



(12)发明专利申请

(10)申请公布号 CN 111067503 A

(43)申请公布日 2020.04.28

(21)申请号 201911412135.8

(22)申请日 2019.12.31

(71)申请人 深圳安视睿信息技术股份有限公司

地址 518129 广东省深圳市龙岗区坂田街
道新雪社区上雪科技园东一巷四栋B
座七楼

申请人 东莞三航安视睿信息技术有限公司

(72)发明人 段黎明 王红梅 段丽岩

(74)专利代理机构 西安研创天下知识产权代理
事务所(普通合伙) 61239

代理人 郭璐

(51)Int.Cl.

A61B 5/024(2006.01)

A61B 5/00(2006.01)

权利要求书3页 说明书9页 附图2页

(54)发明名称

一种基于心率变异性的睡眠分期方法

(57)摘要

本发明公开了一种基于心率变异性的睡眠分期方法,其中,该方法包括:将睡眠阶段信号进行平滑预处理;从平滑处理后ECG信号中提取RR间期;利用RR间期进行心率变异性特征提取;选择合适的心率变异性特征训练睡眠分期模型,利用训练好的模型完成睡眠分期,通过采用上述步骤,平滑掉了噪音信号,更好的保留了原有信息,对睡眠阶段的划分更为精准,分类更加细化,睡眠分期的效果更好。



1. 一种基于HRV的睡眠分期方法,其特征在于,所述HRV的睡眠分期方法具体包括以下步骤:

步骤一:将睡眠阶段信号进行平滑处理,平滑掉睡眠时不可能出现的阶段转换,保存原始睡眠阶段信息;

步骤二:从经步骤一平滑处理后的ECG信号中提取RR间期;

步骤三:利用步骤二提取的RR间期进行心率变异性特征提取;

步骤四:通过步骤三提取的特征训练睡眠分期模型,完成睡眠分期。

2. 根据权利要求1所述的一种基于HRV的睡眠分期方法,其特征在于,步骤一所述睡眠阶段包括4个纯净睡眠阶段,即浅睡眠L、深睡眠D、觉醒W、快速眼动期R;所述睡眠阶段还包括12个阶段转换,即觉醒转换为浅睡眠WL、觉醒转换为深睡眠WD、觉醒转换为快速眼动期WR、浅睡眠转换为觉醒LW、浅睡眠转换为深睡眠LD、浅睡眠转换为快速眼动期LR、深睡眠转换为觉醒DW、深睡眠转换为浅睡眠DL、深睡眠转换为快速眼动期DR、快速眼动期转换为觉醒RW、快速眼动期转换为浅睡眠RL、快速眼动期转换为深睡眠RD。

3. 根据权利要求1所述的一种基于HRV的睡眠分期方法,其特征在于,步骤二所述的从ECG信号中提取RR间期的具体过程为:

S1. 使用小波变换除去ECG信号中的噪音;

S2. 基于滑动窗口进行R波峰值点检测,得到R波横坐标;

S3. 将获取到的峰值点的横坐标连续后一峰值点坐标减去前一峰值点坐标,得到RR间期;

S4. 利用基于3sigma准则进行RR间期的错检和漏检。

4. 根据权利要求1所述的一种基于HRV的睡眠分期方法,其特征在于,步骤三所述的对RR间期进行心率变异性特征提取包括时域、频域和非线性域三维特征的提取。

5. 根据权利要求1所述的一种基于HRV的睡眠分期方法,其特征在于,步骤四所述的选择合适的心率变异性特征的具体步骤包括:

S1. 将睡眠过程分为睡眠转换阶段和纯净睡眠阶段,并对睡眠转换阶段和纯净睡眠阶段进行二分类;

S2. 对睡眠转换阶段进行分节分类:将睡眠转换阶段的后一纯净睡眠 T_{latter} 和前一纯净睡眠 T_{former} 的特征比值作为睡眠转换阶段和纯净睡眠阶段分类的新特征;

S3. 对纯净睡眠阶段进行分节分类:将前一睡眠阶段和该睡眠阶段处于整晚的第几个睡眠循环作为纯净睡眠的分类特征;

S4. 针对睡眠转换阶段以及纯净睡眠阶段中心率的时域、频域和非线性域特征,使用最大相关最小冗余算法进行特征选择。

6. 根据权利要求5所述的一种基于HRV的睡眠分期方法,其特征在于,S4所述的使用最大相关最小冗余算法进行特征选择的具体过程为:

(1) 以阶段中心率的时域特征为时间维度,频域特征为能量维度,非线性特征为复杂性度量;

(2) 给定两个随机变量 x 和 y ,他们的概率密度函数为 $p(x)$, $p(y)$, $p(x, y)$, 则互信息为:

$$I(x; y) = \iint p(x, y) \log[p(x, y) / p(x) p(y)] dx dy$$

目标就是找出含有 $m\{x_i\}$ 个特征的特征子集 S ,如果是离散变量,则最大相关性计算为:

$$\max D(S, c), D = (1/|S|) \sum_{x_i \in S} I(x_i, c)$$

其中： x_i 为第*i*个特征， c 为类别变量， S 为特征子集；

则最小冗余度为：

$$\min R(S, c), R = (1/|S|^2) \sum_{x_i, x_j \in S} I(x_i, x_j)$$

其中： $c(x_i, x_j)$ 为相关函数；

如果是连续变量，则最大相关性：

$$\max D_F, D_F = (1/|S|) \sum_{x_i \in S} F(x_i, c)$$

其中： D_F 为相关性， (x_i, c) 为 F 的统计量；

最小冗余度为：

$$\min R_c, R_c = (1/|S|^2) \sum_{x_i, x_j \in S} c(x_i, x_j)$$

其中： R_c 为冗余度；

(3) 然后整合最大相关性和最小冗余度，采用加法整合，则：

$$\max \Phi(D, R), \Phi = D - R$$

(4) 用增量搜索方法寻找近似最优的特征；假设我们已有特征集 S_{m-1} ，我们的任务就是从剩下的特征 $X - S_{m-1}$ 中找到第*m*个特征，通过选择特征使得 Φ 最大；增量算法优化下面的条件：

$$\max_{x_j \in X - S_{m-1}} [I(x_j, c) - [\sum_{x_i \in S_{m-1}} I(x_j, x_i)] / (m-1)]$$

(5) 针对纯净睡眠阶段，选择前12个特征，纯净睡眠的12个特征分别是RR间期的最小值，RR间期的方差，香农信息熵，正常窦性心律的标准差，相邻RR间期的差值均方根，RR间期的均值，相邻RR间期的差值均方根，RR序列变异程度，RR间期最大值，极低频频段能量值，低频频段能量值，HF高频频段能量；针对睡眠转换阶段，选择 r_Mean 均值， r_Min 最小值， r_TP 前后特征值的比值， r_CV 变异系数， r_vLF 极低频频段能量值， r_LF 低频频段能量值， r_var 方差， r_SDNN 标准差， r_Max 最大值， r_Renyi 香农信息熵， r_LF/HF 低频能量值与高频能量值的比值， r_HF 高频频段能量值， r_RMSSD 差值均方根， r_SDSD 差值标准差， $Sam_Entropy$ 样本熵。

7. 根据权利要求1所述的一种基于HRV的睡眠分期方法，其特征在于，步骤四所述的睡眠分期模型具体分为两层睡眠模型，第一层对纯净睡眠和阶段转换进行二分类，第二层对纯净睡眠的分节分类和分片分类，及对阶段转换的粗粒度和细粒度分类。

8. 根据权利要求1所述的一种基于HRV的睡眠分期方法，其特征在于，步骤四所述的利用训练好的模型完成睡眠分期的具体步骤包括：

S1. 选择机器学习中的支持向量机分类方法和集成学习分类器分类方法，进行睡眠分期模型训练；

S2. 基于隐马尔科夫解码过程，构建睡眠阶段识别模型；

S3. 利用SVM分类器，首先划分出阶段转换和纯净睡眠，进一步利用HMM分类器完成纯净睡眠分类，然后用AdaBoost分类器完成对阶段转换的粗粒度和细粒度分类，最终完成睡眠分期。

9. 根据权利要求8所述的一种基于HRV的睡眠分期方法，其特征在于，步骤S2所述的利用隐马尔科夫解码过程，构建睡眠阶段识别模型的具体过程为：

1) 状态集合 $S = \{S_1, S_2, S_3, S_4\}$ ，为睡眠阶段，即{清醒，浅睡期，深睡期，快速眼动期}；

2) 获取初始状态概率分布,取值为经过分析456个人的睡眠各个交睡眠阶段所占的比例, $\Pi_1=0.2641$, $\Pi_2=0.4527$, $\Pi_3=0.1322$, $\Pi_4=0.1510$;

3) 根据心率特征集合G确定观测序列 $O = \{O_1, O_2, O_3, O_4\}$, 为 $\{\text{Min}, \text{Var}, \text{Renyi}, \text{SDNN}, \text{RMSSD}, \text{Mean}, \text{SDSD}, \text{CV}, \text{Max}, \text{vLF}, \text{LF}, \text{HF}\}$;

4) 获取状态序列 $Q = \{q_1, q_2, q_3, \dots, q_t\}$, 且 $q_i \in \{S_1, S_2, S_3, S_4\}$, 其中Q代表状态序列, q_t 为最后一个状态, q_i 为t个状态中的其中一个状态;

5) 使用训练集数据,对睡眠阶段转换进行概率统计,得到状态转移概率矩阵,且状态转移概率矩阵 $A = \{a_{ij}\}$, $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$, $1 \leq i, j \leq 4$, 其中 a_{ij} 为状态为 S_j 的概率和状态为 S_i 的概率的比值;

6) 对睡眠阶段所对应的HRV特征进行概率统计,得到观测概率分布矩阵:

$B = \{b_j(k)\}$, $b_j(k) = P(o_t = v_k | q_t = S_j)$, $1 \leq j \leq 4$, v_k 为观测序列O的第t个特征 o_t 的实际值, $b_j(k)$ 为概率分布矩阵的元素,即在状态 S_j 下,第t个特征出现的概率;

7) 将该模型记为 $\lambda = (\pi, A, B)$;

8) 根据观测序列O与隐马尔科夫模型 $\lambda = (\pi, A, B)$,求解最有可能的隐状态序列,即睡眠阶段序列。

一种基于心率变异性的睡眠分期方法

技术领域

[0001] 本发明属于智能健康辅助领域,具体涉及一种基于心率变异性的睡眠分期方法。

背景技术

[0002] 据世界卫生组织调查显示,在世界范围内约1/3的人患有睡眠障碍,而中国各类睡眠障碍的患病比例高达38.2%;人体的睡眠质量指数不仅与睡眠时长有关,还与睡眠的深度有关,人从不同的睡眠阶段中醒来会对人的精神状态产生不同的影响,在医学中,用户要做一个完整的睡眠监测,需要在医院戴上专业的PSG监测设备,不仅仅是成本高和操作困难,而且许多患者还会随着睡眠环境的改变而发生睡眠行为的改变,造成在医院的测量结果与平时的睡眠行为差异,进而导致分析的结果不准确,误导医生病情分析,延误诊治;

[0003] 睡眠分期是进行睡眠质量评价的重要依据,但已有的睡眠分期方法大都以脑电信号为主,当前最广泛使用的是利用睡眠多导图采集脑电、心电、肌电等信号,由睡眠专家完成分期;但一方面该设备本身比较复杂且需要专业人员在特定的睡眠测试场所进行,另一方面需要在受试者身上粘贴许多的传感器,对自然睡眠造成了严重侵扰,并且由于价格昂贵,操作复杂,不适应家庭使用,也无法向公众推广;

[0004] 新的生理信号,比如呼吸特征,心率特征,心率变异性特征以及体动等容易被采集到的生理特征被用来进行睡眠分期,这种非接触式的方式更容易被大众接受,在相关文献中已有相关研究,从ECG信号中获取HRV和呼吸信号,使用呼吸和心率进行睡眠阶段的识别,综合使用体动记录仪和ECG数据得到HRV进行睡眠分期,该研究首先利用体动记录仪分析出实验者是处于醒着还是睡眠状态;然后使用HRV的时域、频域特征分析是处于浅睡眠还是深睡眠阶段;还有文献中提出一种考虑个体特征的睡眠分期方法,采用的生理信号包括心率、呼吸率、体动和血氧饱和度,其中呼吸率和体动的测量采用微动敏感床垫,心率和血氧饱和度由血氧计得到;

[0005] 多参数信息融合的睡眠分期,提出在不使用脑电的条件下,利用较易获得的心动周期、呼吸、体动等基本生理参数,提取其中与睡眠过程及其变化有关的规律和信息,建立知识规则库,采用不确定推理的证据理论进行多参数睡眠信息融合计算,实现睡眠结构分期。

发明内容

[0006] 为了克服上述现有技术的缺陷,本发明的目的在于提供一种基于心率变异性的睡眠分期方法,将睡眠阶段信号进行平滑预处理;从平滑处理后ECG信号中提取RR间期;利用RR间期进行心率变异性特征提取;选择合适的心率变异性特征训练睡眠分期模型,利用训练好的模型完成睡眠分期,平滑掉了噪音信号,更好的保留了原有信息,对睡眠阶段的划分更为精准,分类更加细化,睡眠分期的效果更好。

[0007] 为了达到上述目的,本发明的技术方案是这样实现的:

[0008] 一种基于HRV的睡眠分期方法,所述HRV的睡眠分期方法具体包括以下步骤:

[0009] 步骤一:将睡眠阶段信号进行平滑处理,平滑掉睡眠时不可能出现的阶段转换,保存原始睡眠阶段信息;

[0010] 步骤二:从经步骤一平滑处理后的ECG信号中提取RR间期;

[0011] 步骤三:利用步骤二提取的RR间期进行心率变异性特征提取;

[0012] 步骤四:通过步骤三提取的特征训练睡眠分期模型,完成睡眠分期。

[0013] 进一步的,步骤一所述睡眠阶段包括4个纯净睡眠阶段,即浅睡眠L、深睡眠D、觉醒W、快速眼动期R;所述睡眠阶段还包括12个阶段转换,即觉醒转换为浅睡眠WL、觉醒转换为深睡眠WD、觉醒转换为快速眼动期WR、浅睡眠转换为觉醒LW、浅睡眠转换为深睡眠LD、浅睡眠转换为快速眼动期LR、深睡眠转换为觉醒DW、深睡眠转换为浅睡眠DL、深睡眠转换为快速眼动期DR、快速眼动期转换为觉醒RW、快速眼动期转换为浅睡眠RL,快速眼动期转换为深睡眠RD。

[0014] 进一步的,步骤二所述的从ECG信号中提取RR间期的具体过程为:

[0015] S1.使用小波变换除去ECG信号中的噪音;

[0016] S2.基于滑动窗口进行R波峰值点检测,得到R波横坐标;

[0017] S3.将获取到的峰值点的横坐标连续后一峰值点坐标减去前一峰值点坐标,得到RR间期;

[0018] S4.利用基于3sigma准则进行RR间期的错检和漏检。

[0019] 进一步的,步骤三所述的对RR间期进行心率变异性特征提取包括时域、频域和非线性域三维特征的提取。

[0020] 进一步的,步骤四所述的选择合适的心率变异性特征的具体步骤包括:

[0021] S1.将睡眠过程分为睡眠转换阶段和纯净睡眠阶段,并对睡眠转换阶段和纯净睡眠阶段进行二分类;

[0022] S2.对睡眠转换阶段进行分节分类:将睡眠转换阶段的后一纯净睡眠 T_{latter} 和前一纯净睡眠 T_{former} 的特征比值作为睡眠转换阶段和纯净睡眠阶段分类的新特征;

[0023] S3.对纯净睡眠阶段进行分节分类:将前一睡眠阶段和该睡眠阶段处于整晚的第几个睡眠循环作为纯净睡眠的分类特征;

[0024] S4.针对睡眠转换阶段以及纯净睡眠阶段中心率的时域、频域和非线性域特征,使用最大相关最小冗余算法进行特征选择。

[0025] 进一步的,S4所述的使用最大相关最小冗余算法进行特征选择的具体过程为:

[0026] (1)以阶段中心率的时域特征为时间维度,频域特征为能量维度,非线性特征为复杂性度量;

[0027] (2)给定两个随机变量 x 和 y ,他们的概率密度函数(对应于连续变量)为 $p(x)$, $p(y)$, $p(x,y)$,则互信息为:

[0028]
$$I(x,y) = \iint p(x,y) \log[p(x,y)/p(x)p(y)] dx dy$$

[0029] 目标就是找出含有 $m\{x_i\}$ 个特征的特征子集 S ,如果是离散变量,则最大相关性计算为:

[0030]
$$\max_D(S,c), D = (1/|S|) \sum_{x_i \in S} I(x_i,c)$$

[0031] 其中: x_i 为第 i 个特征, c 为类别变量, S 为特征子集;

[0032] 则最小冗余度为:

[0033] $\min R(S, c), R = (1/|S|^2) \sum_{x_i, x_j \in S} I(x_i, x_j)$

[0034] 如果是连续变量,则最大相关性:

[0035] $\max D_F, D_F = (1/|S|) \sum_{x_i \in S} F(x_i, c)$

[0036] 其中: D_F 为相关性, (x_i, c) 为 F 的统计量;

[0037] 最小冗余度为:

[0038] $\min R_c, R_c = (1/|S|^2) \sum_{x_i, x_j \in S} c(x_i, x_j)$

[0039] 其中: R_c 为冗余度, $c(x_i, x_j)$ 为相关函数;

[0040] (3) 然后整合最大相关性和最小冗余度,采用加法整合,则:

[0041] $\max \Phi(D, R), \Phi = D - R$

[0042] (4) 用增量搜索方法寻找近似最优的特征;假设我们已有特征集

[0043] S_{m-1} , 我们的任务就是从剩下的特征 $X - S_{m-1}$ 中找到第 m 个特征,通过选择特征使得 Φ 最大;增量算法优化下面的条件:

[0044] $\max_{x_j \in X - S_{m-1}} [I(x_j, c) - [\sum_{x_i \in S_{m-1}} I(x_j, x_i)] / (m-1)]$

[0045] (5) 针对纯净睡眠,选择前12个特征,纯净睡眠的12个特征分别是RR间期的最小值,RR间期的方差,香农信息熵,正常窦性心律的标准差,相邻RR间期的差值均方根,RR间期的均值,相邻RR间期的差值均方根,RR序列变异程度,RR间期最大值,极低频频段能量值,低频频段能量值,HF高频频段能量;针对睡眠转换阶段,选择的特征是 r_Mean 均值, r_Min 最小值, r_TP 前后特征值的比值, r_CV 变异系数, r_vLF 极低频频段能量值, r_LF 低频频段能量值, r_var 方差, r_SDNN 标准差, r_Max 最大值, r_Renyi 香农信息熵, r_LF/HF 低频能量值与高频能量值的比值, r_HF 高频频段能量值, r_RMSSD 差值均方根, r_SDSD 差值标准差, $Sam_Entropy$ 样本熵。

[0046] 进一步的,步骤四所述的睡眠分期模型具体分为两层睡眠模型,第一层对纯净睡眠和阶段转换进行二分类,第二层对纯净睡眠的分节分类和分片分类,及对阶段转换的粗粒度和细粒度分类。

[0047] 进一步的,步骤四所述的利用训练好的模型完成睡眠分期的具体步骤包括:

[0048] S1. 选择机器学习中的支持向量机分类方法和集成学习分类器分类方法,进行睡眠分期模型训练;

[0049] S2. 基于隐马尔科夫解码过程,构建睡眠阶段识别模型;

[0050] S3. 利用SVM分类器,首先划分出阶段转换和纯净睡眠,进一步利用HMM分类器完成纯净睡眠分类,然后用AdaBoost分类器完成对阶段转换的粗粒度和细粒度分类,最终完成睡眠分期。

[0051] 进一步的,步骤S2所述的利用隐马尔科夫解码过程,构建睡眠阶段识别模型的具体过程为:

[0052] 1) 状态集合 $S = \{S_1, S_2, S_3, S_4\}$, 为睡眠阶段,即{清醒,浅睡期,深睡期,快速眼动期};

[0053] 2) 获取初始状态概率分布,取值为经过分析456个人的睡眠各个交睡眠阶段所占的比例, $\Pi_1 = 0.2641$, $\Pi_2 = 0.4527$, $\Pi_3 = 0.1322$, $\Pi_4 = 0.1510$;

[0054] 3) 根据心率特征集合 G 确定观测序列 $O = \{O_1, O_2, O_3, O_4\}$, 为{Min, Var, Renyi, SDNN, RMSSD, Mean, SDSD, CV, Max, vLF, LF, HF};

[0055] 4) 获取状态序列 $Q = \{q_1, q_2, q_3, \dots, q_t\}$, 且 $q_i \in \{S_1, S_2, S_3, S_4\}$, 其中 Q 代表状态序列, q_t 为最后一个状态, q_i 为 t 个状态中的其中一个状态;

[0056] 5) 使用训练集数据, 对睡眠阶段转换进行概率统计, 得到状态转移概率矩阵, 且状态转移概率矩阵 $A = \{a_{ij}\}$, $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$, $1 \leq i, j \leq 4$, 其中 a_{ij} 为状态为 S_j 的概率和状态为 S_i 的概率的比值;

[0057] 6) 对睡眠阶段所对应的HRV特征进行概率统计, 得到观测概率分布矩阵:

[0058] $B = \{b_j(k)\}$, $b_j(k) = P(o_t = v_k | q_t = S_j)$, $1 \leq j \leq 4$, v_k 为观测序列 O 的第 t 个特征 o_t 的实际值, $b_j(k)$ 为概率分布矩阵的元素, 即在状态 S_j 下, 第 t 个特征出现的概率;

[0059] 7) 将该模型记为 $\lambda = (\pi, A, B)$;

[0060] 8) 根据观测序列 O 与隐马尔科夫模型 $\lambda = (\pi, A, B)$, 求解最有可能的隐状态序列, 即睡眠阶段序列。

[0061] 本发明的有益效果是: 与现有技术相比, 本发明的改进之处在于, 由于本发明所提供的一种基于HRV的睡眠分期方法, 将睡眠阶段信号进行平滑预处理; 从平滑处理后ECG信号中提取RR间期; 利用RR间期进行心率变异性特征提取; 选择合适的心率变异性特征训练睡眠分期模型, 利用训练好的模型完成睡眠分期; 这样, 通过采用上述步骤, 平滑掉了噪音信号, 更好的保留了原有信息, 具有睡眠阶段的划分更为精准, 分类更加细化, 睡眠分期的效果更好的特点。

附图说明

[0062] 图1为本发明的基于心率变异性的睡眠分期方法的主要算法步骤流程图。

[0063] 图2为本发明中对纯净睡眠的分节分类示意图。

[0064] 图3为本发明中对纯净睡眠的分片分类示意图。

[0065] 图4为本发明中对阶段转换的细粒度分类示意图。

具体实施方式

[0066] 为了使本领域的普通技术人员能更好的理解本发明的技术方案, 下面结合附图和实施例对本发明的技术方案做进一步的描述。

[0067] 如附图1-4所示, 一种基于HRV的睡眠分期方法, 所述HRV的睡眠分期方法具体包括以下步骤:

[0068] 步骤一: 将睡眠阶段信号进行平滑处理, 平滑掉睡眠时不可能出现的阶段转换, 保存原始睡眠阶段信息: 具体而言, 睡眠是一个持续性的过程, 但经过PSG信号采集, 然后经过初步判断, 可能存在一些其他的阶段, 这些阶段可能是由某些外部因素引起的, 例如疾病和器械; 平滑规则是显示稳定的睡眠持续时间和睡眠连续性的属性; 也就是说, 在稳定的睡眠阶段, 阶段不太可能突然改变, 因此, 我们对数据进行平滑处理, 采用局部聚类算法(LCA), 尽可能保存原始睡眠阶段信息, 同时平滑掉不太可能出现的阶段转换;

[0069] 睡眠结构不是稳定不变的, 人一晚上的睡眠是不稳定, 要经历3-5个睡眠周期, 每个周期持续90-110分钟; 在每个周期内, 会出现觉醒W, 浅睡眠L, 深睡眠D和快速眼动期R; 通过分析一整晚的睡眠数据, 可以得出在某一段时间内, 某一纯净睡眠占据主要部分, 这说明睡眠不是杂乱无章的, 不是随意切换的, 是有规律、缓慢的变化的过程, 具体变化过程分为

12个睡眠转换阶段,分别是觉醒转换为浅睡眠WL、觉醒转换为深睡眠WD、觉醒转换为快速眼动期WR、浅睡眠转换为觉醒LW、浅睡眠转换为深睡眠LD、浅睡眠转换为快速眼动期LR、深睡眠转换为觉醒DW、深睡眠转换为浅睡眠DL、深睡眠转换为快速眼动期DR、快速眼动期转换为觉醒RW、快速眼动期转换为浅睡眠RL,快速眼动期转换为深睡眠RD;

[0070] 步骤二:从平滑预处理后的ECG信号中提取RR间期;其具体过程为:

[0071] S1.使用小波变换除去ECG信号中的噪音;

[0072] (1)对图象信号进行小波分解;

[0073] (2)对经过层次分解后的高频系数进行阈值量化;

[0074] (3)利用二维小波重构图象信号;

[0075] S2.基于滑动窗口进行R波峰值点检测,得到R波横坐标;

[0076] 利用固定滑动窗口的方法识别所有的波峰点;此处选择波峰点检测的方法是因为波峰表现的突出,检测出所有的R波;本文使用 TOMPKINS的“A Real-Time QRS Detection Algorithm”一文中的提取R波峰值的工具包来进行峰值检测,得到R波横坐标;

[0077] S3.将获取到的峰值点的横坐标连续后一峰值点坐标减去前一峰值点坐标,得到RR间期;

[0078] S4.利用基于3sigma准则进行RR间期的错检和漏检;

[0079] 使用滑动窗口的方法进行波峰点检测时,对波峰点的检测的准确率与窗口的宽度有一定的关系,较大的窗口会导致波峰点的漏检,较小的窗口会导致波峰点的错检;因此,本文也提出基于大部分心率间期均为正确的前提下进行错检和漏检的纠正算法;

[0080] 步骤三:利用RR间期进行心率变异性特征提取,具体而言,所述对RR间期进行心率变异性特征提取包括时域、频域和非线性域三维特征的提取;对于具体特征如下:

[0081] (1)HRV的时域特征提取,其具体过程如下:

[0082] S1.采用心电监测设备,连续记录睡眠过程中的人的正常窦性心搏;

[0083] S2.按照时间或者心搏顺序排列RR间期的数值,此即为RR间期序列;

[0084] S3.对RR间期序列进行时域特征分析,计算RR间期的均值、方差和最大最小值,正常窦性心律的标准差,相邻RR间期的差值均方根,相邻RR间期的差值标准差,差值在50ms以上占所有的百分比以及RR序列变异程度;

[0085] (2)HRV的频域特征提取,其具体过程如下:

[0086] 主要是分析RR间期时间序列的功率谱密度估计图,其描述的是 HRV的频谱随时间序列的分布情况,通过研究分析不同频率范围内(高低频,超低频)的频域值进而实现对心率变化规律的评估,本发明借助自回归模型(Auto-regressive model,AR),功率谱估计方法进行心率变异性的频域分析;

[0087] AR模型是一个全极点的模型,待分析信号 $x(n)$,使用差分方程对其进行表示:

[0088]
$$x(n) = -\sum_{i=1}^p a_p(i) x(n-1) + u(n)$$

[0089] 其中: $u(n)$ 表示均值为0,方差为 σ^2 的白噪声序列, p 表示AR模型的阶数, $a_p(i)$, $i=1,2,\dots,p$ 表示在不同阶数下AR模型对应的参数;

[0090] AR模型功率谱估计的计算方法如下:

[0091]
$$P(w) = \sigma^2 / |1 + \sum_{i=1}^p a_i e^{-jwi}|^2$$

[0092] 其中: e^{-jwi} 为AR模型函数代表了取值趋势, a_i 代表在 i 阶数下AR模型对应的参数。

[0093] HRV的功率频谱密度被分成5个部分,分别为极低频(very Low Frequency, vLF, 0.04HZ),低频(Low Frequency, LF, 0.15HZ),高频(High Frequency, HF, 0.4HZ),极高频(very High Frequency, vHF, 0.5HZ),总频功率(Total Frequency, TF, 0HZ-0.5HZ),根据上述划分标准,在本发明中提取如下HRV的频域特征进行模型的训练:

[0094] 1) vLF:代表极低频频段能量值,研究表明该频段反映了体液因子、体温调节等相关的长期的调节机制;

[0095] 2) LF:代表低频频段能量值,相关研究表明该频段反映了交感神经与副交感神经的共同调节;

[0096] 3) HF:代表高频频段能量,研究表明该频段能量反映副交感神经的活动,反映了人体的呼吸变化;

[0097] 4) vHF:代表极高频频段能量;

[0098] 5) TP:代表整个频段功率的能量总和,该参数反映的是在这一段时间内整个信号的变异性;

[0099] 6) LF/HF:代表低频高频频段能量值比值,是交感神经与迷走神经两者之间平衡性的量化指标;

[0100] (3) HRV的非线性特征提取:计算香农信息熵,作为RR间期复杂性的描述,包括样本熵值;

[0101] 具体香农信息熵的计算过程如下:假设有离散变量 X ,其概率分布为 $X=x_1, x_2, \dots, x_n$,则Renyi熵定义如下:

[0102] $H_\alpha(X) = \log_2 \sum_{i=1}^n p_i^\alpha / (1-\alpha)$

[0103] 其中: p_i 为事件 $X=x_i$ 的概率密度; α 代表Renyi熵的阶数,取值范围为正整数;

[0104] 本文中,主要使用1阶Renyi熵,当 α 取值为1时,由Renyi熵的定义可知,其分母逼近于零,通过洛必达法求极限值,得到熵值,计算公式如下:

[0105] $H_1(X) = \lim_{\alpha \rightarrow 1} H_\alpha(X) = -\sum_{i=1}^n [p_i \log_2(p_i)]$

[0106] 此时Renyi熵又被称为香农(Shannon)信息熵,即可作为RR间期复杂性描述。

[0107] 步骤四:选择合适的心率变异性特征训练睡眠分期模型,利用训练好的模型完成睡眠分期;具体而言,包括三部分内容:

[0108] 第一部分为选择合适的心率变异性特征的过程;

[0109] 第二部分为睡眠分期模型的分层;

[0110] 第三部分为利用训练好的模型完成睡眠分期的过程。

[0111] 在第一部分中所述选择合适的心率变异性特征的过程为:

[0112] S1.将睡眠过程分为睡眠转换阶段和纯净睡眠阶段,并对睡眠转换阶段和纯净睡眠阶段进行区分;

[0113] S2.对睡眠转换阶段进行分节分类:将睡眠转换阶段的最后一纯净睡眠 T_{latter} 和前一纯净睡眠 T_{former} 的特征比值作为睡眠转换阶段和纯净睡眠阶段分类的新特征;

[0114] S3.对纯净睡眠阶段进行分节分类:将前一睡眠阶段和该睡眠阶段处于整晚的第几个睡眠循环作为纯净睡眠的分类特征;

[0115] S4.针对睡眠转换阶段以及纯净睡眠阶段中心率的时域(时间维度)、频域(能量维度)和非线性特征(复杂性度量),使用最大相关最小冗余算法进行特征选择;

[0116] 具体选择算法为:给定两个随机变量 x 和 y ,他们的概率密度函数(对应于连续变量)为 $p(x)$, $p(y)$, $p(x,y)$, 则互信息为:

[0117] $I(x;y) = \iint p(x,y) \log[p(x,y)/p(x)p(y)] dx dy$

[0118] 目标就是找出含有 $m\{x_i\}$ 个特征的特征子集 S ,如果是离散变量,则最大相关性计算为:

[0119] $\max D(S,c), D = (1/|S|) \sum_{x_i \in S} I(x_i, c)$

[0120] x_i 为第 i 个特征, c 为类别变量, S 为特征子集;

[0121] 则最小冗余度为:

[0122] $\min R(S,c), R = (1/|S|^2) \sum_{x_i, x_j \in S} I(x_i, x_j)$

[0123] 如果是连续变量,则最大相关性:

[0124] $\max D_F, D_F = (1/|S|) \sum_{x_i \in S} F(x_i, c)$

[0125] 其中: D_F 为相关性, (x_i, c) 为 F 的统计量;

[0126] $F(x_i, c)$ 为 F 统计量,则最小冗余度为:

[0127] $\min R_c, R = (1/|S|^2) \sum_{x_i, x_j \in S} c(x_i, x_j)$

[0128] 其中: R_c 为冗余度, $c(x_i, x_j)$ 为相关函数;

[0129] 然后整合最大相关性和最小冗余度,采用加法整合,则:

[0130] $\max \Phi(D, R), \Phi = D - R$

[0131] 在实践中,用增量搜索方法寻找近似最优的特征;假设我们已有特征集 S_{m-1} ,我们的任务就是从剩下的特征 $X - S_{m-1}$ 中找到第 m 个特征,通过选择特征使得 Φ 最大;增量算法优化下面的条件:

[0132] $\max_{x_j \in X - S_{m-1}} [I(x_j, c) - [\sum_{x_i \in S_{m-1}} I(x_j, x_i)] / (m-1)]$

[0133] 在本发明中,特征是连续变量,采用的目标函数是加法整合,针对纯净睡眠,选择前12个特征,纯净睡眠的12个特征分别是Min(RR间期的最小值),Var(RR间期的方差),Renyi(香农信息熵),SDNN(正常窦性心律的标准差),RMSSD(相邻RR间期的差值均方根),Mean(RR间期的均值),SDSD(相邻RR间期的差值均方根),CV(RR序列变异程度),Max(RR间期最大值),vLF(极低频频段能量值),LF(低频频段能量值),HF高频频段能量;针对睡眠转换阶段,选择的特征是 r_Mean 均值, r_Min 最小值, r_TP 前后特征值的比值, r_CV 变异系数, r_vLF 极低频频段能量值, r_LF 低频频段能量值, r_var 方差, r_SDNN 标准差, r_Max 最大值, r_Renyi 香农信息熵, r_LF/HF 低频能量值与高频能量值的比值, r_HF 高频频段能量值, r_RMSSD 差值均方根, r_SDSD 差值标准差, $Sam_Entropy$ 样本熵;

[0134] r_Mean 均值代表一段时间内的RR间期的均值;

[0135] r_Min 最小值代表一段时间内的RR间期的最小值;

[0136] r_TP 表示阶段转换前后的特征值之比;

[0137] r_CV 变异系数表示一段时间RR间期序列变异程度;

[0138] r_vLF 极低频频段能量值,研究表明该频段反映了体液因子、体温调节等相关的长期的调节机制;

[0139] r_LF 低频频段能量值,相关研究表明,该频段反映了交感神经与副交感神经的共同调节;

[0140] r_var 方差表示一段时间内的RR间期的方差;

[0141] r_SDNN 标准差表示心跳间期与心跳间期均值差值的平方和的均值,从数学及物理理论角度分析,SDNN的值反映了这段心率时间序列信号的总功率;

[0142] r_Max 最大值表示一段时间的RR间期的最大值;

[0143] r_Renyi 香农信息熵表示RR间期复杂性;

[0144] r_LF/HF 低频能量值与高频能量值的比值,该比值与交感神经与迷走神经相关,反映了两者的相互变化关系;

[0145] r_HF 高频频段能量值,该频段能量反映副交感神经的活动,反映了人体的呼吸变化;

[0146] r_RMSSD 差值均方根,表示一段时间内的相邻RR间期的差值均方根;

[0147] r_SDSD 差值标准差,一段时间内的相邻RR间期的差值均方根;

[0148] Sam_Entroy 样本熵,表示RR间期总体的复杂度;

[0149] 第二部分所述睡眠分期模型具体分为两层睡眠模型,第一层对纯净睡眠和转换阶段进行二分类,第二层对纯净睡眠分节分类和分片分类,及对阶段转换的粗粒度和细粒度分类;

[0150] 第一层对纯净睡眠和阶段转换进行二分类的具体过程为:

[0151] 设时间尺度为D,并在不同的时间尺度D(Domain)下进行阶段转换的分析,时间尺度为1-10分钟,分析阶段转换和纯净睡眠在D下的分类结果:

[0152] S1.将睡眠阶段的觉醒期,浅睡眠,深睡眠和快速眼动期划分为纯净睡眠,将不同睡眠阶段的转换划分成为阶段转换,进行二分类;

[0153] S2.使用滑动窗口进行切分,目的是进行纯净睡眠P和阶段转换T的样本构建,使用分类器分类出哪些是纯净睡眠,哪些是阶段转换,时间尺度分别为1-10分钟;

[0154] 针对纯净睡眠的进一步分析,由两个方向进行:

[0155] 一是直接对在纯净睡眠和阶段转换的二分类的基础上,对分节的纯净睡眠直接进行分类,这个分节的长度是不确定的,默认在已经将睡眠阶段二分类成为纯净睡眠和阶段转换的基础上,划分出的节是纯净睡眠,中间没有其他的纯净睡眠,如附图2所示,除去标记的,剩下的是不同纯净睡眠的分类;二是将分节出的纯净睡眠,进一步等长切分划分为不同的片,然后再对片进行分类,如附图3所示,除去标记的纯净睡眠,进一步等长切分,然后进行分片分类,这样可以弥补第一步由于阶段转换分类不准确造成的将纯净睡眠误分类的不足;

[0156] 对第一步分类好的阶段转换进一步分类,细粒度分析是将所有的阶段转换进行分类,分别是觉醒转换为浅睡眠WL、觉醒转换为深睡眠WD、觉醒转换为快速眼动期WR、浅睡眠转换为觉醒LW、浅睡眠转换为深睡眠LD、浅睡眠转换为快速眼动期LR、深睡眠转换为觉醒DW、深睡眠转换为浅睡眠DL、深睡眠转换为快速眼动期DR、快速眼动期转换为觉醒RW、快速眼动期转换为浅睡眠RL,快速眼动期转换为深睡眠RD,一共是12个阶段转换,如附图4所示;

[0157] 对阶段转换的粗粒度和细粒度分类:粗粒度分类,将阶段转换分成6类,即觉醒转换为浅睡眠W-L,浅睡眠转换为觉醒L-W,浅睡眠转换为深睡眠L-D,深睡眠转换为浅睡眠D-L,浅睡眠转换为快速眼动期L-R,快速眼动期转换为浅睡眠R-L,深睡眠转换为快速眼动期D-R,快速眼动期转换为深睡眠R-D;细粒度分类,将阶段转换分成12类,即觉醒转换为浅睡眠WL、觉醒转换为深睡眠WD、觉醒转换为快速眼动期WR、浅睡眠转换为觉醒LW、浅睡眠转换

为深睡眠LD、浅睡眠转换为快速眼动期LR、深睡眠转换为觉醒DW、深睡眠转换为浅睡眠DL、深睡眠转换为快速眼动期DR、快速眼动期转换为觉醒RW、快速眼动期转换为浅睡眠RL,快速眼动期转换为深睡眠RD;

[0158] 考虑到阶段转换在人的睡眠过程中出现的概率问题,依据对大量睡眠数据的统计分析,W和L,L和D以及L和R的转换占据了阶段转换的80%以上,因此,主要进行出现概率较大的6个阶段转换的识别,分别是觉醒转换为浅睡眠W-L,浅睡眠转换为觉醒L-W,浅睡眠转换为深睡眠L-D,深睡眠转换为浅睡眠D-L,浅睡眠转换为快速眼动期L-R,快速眼动期转换为浅睡眠R-L,深睡眠转换为快速眼动期 D-R,快速眼动期转换为深睡眠R-D;

[0159] 第三部分所述利用训练好的模型完成睡眠分期的过程为:

[0160] S1.选择机器学习中的支持向量机分类方法和集成学习分类器分类方法,进行睡眠分期模型训练;

[0161] S2.基于隐马尔科夫解码过程,构建睡眠阶段识别模型,下面详细描述建模的具体过程:

[0162] 1) 状态集合 $S = \{S_1, S_2, S_3, S_4\}$,为睡眠阶段,即{清醒,浅睡期,深睡期,快速眼动期};

[0163] 2) 获取初始状态概率分布,取值为经过分析456个人的睡眠各个交睡眠阶段所占的比例, $\Pi_1=0.2641, \Pi_2=0.4527, \Pi_3=0.1322, \Pi_4=0.1510$;

[0164] 3) 根据心率特征集合G确定观测序列 $O = \{O_1, O_2, O_3, O_4\}$,为{Min, Var, Renyi, SDNN, RMSSD, Mean, SDS, CV, Max, vLF, LF, HF};

[0165] 4) 获取状态序列 $Q = \{q_1, q_2, q_3, \dots, q_t\}$,且 $q_i \in \{S_1, S_2, S_3, S_4\}$;

[0166] 5) 使用训练集数据,对睡眠阶段转换进行概率统计,得到状态转移概率矩阵,且状态转移概率矩阵 $A = \{a_{ij}\}$, $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$, $1 \leq i, j \leq 4$,其中 a_{ij} 为状态为 S_j 的概率和状态为 S_i 的概率的比值;

[0167] 6) 对睡眠阶段所对应的HRV特征进行概率统计,得到观测概率分布矩阵:

[0168] $B = \{b_j(k)\}$, $b_j(k) = P(o_t = v_k | q_t = S_j)$, $1 \leq j \leq 4$, v_k 为观测序列O的第t个特征 o_t 的实际值;

[0169] 7) 将该模型记为 $\lambda = (\pi, A, B)$;

[0170] 8) 在本问题中,我们关注的是马尔科夫模型中隐含状态,也就是知道可观测的HRV特征,研究睡眠阶段的问题,因此采用隐马尔科夫模型解码过程的Viterbi算法,根据观测序列O与隐马尔科夫模型 $\lambda = (\pi, A, B)$,求解最有可能的隐状态序列,也即睡眠阶段序列;

[0171] S3.利用SVM分类器,首先划分出阶段转换和纯净睡眠,进一步利用HMM分类器完成纯净睡眠分类,然后用AdaBoost分类器完成对阶段转换的粗粒度和细粒度分类,最终完成睡眠分期。

[0172] 以上显示和描述了本发明的基本原理、主要特征和本发明的优点。本行业的技术人员应该了解,本发明不受上述实施例的限制,上述实施例和说明书中描述的只是说明本发明的原理,在不脱离本发明精神和范围的前提下,本发明还会有各种变化和改进,这些变化和改进都落入要求保护的本发明范围内。本发明要求保护范围由所附的权利要求书及其等效物界定。



图1




图2




图3




图4

专利名称(译)	一种基于心率变异性的睡眠分期方法		
公开(公告)号	CN111067503A	公开(公告)日	2020-04-28
申请号	CN201911412135.8	申请日	2019-12-31
[标]发明人	段黎明 王红梅		
发明人	段黎明 王红梅 段丽岩		
IPC分类号	A61B5/024 A61B5/00		
CPC分类号	A61B5/02405 A61B5/4809 A61B5/4812 A61B5/4815 A61B5/7203 A61B5/7267		
代理人(译)	郭璐		
外部链接	Espacenet SIPO		

摘要(译)

本发明公开了一种基于心率变异性的睡眠分期方法,其中,该方法包括:将睡眠阶段信号进行平滑预处理;从平滑处理后ECG信号中提取RR间期;利用RR间期进行心率变异性特征提取;选择合适的心率变异性特征训练睡眠分期模型,利用训练好的模型完成睡眠分期,通过采用上述步骤,平滑掉了噪音信号,更好的保留了原有信息,对睡眠阶段的划分更为精准,分类更加细化,睡眠分期的效果更好。

