

基于脑电功率谱-连续隐马尔科夫链的精神疲劳分级模型

赵春临, 郑崇勋, 赵敏

(西安交通大学教育部生物医学信息工程重点实验室, 710049, 西安)

摘要: 提取多通道脑电(EEG)功率谱特征, 训练连续高斯密度混合隐马尔科夫模型(CHMM), 建立了基于功率谱-CHMM的精神疲劳分级模型. 分级结果表明: EEG各节律功率谱及其比值是精神疲劳的敏感指标, CHMM对于不同的精神疲劳状态具有较高的分类精度, 最高分类正确率达到97.5%; 在训练样本相同的情况下, CHMM比反向传输人工神经网络具有更高的分类精度.

关键词: 连续隐马尔科夫模型; 脑电; 功率谱; 精神疲劳

中图分类号: R318.04 **文献标识码:** A **文章编号:** 0253-987X(2007)12-1474-05

Mental Fatigue Staging Model Based on Electroencephalogram Power Spectrum and Continuous Hidden Markov Model

Zhao Chunlin, Zheng Chongxun, Zhao Min

(Key Laboratory of Biomedical Information Engineering of Education Ministry, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Multi-channel electroencephalogram(EEG) power spectrum is extracted for training continuous hidden Markov model (CHMM), and a novel approach to classify the mental fatigue levels is proposed based on power spectrum-CHMM. The result shows that EEG power spectrum and the ratio of different rhythm serve as sensitive indices for mental fatigue, CHMM is effective for classifying mental fatigue levels with the highest classification accuracy of 97.5%. CHMM enables to classify more accurately comparing with back propagation neural network for the same training samples.

Keywords: continuous hidden Markov model; electroencephalogram; power spectrum; mental fatigue

精神疲劳是生活和工作一种普遍的现象,是导致一些操作性事故的最主要原因,因此研究精神疲劳,建立评估与分级模型具有重要意义.精神疲劳有许多不同的测定方法,其中最具有潜力、最可靠并成功应用于大脑状态检测的方法是脑电(EEG)分析^[1].不同疲劳状态下,EEG在这几种节律上有明显的变化^[2].但是,精神疲劳与EEG的关系在各研究中的报道也不尽相同,甚至有相反的结论.这可能与研究方法、实验条件等不同有关,以EEG为特征进行精神疲劳评估分析仍然充满挑战.

目前,许多模式识别的方法都依赖于大样本的学习训练以及构造正确的学习网络模型,这在实际应用中,往往难以达到.基于转移概率的经典隐马尔科夫模型(HMM)是分析非平稳时间序列的强大工具,已被成功用于语音信号识别,故障检测等领域^[3-5].它不需要大量的训练样本就可以找到合理的概率转移矩阵,建立分类模型,达到所需的分类精度.以多通道EEG的功率谱能量及其相关指标作为观察特征,对连续隐马尔科夫模型(CHMM)进行训练,得到各疲劳状态对应的CHMM,从而对精神疲

劳进行分类评估,并且可以选择合适的隐状态数目,在保证分类精度的情况下,减少计算复杂度,取得较好效果.与反向传输(BP)人工神经网络方法进行对比表明,连续隐马尔科夫模型需要的训练样本少,具有较高的分类精度.

1 CHMM 及其学习算法

1.1 HMM 基本原理

HMM 是在语音信号处理中广泛使用的模型,取得了突破性进展^[6].该模型对时变、非平稳时间序列具有较好的分析效果,HMM 可以记为

$$\lambda = (\mathbf{N}, \mathbf{M}, \boldsymbol{\pi}, \mathbf{A}, \mathbf{B}) \quad (1)$$

式中: $\mathbf{N}$ 为隐状态数目; $\mathbf{M}$ 为每个状态对应的可能的观测值数目; $\boldsymbol{\pi}$ 为初始概率分布矢量,记为 $\boldsymbol{\pi} = \{\pi_i\}$, $\pi_i = P\{q_1 = S_i\}$; $\mathbf{A}$ 为状态转移概率矩阵,记为 $\mathbf{A} = \{a_{ij}\}$, $a_{ij} = P\{q_{t+1} = S_j | q_t = S_i\}$; $\mathbf{B}$ 为观察值概率矩阵,记为 $\mathbf{B} = \{b_{jk}\}$, $b_{jk} = P\{v_k | q_t = S_j\}$. 对于连续 HMM, $\mathbf{B}$ 是一组观察值概率函数,记为 $\mathbf{B} = \{b_j(X), j=1, \dots, N\}$. 另外,隐状态集合 $\mathbf{S} = \{S_1, S_2, \dots, S_N\}$, 观察值序列集合 $\mathbf{V} = \{v_1, v_2, \dots, v_M\}$, 选择观察概率服从高斯分布,其观察值概率密度函数为

$$b_j(X) = \sum_{k=1}^2 c_{jk} N(X, \mu_{jk}, \Sigma_{jk}), 1 \leq j \leq N, \text{ 其中 } \sum_{k=1}^2 c_{jk} = 1.$$

给定一个模型 λ , 观察值序列 $\mathbf{O} = \{O_1, O_2, \dots, O_T\}$, 其中 $O_t \in \{v_1, v_2, \dots, v_M\}$, 是 t 时刻对应的观察值. $\mathbf{O}$ 在 λ 条件下发生的概率为

$$P(\mathbf{O} | \lambda) = \sum_{\mathbf{S}} P(\mathbf{O} | \mathbf{S}, \lambda) P(\mathbf{S} | \lambda) = \sum_{r=1}^{r_{\max}} \pi_{q1} b_{q1}(O_1) a_{q1q2} b_{q2}(O_2) \cdots a_{q(T-1)qT} b_{qT}(O_T)$$

式中: r 表示长度为 T 的隐状态, $r_{\max} = N^T$.

1.2 Baum-Welch 算法

转移矩阵 $\mathbf{A}$ 和 $\mathbf{B}$ 都能够从训练样本序列中,通过 Baum-Welch 算法递归的学习得到,其实质是一种广义期望最大化算法,其估算公式如下

$$\begin{aligned} \bar{\pi}_i &= \alpha_i(1) \beta_i(1) / P(\mathbf{O} | \lambda) \quad 1 \leq i \leq N \quad (2) \\ \bar{a}_{ij} &= \frac{\sum_{t=1}^T \alpha_i(t) \beta_j(t) / P(\mathbf{O} | \lambda)}{\sum_{t=1}^T \sum_{k=1}^N \alpha_i(t) \beta_k(t) / P(\mathbf{O} | \lambda)} \quad 1 \leq i, j \leq N \end{aligned} \quad (3)$$

$$\bar{b}_{jk} = \frac{\sum_{t=1}^T \sum_{l=1}^N \alpha_l(t) \beta_j(t) / P(\mathbf{O} | \lambda)}{\sum_{t=1}^T \sum_{l=1}^N \alpha_l(t) \beta_j(t) / P(\mathbf{O} | \lambda)} \quad 1 \leq j \leq N, 1 \leq k \leq M \quad (4)$$

式中: $\alpha_i(t) = \sum_j \alpha_i(t-1) a_{ij} b_{jk}$, 称为前向变量; $\beta_j(t) = \sum_j \beta_j(t+1) a_{ij} b_{jk}$ 称为后向变量. 根据式(2)~式(4), $\bar{a}_{ij}$ 和 $\bar{b}_{jk}$ 可以从一个给定的初始值开始逐步调整,直到收敛.

2 多通道 EEG 特征提取

2.1 实验数据

实验数据取自 2 位受试者,被试者均为男性,在校大学生,右利手.采用 10-20 导联电极,各导联阻抗均小于 5 k Ω ,参考电极粘贴在喉结右下方的锁骨管处.实验是在安静的环境下进行的,室温大约为 20 $^{\circ}\text{C}$.脑电数据记录仪选用 PL-EEG Wavepoint 系统,采样频率为 166 Hz.两位受试者分别进行了 4 状态和 3 状态的疲劳实验.实验具体细节描述如下.

2.1.1 3 状态疲劳实验 本实验是由受试者 1 在闭眼状态下完成的,各种实验状态均持续大约 5 min.

状态 1-1:受试者自我感觉非常清醒,在室内正常照明灯光下进行的,数据采集持续时间为下午 3:50~3:55.

状态 1-2:受试者自我感觉比较清醒,在室内正常照明灯光下进行的,数据采集持续时间为下午 5:15~5:20.

状态 1-3:受试者显得有些疲劳,并偶尔打哈欠,实验时关闭室内照明灯光,数据采集持续时间为下午 6:52~6:57.

2.1.2 4 状态疲劳实验 本实验是由 2 受试者在室内灯光关闭、受试者闭眼状态下进行的,各种实验状态均持续大约 5 min.

状态 2-1:受试者非常清醒,数据采集持续时间为上午 11:58~12:03.

状态 2-2:受试者午饭后有一些疲倦,数据采集持续时间为下午 2:37~2:42.

状态 2-3:受试者经过一下午的阅读,感到有一些疲劳,并偶尔打哈欠,数据采集实验持续时间为下午 4:38~4:44.

状态 2-4:受试者感到非常疲劳,不时打哈欠,数据采集持续时间为下午 5:36~5:41.

疲劳程度主要根据受试者自述,并结合面部表情等有关行为学特征进行划分。

2.2 多通道 EEG 功率谱特征提取

采集的 EEG 信号经过 50 阶带通 FIR 滤波,带宽为 0.5~30 Hz,去除工频干扰和低频干扰,采用 ICA 去除眼电干扰。

经过预处理后的 EEG 数据采用如图 1 所示的方法,对每一通道的 EEG 数据加滑动时间窗,每窗包含 5 s(830 点)EEG 数据,加下式

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{L-1}\right) \quad 0 \leq n \leq L-1 \quad (5)$$




图1 EEG数据特征提取示意图

所示的汉宁窗以减少频谱泄漏,并计算其平均功率谱,从而得到不同频段的能量值。计算方法是:5 s 的 EEG 以 1 s 为基准,采用傅里叶变换计算功率谱,再以 0.1 s 为步长,直到计算出 5 s 内所有的共 41 段的功率谱,取这 41 段的均值作为这 5 s 的平均功率谱,得到不同频段的能量;然后每次移动窗口 0.2 s (32 点),直至计算出 5 min 内的全部滑动窗的平均功率谱,计算各频段能量,从而得到 EEG 能量时间序列,如图 1 所示。

以 O1、O2、T3、T4、Fp1、Fp2 等 6 个 EEG 导联及其相关频段 θ 、 α 、 β 、 θ/α 、 β/α 、 $(\alpha+\theta)/\beta$ 功率谱能量作为每个 5 s 时间窗的多维观测特征,连续 10 个 EEG 时间窗序列形成 HMM 的观察序列 $\{O_1, O_2, \dots, O_{10}, \dots, O_T\}$ 。

在不同的精神疲劳状态下,EEG 各个频段的功率谱能量也表现出不同的差异,图 2、图 3 显示了两个受试者的 α 频段的前 500 个观察序列的能量,其他频段数据可参看表 1、表 2。

表1 3 状态实验 6 个频段的功率谱能量的均值和标准差

状态	θ		α		β		$\theta \cdot \alpha^{-1}$		$\beta \cdot \alpha^{-1}$		$(\alpha+\theta) \cdot \beta^{-1}$	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
1	41.994	11.663	48.993	7.343 8	92.62	10.983	0.868 6	0.265	1.935	0.337 7	0.997 3	0.189 9
2	33.236	7.928 3	33.459	4.442 3	67.156	6.815 2	1.002	0.234 5	2.041 7	0.28	0.999 4	0.152 7
3	79.761	8.516 4	124.64	11.161	198.63	13.418	0.644 4	0.086 2	1.606 7	0.177 8	1.033 4	0.097 3

表2 4 状态实验 6 个频段的功率谱能量的均值和标准差

状态	θ		α		β		$\theta \cdot \alpha^{-1}$		$\beta \cdot \alpha^{-1}$		$(\alpha+\theta) \cdot \beta^{-1}$	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
1	66.595 6	9.743 3	45.034 6	3.417 3	94.146 4	15.450 7	1.504 3	0.323 5	2.088 5	0.254 8	1.231 7	0.282 6
2	60.157 7	8.593 1	48.051 5	4.505 5	108.406	12.051 9	1.278 7	0.293 4	2.259 5	0.156 1	1.015 1	0.156 3
3	55.215 7	8.721 3	44.073 3	5.674 4	88.569 8	14.182	1.277 4	0.267 8	2.008 3	0.151 2	1.144 8	0.182 2
4	48.456 8	9.585 2	36.779 4	7.072 2	79.766 4	17.670 1	1.353 7	0.295 9	2.170 2	0.210 4	1.097 2	0.174 4




图2 3 状态实验的 α 频段功率谱能量




图3 4 状态实验的 α 频段功率谱能量

从上面的图和表可以看出,功率谱能量特征是精神疲劳较为敏感的指标.在 3 状态实验中,不同精神疲劳状态的功率谱能量有着明显的不同,同一频段 EEG 数据在不同疲劳状态下的功率谱能量有较大的变化,状态 3 的能量总是最高的,状态 1 次之,状态 2 最小.在 4 状态实验中这个规律不是很明显,从图 4 中可以看到状态 1 和状态 2、3 的能量几乎重叠,这将会给后面的分类造成困难.

3 HMM 分类模型的建立

建立 HMM 实际上就是从训练样本中找到转移矩阵 A 和观察值概率矩阵 B ,HMM 训练流程见图 4.




图 4 基于 EEG 的 HMM 分级模型训练流程

对于连续 EEG 信号,必须定义好隐状态和混合高斯概率密度函数的数目.本文选取了 5 状态非时间可逆 Markov 链模型,即状态转移矩阵是上三角矩阵.每个状态的观察概率由 2 个高斯概率密度函数联合决定,状态初始概率 $\pi = \{1, 0, 0, 0, 0\}$.对两个不同的受试者,分别训练各自的 HMM.图 4 中的每个 λ_i 参数就是对应精神疲劳状态的 HMM.

4 结果及讨论

根据上面所述的方法,建立基于多通道 EEG 功率谱能量的 HMM 精神疲劳分类模型.500 个时间观察序列(约 2 min)的 EEG 数据被选为样本,其中 10% 作为训练样本,90% 作为测试样本.两状态下的训练测试情况如表 3、表 4.

表 3、表 4 分别给出了实验 1 和实验 2 中不同疲劳状态的分类正确率(百分比).从表中可以看出,训练样本较少时,分类效果不如训练样本多的效果

表 3 3 状态的分类结果

训练样本数	正确率/%			
	状态 1	状态 2	状态 3	平均
5	100	81.25	100	93.75
10	98.75	93.75	100	97.5

表 4 4 状态的分类结果

训练样本数	正确率/%				
	状态 1	状态 2	状态 3	状态 4	平均
15	90	88.75	38.75	35	63.13
20	91.25	83.75	40.25	82.5	74.44

好.在这次实验中,3 状态的分类效果明显好于 4 状态的分类效果,特别是 4 状态实验中的状态 3,基本上不能正确分类,这从 α 频段能量特征的分布图中可以看出,说明疲劳状态分为 3 种程度可能更加合适.从上表还可以看出,训练样本数目增加,可以提高分类精度.对于不同的精神疲劳状态,通过训练不同的 λ_i 参数,确定对应的 HMM,可以得到满意的分类效果,基于概率统计的 HMM 是一种强有力的非平稳时变时间序列的分析工具,通过几个少量的训练样本就可以达到较好的分类精度.

本文还比较了 BP 神经网络和 HMM 的分类性能,在 5 个训练样本和 20 个训练样本的情况下,分类结果见表 5、表 6.从表 4 可以看出,在相同训练样本条件下,HMM 的分类性能优于 BP 网络,这说明对 EEG 信号,HMM 更加能够反映出其非平稳的特性.

表 5 3 状态 BP 与 HMM 比较(训练样本数为 5)

方法	正确率/%			
	状态 1	状态 2	状态 3	平均
BP	97.25	80	100	92.42
CHMM	100	81.25	100	93.75

表 6 4 状态 BP 与 HMM 比较(训练样本数为 20)

方法	正确率/%				
	状态 1	状态 2	状态 3	状态 4	平均
BP	88.25	80	32.5	78.25	69.75
CHMM	91.25	83.75	40.25	82.5	74.44

5 结 论

EEG 各频段功率谱能量及其相关指标是精神疲劳的敏感特征,与不同精神疲劳状态具有较强的相关性,以此为依据建立的 CHMM 分级模型具有

较好的分类效果. 进一步优化 HMM 中隐状态的数目和观察序列的高斯混合模型个数, 可以在保证分类精度的情况下减少计算复杂度, 与 BP 人工神经网络相比较, CHMM 所需的训练样本更少, 计算量小, 分类精度更高. 本文提出的基于多通道 EEG 功率谱能量和 HMM 的精神疲劳分级方法为评估和测定精神疲劳提供了一种思路, 具有比较广阔的应用前景.

致谢 感谢新加坡国立大学机械工程与生物分离工程系提供疲劳实验数据.

参考文献:

- [1] Klimesch W. EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis[J]. Brain Research Review, 1999, 29(2/3):169-195.
- [2] Jung Txyy-Ping, Stensmo M. Estimating alertness form the EEG power spectrum[J]. IEEE Transactions on Biomedical Engineering, 1997, 44(1):60-69.
- [3] Myers C, Singer A, Shin F, et al. Modeling chaotic systems with hidden Markov model[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 1992:565-568.
- [4] Heck L P, McClellan J H. Mechanical system monitoring using HMM[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 1991:1697-1700.
- [5] Zhong S, Ghosh J. HMMs and coupled HMMs for multi-channel EEG classification [C]// International Joint Conference on Neural Networks. Piscataway: IEEE, 2002:1154-1159.
- [6] Ocak H, Loparo K A. A new bearing fault detection and diagnosis scheme based on hidden Markov modeling of vibration signals [C]// IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2001:3141-3144.

(编辑 杜秀杰)