



(12)发明专利申请

(10)申请公布号 CN 107007278 A

(43)申请公布日 2017.08.04

(21)申请号 201710277529.1

A61B 5/00(2006.01)

(22)申请日 2017.04.25

(71)申请人 中国科学院苏州生物医学工程技术
研究所地址 215163 江苏省苏州市高新区科技城
科灵路88号

(72)发明人 王心醉

(74)专利代理机构 北京远大卓悦知识产权代理
事务所(普通合伙) 11369

代理人 韩飞

(51)Int.Cl.

A61B 5/0402(2006.01)

A61B 5/0476(2006.01)

A61B 5/0488(2006.01)

A61B 5/08(2006.01)


权利要求书1页 说明书8页 附图3页

(54)发明名称

基于多参数特征融合的自动睡眠分期方法

(57)摘要

本案涉及基于多参数特征融合的自动睡眠分期方法,包括:采集脑电信号、肌电信号、心电信号和呼吸信号;对所有信号做去噪处理;提取脑电信号的 α 、 β 、 θ 、 δ 特征波的能量比;利用样本熵算法提取脑电信号样本熵;利用小波分解算法提取肌电信号中的高频特征能量比;利用样本熵算法提取心电信号样本熵;利用均值法提取呼吸信号的均值;将这五种特征参数输入支持向量机中进行训练和测试,从而得到分类结果。本案采用提取EEG、EMG、ECG和呼吸多个特征的方法,显著提高了睡眠分期的准确率和泛化能力;实验结果可信度高,能够准确完成睡眠分期,为评估睡眠质量提供有效依据,具有良好的应用前景。



1. 一种基于多参数特征融合自动睡眠分期方法,其特征在于,包括:
采集脑电信号、肌电信号、心电信号和呼吸信号;
对脑电信号、肌电信号、心电信号和呼吸信号做去噪处理;
提取去噪后的脑电信号的 α 、 β 、 θ 、 δ 特征波的能量比,得到第一特征参数;
利用样本熵算法提取脑电信号样本熵,得到第二特征参数;
利用小波分解算法提取肌电信号中的高频特征能量比,得到第三特征参数;
利用样本熵算法提取心电信号样本熵,得到第四特征参数;
利用均值法提取呼吸信号的均值,得到第五特征参数;
将第一特征参数、第二特征参数、第三特征参数、第四特征参数和第五特征参数输入支持向量机中进行训练和测试,从而得到分类结果。
2. 如权利要求1所述的基于多参数特征融合自动睡眠分期方法,其特征在于,所述第一特征参数通过以下方法获得:
使用“db4”小波函数对脑电信号进行7层小波分解,选择D3代表 β 波,D4代表 α 波,D5代表 θ 波,D6+D7代表 δ 波,分别计算 α 波、 β 波、 θ 波和 δ 波在0-30Hz上所占能量和的比值。
3. 如权利要求1所述的基于多参数特征融合自动睡眠分期方法,其特征在于,所述第三特征参数通过以下方法获得:
使用“sym3”小波函数对肌电信号进行3层小波分解,选择D1+D2代表肌肉运动频率,计算该肌肉运动频率在0-125Hz上所占的能量和的比值。
4. 如权利要求1所述的基于多参数特征融合自动睡眠分期方法,其特征在于,在利用样本熵算法提取脑电信号和心电信号的样本熵时,其中所用的嵌入维数=2,相似容限为原始数据的标准偏差的0.2倍,数据长度=1000。
5. 如权利要求1所述的基于多参数特征融合自动睡眠分期方法,其特征在于,对脑电信号、肌电信号和心电信号的去噪处理具体为:采用小波分解去除脑电信号、肌电信号和心电信号中的高频噪声。
6. 如权利要求1所述的基于多参数特征融合自动睡眠分期方法,其特征在于,对呼吸信号的去噪处理具体为:采用中值滤波法对呼吸信号进行去噪处理。

基于多参数特征融合自动睡眠分期方法

技术领域

[0001] 本发明涉及一种睡眠分期方法,尤其涉及一种基于多参数特征融合的自动睡眠分期方法。

背景技术

[0002] 随着现代社会竞争激烈,快节奏工作与生活对人们的睡眠产生了巨大影响。据世界卫生组织统计,27%的人有睡眠障碍。目前,睡眠障碍已被确认是一种具有公共危害性的疾病,越来越受到人们的高度重视。通过各生理信号对人体睡眠状态进行分期,是客观评估睡眠质量的一种有效方法。

[0003] 通过不同分析方法提取脑电 (Electroencephalogram, EEG) 的特征参数,再利用分类器进行分类是睡眠分期的经典方法。在现有技术中有人通过对EEG进行非线性符号动力学分析、去趋势波动分析和频谱分析的方法,并结合最小二乘向量机分类器将睡眠状态分为五期,准确率达到92.87%,但该算法只对每个样本进行单独的训练和验证,泛化能力有待提高。若利用离散小波变换结合非线性支持向量机的方法满足了模型对泛化能力的要求,准确率却只有81.65%。

发明内容

[0004] 针对现有技术中存在的技术问题,本案的目的是提供一种基于多参数特征融合的自动睡眠分期方法,以期能够提高睡眠分期的准确率和泛化能力。

[0005] 为实现上述目的,本案通过以下技术方案实现:

[0006] 一种基于多参数特征融合的自动睡眠分期方法,其包括:

[0007] 采集脑电信号 (EEG)、肌电信号 (EMG)、心电信号 (ECG) 和呼吸信号;

[0008] 对脑电信号、肌电信号、心电信号和呼吸信号做去噪处理;

[0009] 提取去噪后的脑电信号的 α 、 β 、 θ 、 δ 特征波的能量比,得到第一特征参数;

[0010] 利用样本熵算法提取脑电信号样本熵,得到第二特征参数;

[0011] 利用小波分解算法提取肌电信号中的高频特征能量比,得到第三特征参数;

[0012] 利用样本熵算法提取心电信号样本熵,得到第四特征参数;

[0013] 利用均值法提取呼吸信号的均值,得到第五特征参数;

[0014] 将第一特征参数、第二特征参数、第三特征参数、第四特征参数和第五特征参数输入支持向量机中进行训练和测试,从而得到分类结果。

[0015] 优选的是,所述的基于多参数特征融合的自动睡眠分期方法,其中,所述第一特征参数通过以下方法获得:

[0016] 使用“db4”小波函数对脑电信号进行7层小波分解,选择D3代表 β 波,D4代表 α 波,D5代表 θ 波,D6+D7代表 δ 波,分别计算 α 波、 β 波、 θ 波和 δ 波在0-30Hz上所占能量和的比值。

[0017] 优选的是,所述的基于多参数特征融合的自动睡眠分期方法,其中,所述第三特征参数通过以下方法获得:

[0018] 使用“sym3”小波函数对肌电信号进行3层小波分解,选择D1+D2代表肌肉运动频率,计算该肌肉运动频率在0-125Hz上所占的能量和的比值。

[0019] 优选的是,所述的基于多参数特征融合的自动睡眠分期方法,其中,在利用样本熵算法提取脑电信号和心电信号的样本熵时,其中所用的嵌入维数=2,相似容限为原始数据的标准偏差的0.2倍,数据长度=1000。

[0020] 优选的是,所述的基于多参数特征融合的自动睡眠分期方法,其中,对脑电信号、肌电信号和心电信号的去噪处理具体为:采用小波分解去除脑电信号、肌电信号和心电信号中的高频噪声。

[0021] 优选的是,所述的基于多参数特征融合的自动睡眠分期方法,其中,对呼吸信号的去噪处理具体为:采用中值滤波法对呼吸信号进行去噪处理。

[0022] 本发明的有益效果是:本案采用提取EEG、EMG、ECG和呼吸多个特征的方法,结合支持向量机分类器将睡眠状态分为五类(即Wake、N1、N2、N3、REM);对比基于EEG睡眠分期算法,多特征的加入显著提高了睡眠分期的准确率和泛化能力;实验结果可信度高,能够准确完成睡眠分期,为评估睡眠质量提供有效依据,具有良好的应用前景。

附图说明

[0023] 图1为本案自动睡眠分期方法的流程图。

[0024] 图2为脑电信号、肌电信号、心电信号和呼吸信号的去噪效果图。

[0025] 图3为脑电信号、肌电信号、心电信号和呼吸信号的特征提取结果图;其中,a为EEG的 α 、 β 、 θ 、 δ 特征波与EMG高频成分能量比;b为ECG样本熵;c为EEG样本熵;d为呼吸均值。

具体实施方式

[0026] 下面结合附图对本发明做进一步的详细说明,以令本领域技术人员参照说明书文字能够据以实施。

[0027] 1. 数据获取和预处理

[0028] 本案使用的数据来自于MIT-BIH多导睡眠数据库(Golberger AL, Amaral LAN, Glass L, et al. MIT-BIH Polysomnographic database. [DB/OL]. [2000-06-13]),该数据库记录了16个测试对象睡眠过程中的多个生理参数信号,采样频率250Hz。16个测试对象中,只有slp32、slp41、slp45、slp48测试个体包含完整的EEG、ECG、EMG(来自下颌)、呼吸信号且睡眠阶段完整,所以选择样本slp32、slp41、slp45、slp48作为实验对象。所有数据每30秒分为一段,由专家根据R&K标准进行睡眠分期判定,本案以此分期结果来测试算法的分期准确性及泛化能力。

[0029] 生理信号通常会受到一些未知频率成分的干扰,尤其是脑电信号(心电、肌肉运动、眼球的运动和闪烁会对其产生影响),因此本案需要对这些信号做降噪处理。临床和研究学中关注的EEG频率范围在0.5-35Hz,EMG的有效信号频率一般在0-500Hz,心电ECG的频率范围是0.05-100Hz,采用“db4”小波对原始EEG进行7层分解,采用“sym3”小波基对EMG进行3层分解,采用“db4”小波基对ECG进行6层分解,采用启发式阈值法对EEG、EMG、ECG信号进行去噪处理,采用中值滤波法对呼吸信号进行去噪处理,得到较纯净的信号。截取测试对象slp45的一段数据(4000个数据),去噪效果如图1所示。

[0030] 2.特征提取和分类算法

[0031] 2.1特征提取算法

[0032] 特征提取即提取睡眠所包含的信息,为更加详细的描述睡眠结构为实现准确分期,本文提取四路生理参数信号共八个特征,各信号特征描述如表1所示。

[0033] 表1提取特征总结表

信号	特征类型	特征描述
EEG	频域特征	能量比 η_{α} 、 η_{β} 、 η_{θ} 、 η_{δ}
	非线性特征	样本熵 $SampEn_e$
EMG	频域特征	肌电活动高频成分能量比 η_h
ECG	非线性特征	样本熵 $SampEn_c$
呼吸	时域特征	均值 $Mean_r$

[0035] 2.1.1 Mallat分解算法

[0036] Mallat分解算法即计算小波变换快速算法,是一种多分辨分析思想。算法又被称作塔式算法,由分解滤波器H、G进行分解。

[0037] 分解算法为:

$$\begin{cases} A_0[x(n)] = x(n) \\ A_i[x(n)] = \sum_k H(2n-k)A_{i-1}[x(n)] \\ D_i[x(n)] = \sum_k G(2n-k)D_{i-1}[x(n)] \end{cases} \quad (1)$$

[0039] 式中, $x(n)$ 是原信号, i 是分解层数, H 、 G 是小波分解滤波器, A_i 是 $x(n)$ 在第 i 层上近似部分的小波系数(低频), D_i 是 $x(n)$ 在第 i 层上细节部分的小波系数(高频)。

[0040] 在每一个尺度 2^i 上, 信号被分解成近似小波系数 A_i 和细节小波系数 D_i 。对于信号进行 i 层小波分解, 结点 A_i 和 D_i 的频率范围分别是 $0 \sim \frac{fs}{2^{i+1}}$ 和 $\frac{fs}{2^{i+1}} \sim \frac{fs}{2^i}$, 其中 fs 为采样频率。在实际应用中, 一般根据信号的特征来选择适当的分解层数。

[0041] 2.1.2特征能量比

[0042] 特征能量比是分解后所需层数的小波系数能量和占总层数小波系数能量和的比值, 计算公式如式(2)-(3):

$$\eta_i = \frac{\sum_{k=1}^n |D_i(k)|^2}{E_s} \quad (2)$$

$$E_s = \sum_{k=1}^N |D_i(k)|^2 \quad (3)$$

[0045] η_i : 分解后第 i 层频带所占总能量和的比值; $D_i(k)$: 分解后第 i 层上的第 k 个小波系数; n : 第 i 层的数据个数; E_s : 总能量和; N : 总层数的数据个数。

[0046] EEG信号的 α 、 β 、 θ 和 δ 波的频率范围分别为8~13Hz、13~30Hz、4~7Hz、1~4Hz, 本案对EEG信号利用“db4”小波基进行7层小波分解, 得到各层小波系数, 其中, D_3 代表 β 波, D_4 代表 α 波, D_5 代表 θ 波, D_6+D_7 代表 δ 波, 根据式(2)和式(3)分别计算 D_3 、 D_4 、 D_5 、 D_6+D_7 在0~

30Hz上所占的能量特征比,即得到EEG的四个频域特征: η_{α} 、 η_{β} 、 η_{θ} 、 η_{δ} 。

[0047] EMG信号中代表肌肉运动的高频频率范围为30~125Hz,本文选择“sym3”小波基对EMG信号进行3层小波分解,得到各层小波系数,其中D1+D2代表30~125Hz,根据式(2)和式(3)计算其在0~125Hz上所占的能量特征比,

[0048] 得到EMG的频域特征 η_h 。

[0049] 2.1.3样本熵

[0050] 样本熵算法的具体流程如下:

[0051] (1) 对一个由N点组成的原始信号 $\{u(i), 1 \leq i \leq N\}$ 按顺序组成一组m维矢量:

[0052] $X(i) = [u(i), u(i+1), \dots, u(i+m-1)]$ (4)

[0053] 式中, $i=1, 2, \dots, N-m+1$;

[0054] (2) $X(i)$ 与 $X(j)$ 之间的距离 $d[X(i), X(j)]$ 定义为两者对应元素中差值最大的一个,即:

[0055] $d[X(i), X(j)] = \max[|u(i+k) - u(j+k)|]$ (5)

[0056] 式中, $k=1, 2, \dots, m-1, i, j=1, 2, \dots, N-m+1$;

[0057] (3) 给定阈值 $B^m(r) = \frac{1}{N-m+1}$,对每一个i值统计 $d[X(i), X(j)]$ 小于r的数目(模版匹配数),以及此数目与矢量总个数的比值,记为 $B_i^m(r)$:

[0058] $B_i^m(r) = \frac{1}{N-m} \{d[X(i), X(j)] < r \text{ 的数目}\}$ (6)

[0059] 式中, $i, j=1, 2, \dots, N-m+1, i \neq j$;

[0060] (4) 求所有i的平均值 $B^m(r)$,即:

[0061] $B^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} B_i^m(r)$ (7)

[0062] (5) 把维数加1,组成m+1维矢量,重复(1)~(4)步骤,得到 $B^{m+1}(r)$;

[0063] (6) 定义样本熵为: $SampEn(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \right\}$ (8)

[0064] (7) 当N为有限值时,样本熵可写为:

[0065] $SampEn(m, r, N) = -\ln[B^{m+1}(r)/B^m(r)]$ (9)

[0066] 计算样本熵 $SampEn(m, r, N)$,首先要对m, r, N三个参数进行选取:m为嵌入维数,通常为1或2,实际应用中优先选择2,所以本案选择m=2;r为相似容限,r值太大会丢失很多详细信息,经研究分析得出 $r=0.2SD$ (SD为原始数据的标准偏差)时结果较好,本案选择 $r=0.2SD$;N为数据长度,经实验总结认为N=1000时效果最好。

[0067] 2.1.4均值

[0068] 均值计算简单速度快,且更能反映呼吸信号的幅度变换特征,因此本案选用均值法提取呼吸信号的时域特征。计算公式如下:

[0069] $Mean_r = \frac{1}{N} \sum_{i=1}^N x_i$

[0070] 其中,N为数据个数, x_i 为第i个数据的呼吸信号幅值, $Mean_r$ 为N个呼吸数据的均值。因为数据库中的数据以30s划分为一个睡眠阶段,共7500个数据点,因此本案中N=7500。

[0071] 2.2支持向量机分类算法

[0072] 支持向量机 (SVM) 通过寻求结构化风险最小, 达到最小化经验风险和置信范围, 并使其分类具有更强的泛化能力。SVM的基本思想是将数据映射到高维空间中, 然后在新空间中构建最优分类超平面。这一映射通过核函数 $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 实现, 得到最优分类函数:

$$[0073] \quad y = \text{sgn} \left\{ \sum_{i=1}^m \alpha_i y_i K(x_i, x_j) + b \right\} \quad (10)$$

[0074] 本文选取径向基核函数:

$$[0075] \quad K(x, x_i) = \exp(-\gamma * ||x - x_i||^2) \quad (11)$$

[0076] SVM实现分类的步骤:

[0077] (1) 选取数据的70%做为训练数据, 数据库中专家判读结果作为分类标签, 将训练数据和标签输入SVM分类器中得到分类模型;

[0078] (2) 剩下的30%数据做为测试数据, 数据库中专家判读结果作为测试标签, 输入SVM分类模型中得到分类结果, 比较测试得到结果和测试标签, 计算出分类精度。

[0079] 3. 实验结果

[0080] 3.1特征提取结果

[0081] 本文通过选取样本slp45的各个睡眠期(包括Wake、N1、N2、N3、REM)的一段数据进行特征分析。样本slp45睡眠时间为380分钟, 取每组数据长度7500点(30s), 截取EEG、EMG、ECG、呼吸信号中各睡眠阶段25分钟的(共 50×8 组)数据进行特征提取, 特征提取结果如图2所示。计算呼吸信号特征值的方差, 其余特征取平均值, 得到表2。

[0082] 表2不同特征参数在各睡眠阶段的平均值

[0083]

睡眠阶段 特征参数	W	N1	N2	N3	REM
α	0.1837	0.1050	0.0702	0.0240	0.0937
β	0.1170	0.0768	0.0286	0.0085	0.0508
θ	0.0802	0.0806	0.0671	0.0350	0.1210
δ	0.1214	0.1860	0.3312	0.3910	0.2687
EMG 高频	0.1163	0.0863	0.0331	0.0805	0.0133
EEG 样本熵	1.0360	1.0451	0.5054	0.3827	0.7550
ECG 样本熵	0.2706	0.1445	0.1396	0.1839	0.1340
呼吸方差	5543.6	868.34	97.241	173.02	476.45

[0084] 由图2和表2可以分析得出: (1) EEG: α 、 β 波的能量比在整个睡眠过程中变化趋势类似, 即在Wake期最高, 随着睡眠的加深开始逐渐降低, 到REM期时有所增加; θ 波在Wake、N1、REM期时占的比重较大, N3期很少; δ 波在整个睡眠过程中所占的比重比较大, 在N3期达到最大; 由于Wake期脑活动强, 脑电复杂度高, Wake期的样本熵最大, 随着睡眠的深入, 脑电活动

减弱,复杂度降低,脑电样本熵值减小,到REM期时,由于大脑开始做梦,脑电活动增强,复杂度又开始增加,样本熵值开始增大;(2) EMG:高频部分在Wake期较高,随着睡眠的深入逐渐减少,在REM期几乎没有;(3) ECG:在Wake期最高,然后逐渐降低,N3期有所增加;(4) 呼吸信号:呼吸幅度在Wake期时最明显,随着睡眠的深入,呼吸大幅度降低,N3期稍微有所增加。由此可见,这些特征在睡眠各期差异明显,采用以上八个特征参数作为分类器的输入,进行睡眠阶段的分类识别具有较强的理论支持。

[0085] 3.2分类结果

[0086] 提取slp32、slp41、slp45、slp48样本整夜睡眠数据(slp32共640组、slp41共780组、slp45共755组、slp48共760组)的八个特征属性:EEG的 α 、 β 、 θ 、 δ 波能量比、样本熵、EMG高频部分(30~125Hz)能量比、ECG样本熵、呼吸均值。把四个样本的特征参数混合,组成共有2935组特征的样本,其中70%(2055组)作为训练样本,用来建立SVM睡眠分类模型,剩余30%(880)作为测试集,用来检验分类效果。

[0087] 为验证该方法的优越性,设计三种方法对比实验:(1)基于EEG的睡眠分类方法;(2)基于EEG和ECG的睡眠分类方法;(3)基于多参数特征融合的睡眠分类方法。三种方法的分类效果对比如表3所示。对比基于EEG的睡眠分期方法,其他两种方法在睡眠各阶段正确率的提高率如表4。

[0088] 表3三种不同自动睡眠分期方法结果比较

[0089]

睡眠阶段	训练样本	测试样本	三种方法比较					
			EEG		EEG、ECG		多参数	
			正确样本	正确率/%	正确样本	正确率/%	正确样本	正确率/%
W	668	286	268	93.71	269	94.06	280	97.90
N1	386	166	108	65.06	117	70.48	147	88.55
N2	734	314	281	89.49	287	91.40	292	92.99
N3	125	53	36	67.92	35	66.04	43	81.13
R	142	61	40	65.57	41	67.72	56	91.80
总体	2055	880	733	83.30	749	85.11	818	92.95

[0090] 表4基于EEG、ECG睡眠分期方法与基于多参数睡眠分期方法相比基于EEG睡眠分期方法的提高率

[0091]

睡眠阶段 方法	提高率/%					总体
	W	N1	N2	N3	R	
EEG 与 ECG	0.35	5.42	1.91	-1.88	2.15	1.81
多参数	4.19	23.49	3.50	13.21	26.23	9.65

[0092] 为了验证该方法的泛化能力,本案采用交叉验证法对不同样本进行训练和测试。由于样本slp32没有REM期,容易造成误判,导致测试样本的准确率降低,所以在本次实验中剔除slp32样本。该实验步骤如下:首先分别取slp41、slp45、slp48单个样本作训练集,然后用该训练后的模型测试剩余两个样本,实验结果如表5所示。

[0093] 表5基于多参数特征融合的睡眠分期方法的泛化能力测试结果

[0094]

正确率/% 训练样本	测试样本			平均
	Slp41	Slp45	Slp48	
Slp41	/	85.12	88.54	86.83
Slp45	83.20	/	/	85.23
Slp48	85.54	81.23	/	83.39
平均正确率	/	/	/	85.15

[0095] 4. 结果分析

[0096] 在表3中,基于EEG的睡眠分期方法的正确率为83.30%,基于EEG和ECG的睡眠分期方法的正确率为85.11%,基于多参数的睡眠分期方法的正确率为92.95%,相比前两者,后者的正确率更高,优于许多自动睡眠分期算法。其中,Wake期准确率最高,其次分别是N2期和REM期,这三个睡眠阶段的分期准确率均达到91.80%以上。因此,本案所设计的基于多参数特征融合的睡眠分期方法可以实现较高准确率的睡眠分期。

[0097] 在对睡眠各期的影响方面,从表3和表4可以看出,加入ECG信号后N1期的影响最明显,其余各期影响不大;而基于多参数的睡眠分期方法对睡眠各期的影响都较大,其中对N1期和REM期的影响最大,正确率分别提高23.49%和26.23%,使这两期的正确率分别达到88.55%和91.80%,其次是N3期,正确率提高13.21%,但其正确率只有81.13%;虽然对W期和N2期的影响相对较小,但W期和N2期的正确率都在92%以上。总体来看,相比基于EEG的睡眠分期方法,基于EEG和ECG的睡眠分期方法正确率提高1.81%,基于多参数的睡眠分期方法正确率提高9.65%,这说明通过加入ECG、EMG、呼吸信号的特征可以有效提高睡眠分期的准确率。

[0098] 由泛化能力测试结果表5可知,对于不同样本间的交叉建模验证效果较理想,平均准确率达85.15%,表明基于多参数特征融合的睡眠分期具有较好的泛化能力。

[0099] 尽管本发明的实施方案已公开如上,但其并不仅仅限于说明书和实施方式中所列运用,它完全可以被适用于各种适合本发明的领域,对于熟悉本领域的人员而言,可容易地实现另外的修改,因此在不背离权利要求及等同范围所限定的一般概念下,本发明并不限

于特定的细节和这里示出与描述的图例。




图1




图2




图3

专利名称(译)	基于多参数特征融合的自动睡眠分期方法		
公开(公告)号	CN107007278A	公开(公告)日	2017-08-04
申请号	CN201710277529.1	申请日	2017-04-25
[标]申请(专利权)人(译)	中国科学院苏州生物医学工程技术研究所		
申请(专利权)人(译)	中国科学院苏州生物医学工程技术研究所		
当前申请(专利权)人(译)	中国科学院苏州生物医学工程技术研究所		
[标]发明人	王心醉		
发明人	王心醉		
IPC分类号	A61B5/0402 A61B5/0476 A61B5/0488 A61B5/08 A61B5/00		
CPC分类号	A61B5/0402 A61B5/0476 A61B5/0488 A61B5/08 A61B5/4809 A61B5/4812 A61B5/7203 A61B5/725 A61B5/7253 A61B5/7267		
代理人(译)	韩飞		
外部链接	Espacenet SIPO		

摘要(译)

本案涉及基于多参数特征融合的自动睡眠分期方法，包括：采集脑电信号、肌电信号、心电信号和呼吸信号；对所有信号做去噪处理；提取脑电信号的 α 、 β 、 θ 、 δ 特征波的能量比；利用样本熵算法提取脑电信号样本熵；利用小波分解算法提取肌电信号中的高频特征能量比；利用样本熵算法提取心电信号样本熵；利用均值法提取呼吸信号的均值；将这五种特征参数输入支持向量机中进行训练和测试，从而得到分类结果。本案采用提取EEG、EMG、ECG和呼吸多个特征的方法，显著提高了睡眠分期的准确率和泛化能力；实验结果可信度高，能够准确完成睡眠分期，为评估睡眠质量提供有效依据，具有良好的应用前景。

