率。定义 $\mathbf{C}_i = \text{diag}(\sqrt{\gamma_1(i)}, \sqrt{\gamma_2(i)}, \dots, \sqrt{\gamma_T(i)})$; \mathbf{Y}_i 为一个列向量, 它的第 t 个元素是 y_t ; \mathbf{X}_i 是一个矩阵, 它的第 t 行是 $[-y_{t-p}, \dots, -y_1]$; 并定义 $\hat{\mathbf{X}}_i = \mathbf{C}_i \mathbf{X}_i$, $\hat{\mathbf{Y}}_i = \mathbf{C}_i \mathbf{Y}_i$, 于是上述问题就转换为一个标准的最小平方和问题, 即:

$$\hat{\mathbf{a}}_i = (\hat{\mathbf{X}}_i^T \hat{\mathbf{X}}_i)^{-1} \hat{\mathbf{X}}_i^T \hat{\mathbf{Y}}_i \quad (10)$$

可以使用奇异值分解技术将其计算出来。对于每一个状态的噪声方差为:

$$\hat{\sigma}_i^2 = \frac{\sum_t \gamma_t(i) (y_t - \hat{\mathbf{y}}_t^i)^2}{\sum_t \gamma_t(i)} \quad (11)$$

概括而言, HMM模型的训练通过运行前向-后向算法得到 $\gamma_t(i)$ 和 $\zeta_t(i, j)$ 的值, 然后初始状态概率和状态转移概率矩阵通过EM算法进行调整。AR模型使用式(10)和式(11)进行更新, 构成了EM算法的一次迭代过程。每一次迭代过程都要求通过前向-后向算法和求解加权平方和问题来实现。一般地, 特定的HMM-AR模型要经过数十步就能完成。

1.3 HMM-AR模型状态监测方法

利用HMM-AR模型对脑电信号思维过程进行状态监测和识别的步骤如下: (1) 初始值设置。设置隐含状态数; 根据特定问题的平均状态驻留密度初始化状态转移概率矩阵, 即假设 av_dur 是平均状态稳定时间密度, ns 是采样率, 希望HMM保持在状态 i 为 av_dur s, 则相应的状态转移矩阵的对角线值被设置为 $\gamma_{ii} = 1 - \frac{1}{(av_dur) \times f_s}$ 。如EEG数据可以认为在

半秒周期内是固定的, 对于采样率为125 Hz的数据, 其对角线的值设为0.984, 非对角值为 $1-0.984=0.016$ 。用平稳AR模型估计Kalman-AR模型中的观测噪声; 平滑系数设置为0.01。(2) 用Kalman-AR方法对系统状态进行自适应跟踪, 获得动态AR模型的AR系数, 其中状态噪声协方差矩阵用Jazwinski算法进行更新, 光滑参数 α 默认值设置为0.01。(3) 用AR向量初始化高斯混合模型(GMM), 得到每个状态的中心AR参数矢量。GMM的参数初始化采用聚类选择法中 k -均值算法。(4) 设置HMM迭代条件, 开始迭代算法。(5) 根据每一个状态的AR系数和式(7)构建观测值概率矩阵, 进行HMM训练。(6) 对AR参数进行调整, 根据式(9)~式(11)重新训练直到满足迭代条件。(7) 用Viterbi算法找到最优状态。

2 EEG手部运动数据区分

2.1 运动相关脑电信号的一般特性

运用HMM-AR方法可从时间上识别运动相关与非运动脑电信号。实验基于以下脑电知识^[8-9]:

(1) μ -节律事件相关去同化(μ ERD)。开始于运动执行前1 s, 主要集中在C3(或CP3)和C4(或CP4)头皮区域, 呈对侧优势, 通常能够在感觉运动皮层区看到两个中心区域。 μ ERD能够用来区分身体哪一侧执行运

动。去同化现象仅仅是想象运动的开始,在大多数成年人中都能够观测到这一现象。(2) β -节律事件相关去同化(β ERD)。通常发生在头皮中心区域,比 β ERS具有更大的扩散特性,比 β ERS分布的更加广泛, β ERD的强度至少是 μ ERD的两倍。(3) β -节律事件相关同化(β ERS)。该现象出现在 β 节律中心,表现为运动后出现一个相位同步反弹。 β ERS出现大约在运动开始后1 s,也具有对侧优势。

2.2 EEG手部运动数据测试

对EEG数据记录,运用HMM-AR模型区分运动和休闲两种状态。测试者根据提示进行左右手部想象运动。目标提示之间是随机长度为1.75~2.25 s的时间段,这段时间测试者处于休闲状态。采用BrainAmp放大器进行数据采集,共记录了64个电极的信号,信号经过带宽为0.05~200 Hz的滤波,采样率为100 Hz。因为左右手部运动,ERD和ERS现象最明显的是C3和C4两导数据,所以在实验中仅关注这两个电极的电位信息。实验中进行了70 s,取0~30 s数据进行分析,其C3和C4两导信号在0~30 s中的原始数据如图1和图2所示。




图1 C3导联原始脑电数据




图2 C4导联原始脑电数据

分类实验的步骤如下:

(1) 先对数据进行滤波,仅仅考虑频率为12~14 Hz的数据,采用巴特沃思零相位滤波器;并采用Laplacian变换提高BCI系统性能,计算出电极读数之间的差异。考虑到 μ 节律范围是8~12 Hz, β 节律范围是13~30 Hz。对于不同的个体,其具体结果可能不同,但是其 μ 节律与 β 节律肯定会不同。因此,选取核心频率位于12~14 Hz的范围,正好位于 μ 节律与 β 节律的过度带,希望在该范围内能够体现处两种节律的区别。

(2) 对C3和C4两导数据进行独立成分的分量分析^[10-13],希望能够得到有意义的信号源。将得到的第一个独立源作为判断信号源,如图3所示。独立成份分量的作用主要是分离出不同信号源产生的信息,使信号独立。对C3和C4两导进行独立成分分量分析的目的就是希望分别得到C3、C4两区域独立信号源产生数据。分离得到两个独立数据源都可以作为下一步判断的数据,试验结果证明效果相同。本文选用第一个独立源作为判断信号源,仅仅考虑左、右手部的运动。如果考虑到其他部位的运动,如何选取独立数据源将是进一步需要思考的问题。




图3 ICA分离后第一个分量数据

(3) 在实验中,隐含状态数设置为2;EEG数据可以认为在半秒周期内是固定的,对于采样率为100 Hz的数据,其对角线的值设为0.98,非对角值为 $1-0.98=0.020$,即:

$$P = \begin{pmatrix} 0.98 & 0.02 \\ 0.02 & 0.98 \end{pmatrix}$$

(4) 对时间序列进行平稳AR模型估计,得到估计观测噪音为0.5,平滑系数设置为0.01。

(5) 用Kalman-AR方法获得动态AR模型的AR系数。运用HMM-AR初始参数进行在线EM算法估计,式(7)得到观测到时间序列 y_t 的概率定义,然后用向前-向后和Baum-Welch算法进行计算。HMM-AR模型结果是状态转移矩阵变为:

$$P = \begin{pmatrix} 0.9878 & 0.0122 \\ 0.0118 & 0.9882 \end{pmatrix}$$

8次EM迭代内收敛。

(6) 在估计状态序列时应用Viterbi解码算法, 沿着运动时间提示结果如图4所示。假设 $N=2$ 状态, 相应与存在、缺少运动, 图中上线表示HMM-AR算法结果, 沿时间运动和休息的不同时刻值; 下线表示实际试验中提示运动的值, 可以看到HMM-AR模型正确区分了手动和非手动区域。HMM分类器提供一个有意义的数据分段, 它发现提示运动在1 s以内的精确性。




图4 HMM-AR算法结果和实际试验对比情况




图5 HMM-AR识别后两种状态分别对应的频谱

图5所示HMM-AR模型的两种状态分别对应的频谱图。与运动相关的一个现象“ERD”和“ERS”主要牵涉到3个现象： μ 节律事件相关去同步(发生在运动开始前1 s)、 β 节律事件相关去同化和 β 节律事件相关同化。 μ 节律范围是8~12 Hz, β 节律范围是13~

30 Hz。实验中取频率范围12~14 Hz, 分离出两种状态, 第一种状态的频率集中在14 Hz, 对应于 β 节律, Viterbi解码中取值1; 第二种状态的频率集中在12 Hz, 对应于 μ 节律, Viterbi解码中取值2。从图4可以看到HMM-AR方法很好地将两种不同频率的状态分离出来, 显示了运动开始和休息状态的区别。

3 讨论

HMM模型中初始化是一个很关键的问题。在HMM-AR模型中, AR系数通过Kalman滤波器AR系数的Gaussian混合聚集初始化, 这种非监督初始化方法对找到最优结果很关键。另外, HMM状态转移矩阵通过定义周期来初始化, 该周期为平稳阶段时间序列的长度, 提供了从问题领域结合先验知识到统计模型中的方法。脑电大量信息被淹没在噪音中, 运用HMM-AR模型进行脑电状态识别的关键在于特征的提取。(1) 通道的确定。选取最能够反映信号变化的通道是提高识别率的关键, 身体不同部位的活动, 反映在不同的通道上。实验中仅仅对左、右手是否运动进行识别, 由身体运动部位与感觉运动皮层对应关系可以得到左手运动定位于右半球感觉运动皮层, 右手运动定位于左半球感觉运动皮层, 反映在头部电极, 信号最强的部位是C3/C4, 所以直接采用C3/C4通道进行区分。如果是对于其他任务的判断, 可以采用 r^2 判据作为选取通道的依据^[14], 实验中采用 r^2 判据同样得到C3/C4是信号最强的部位。(2) 频率滤波。脑电信号的频带范围比较广, 而且信号之间相互干扰, 如何有效地识别不同信号, 以确定运动开始是又一个关键问题。为了有效地提取信号特征, 本文根据 μ -节律事件相关去同化(μ ERD)开始于运动执行前1 s这一关键知识, 只考虑12~14 Hz之间的脑电信号, 用HMM-AR方法实现了 μ 节律和 β 节律的区分, 从而实现了运动与非运动的脑电信号区分。最终的分类结果如图4所示, 大多数任务分类是在任务开始一段时间以后才分类为任务期, 可以认为这是由于 β ERS的原因, β 信号加强, 而它正好出现大约在运动开始后1 s。同样, 当任务结束一段时间以后, 任务分类认为是任务的结束, 这可以解释为分类延时。但在9~15 s的任务分类中, 开始与结束都是超前, 这个异常现象引起的原因可能是因为测试者过于紧张, 提前认为任务发生而造成的。(3) 为了提高数据的可识别性, 实验中对数据同时采用了Laplacian滤波和ICA变换, 使得数据分析的正确率大大提高, 特别是Laplacian滤波可以大大增强信

号。头部脑电信号记录是不同脑电区域活动的空间叠加，表面Laplacian滤波算法可以加强局部地区脑电，减低脑电信号的漫射作用。仅仅用HMM-AR模型不能很好地判断任务的开始，其结果如图6所示。可以看到未预处理的信号，由于信号源传输的延时，使得信号相互干扰，出现多处错误判断。




图6 仅用HMM-AR模型识别任务的结果比较

同样，本文对另一位测试者进行了相同的实验，同样得到了较为满意的效果。

4 结束语

本文介绍了自动实现脑-机接口的EEG分析的方法。应用隐马尔科夫方法来分析EEG，对数据进行自然选择，其特征提取和HMM训练在一般PC和Matlab环境下花费仅几秒。系统用时间EEG信息来识别是否想象运动，这种判别与真实脑机接口环境要求更加接近。但是该识别方法仅仅对区分运动与非运动状态有效，不能识别运动本身。

参 考 文 献

[1] TANG Yan, TANG Jin-tian, GONG An-dong. Multi-class EEG classification for brain computer interface based on CSP[C]//International Conference on Biomedical Engineering and Informatics. Hainan: [s.n.], 2008.

[2] GONG An-dong, CAI Zi-xing, TANG Yan. Distinguishing between left and right finger movement from EEG using SVM[C]//1st International Conference on Bioinformatics and Biomedical Engineering. Wuhan: [s.n.], 2007.

[3] 张莉, 何传红, 何炜. 脑-机接口的研究现状与挑战[J]. 现代科学仪器, 2007, 2: 23-26.

ZHANG Li, HE Chuan-hong, He Wei. Statues and challenges in brain-computer interface technologies[J]. Modern Scientific Instruments, 2007, 2: 23-26.

[4] 綦宏志, 程龙龙, 陈滨津. 想象动作中动态脑电的信息熵研究[J]. 中国生物医学工程学报, 2007, 26(1): 74-77.

QI Hong-zhi, CHENG Long-long, CHEN Bin-jin. Study on information entropy of ongoing EEG signals during motor imaginary[J]. Chinese Journal of Biomedical Engineering, 2007, 26(1): 74-77.

[5] FRASER A M, DIMITRIADIS A. Forecasting probability densities by using hidden markov models with mixed states[C]//Time Series Prediction: Forecasting the Future and Understanding the Past. New York: Addison-Wesley, 1994: 265-282.

[6] PENNY W D, STEPHEN J. Roberts dynamic models for nonstationary signal segmentation[J]. Computers and Biomedical Research, 1999, 32(6): 483-502.

[7] 冯长建. HMM动态模式识别理论、方法以及在旋转机械故障诊断中的应用[D]. 杭州: 浙江大学, 2002.

FENG chang-jian. HMM dynamical pattern recognition theories, methods and applications in faults diagnosis of rotating machine[D]. Hangzhou: Zhejiang University, 2002.

[8] STANCAK A, FEIGE B, LÜCKING C H, et al. Oscillatory cortical activity and movement-related potentials in proximal and distal movements[J]. Clinical Neurophysiology, 2000, 111: 636-650.

[9] MCFARLAND D J, MINER L A, VAUGHAN T M, et al. Mu and beta rhythm topographies during motor imagery and actual movements[J]. Brain Topography, 2000, 12(3): 177-186.

[10] JUNG T P, MAKEIG S, WESTERFIELD M, et al. Independent component analysis of single-trial event-related potentials[J]. Human Brain Mapping, 2001, 14(3): 168.

[11] AN Bin, NING Yan, JIANG Zhao-hui. Classifying ECoG/EEG-based motor imagery tasks[C]//Proceedings of the 28th IEEE EMBS Annual International Conference. New York, USA: IEEE, 2006: 6339-6342.

[12] 唐艳, 柳建新, 龚安栋. ICA+CSSD的脑-机接口分类[J]. 电子科技大学学报, 2008, 37(5): 466-469.

TANG Yan, LIU Jian-xin, Gong An-dong. Classifying for brain-computer interfaces using ICA+CSSD[J]. Journal of Electronic Science and Technology of China, 2008, 37(5): 466-469.

[13] CHIAPPA S, BARBER D. Generative independent component analysis for EEG classification[C]//ESANN'2005 Proceedings-European Symposium on Artificial Neural Networks Bruges(Belgium). [S.l.]: [s.n.], 2005.

[14] ERLANGUNG Z. Increasing information transfer rates for brain-computer interfacing[D]. Potsdam: Mathematisch-Naturwissenschaftlichen Fakultät der Universität, 2006.

编辑 黄莘