



(12)发明专利申请

(10)申请公布号 CN 106709469 A

(43)申请公布日 2017.05.24

(21)申请号 201710002025.9

A61B 5/00(2006.01)

(22)申请日 2017.01.03

(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 吕甜甜 陈骁 俞乾

(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.

G06K 9/00(2006.01)

G06K 9/62(2006.01)

A61B 5/0476(2006.01)

A61B 5/0488(2006.01)


权利要求书1页 说明书7页 附图3页

(54)发明名称

基于脑电和肌电多特征的自动睡眠分期方法

(57)摘要

本案涉及基于脑电和肌电多特征的自动睡眠分期方法,包括采集脑电信号和肌电信号;采用小波分解去除脑电信号和肌电信号中的高频噪声;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;将第一特征参数、第二特征参数和第三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和EMG多个特征的方法,结合支持向量机分类器,提高了睡眠分期的准确率;交叉验证结果表明该方法具有一定的泛化能力;实验结果可信度高,具有良好的应用前景。



1. 一种基于脑电和肌电多特征的自动睡眠分期方法,其特征在于,包括:
采集脑电信号和肌电信号;
采用小波分解去除脑电信号和肌电信号中的高频噪声;
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;
将第一特征参数、第二特征参数和第三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所述的基于脑电和肌电多特征的自动睡眠分期方法,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所述的基于脑电和肌电多特征的自动睡眠分期方法,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所述的基于脑电和肌电多特征的自动睡眠分期方法,其特征在于,在利用样本熵算法提取脑电信号样本熵时,其中所用的嵌入维数=2,相似容限为脑电信号原始数据的标准偏差的0.2倍,数据长度=1000。

基于脑电和肌电多特征的自动睡眠分期方法

技术领域

[0001] 本发明涉及一种睡眠分期方法,尤其涉及一种基于脑电和肌电多特征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。目前,对 EEG 的分析方法主要是从其时域、频域和非线性方面进行分析。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,本案提供一种基于脑电和肌电多特征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] 一种基于脑电和肌电多特征的自动睡眠分期方法,其包括:

[0007] 采集脑电信号和肌电信号;

[0008] 采用小波分解去除脑电信号和肌电信号中的高频噪声;

[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] 将第一特征参数、第二特征参数和第三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。

[0013] 优选的是,所述的基于脑电和肌电多特征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:

[0014] 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。

[0015] 优选的是,所述的基于脑电和肌电多特征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:

[0016] 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。

[0017] 优选的是,所述的基于脑电和肌电多特征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样本熵时,其中所用的嵌入维数=2,相似容限为脑电信号原始数据的标准偏差的0.2倍,数据长度=1000。

[0018] 本发明的有益效果是:本案采用提取EEG和EMG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,EMG的加入能提高睡眠分期的准确率;交叉验证结果表明,该方法具有一定的泛化能力;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

[0019] 图1为本案自动睡眠分期方法的流程图。

[0020] 图2为EEG和EMG的去噪效果图。

[0021] 图3为 α 、 β 、 θ 、 δ 波和EMG高频成分在睡眠各阶段的能量比示意图。

[0022] 图4为睡眠各阶段的EEG样本熵示意图。

[0023] 图5为各睡眠阶段的平均准确率的对比图。

具体实施方式

[0024] 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。

[0025] 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个测试对象的睡眠信号种类不同,本案选择具有EEG、EMG(下颌肌电)且睡眠阶段完整的样本s1p32、s1p41、s1p45、s1p48作为实验对象。每30秒数据后都记录一份由经验丰富的医生进行的人工睡眠分期判定,本案以此分期结果来测试算法的分期准确性及泛化能力。

[0026] 算法首先利用小波分解对EEG和EMG预处理,舍掉高频噪声部分;再提取去噪后EEG的 α 、 β 、 θ 、 δ 特征波的能量比,得到第一部分特征参数;再利用样本熵算法提取EEG样本熵得到第二部分特征参数;将两部分特征参数输入支持向量机中进行训练和测试得到分类结果;利用小波分解算法提取EMG的高频特征能量比,得到第三部分特征参数;将三部分特征参数输入支持向量机中进行训练和测试得到分类结果,该方法流程如图1所示。

[0027] 1.1、特征提取

[0028] 根据2007年美国睡眠医学学会(American Academy of Sleep Medicine, AASM)制定的睡眠判读指南,睡眠可分为五期:觉醒期(W期)、非快速眼动1期(N1期)、非快速眼动2期(N2期)、非快速眼动3期(N3期),快速眼动期(REM期)。实现准确分期的关键是提取能代表各个睡眠阶段的特征,各睡眠阶段特征如表1所示。

[0029] 表1各睡眠阶段特征

[0030]

睡眠阶段	特征
W	α 波 (8~13Hz)、 β 波 (13~30Hz)、肌电活动高
N1	θ 波 (4~8Hz)、肌电活动减弱, 或维持清醒水平
N2	睡眠纺锤波 (12~14Hz) 肌电活动弱于 N1 期

[0031]

N3	δ 波 (1~4Hz)、肌电活动一般显著减少
REM	α 波 (8~13Hz)、 θ 波 (4~8Hz)、肌电基本消失

[0032] 1.1.1、离散小波变换

[0033] 离散小波变换(简称DWT)实质是将能量有限的信号分解到时间-尺度空间上,能自动适应时频信号分析的要求,使其特别适用于非稳定信号。为能够有效地计算DWT,可使用让信号顺序地通过一系列低通和高通滤波器对的方法,该算法的分解系数为:

$$[0034] \quad \begin{cases} A_{k,n} = \sum_l a_{l-2n} A_{k+1,l} \\ D_{k,n} = \sum_l b_{l-2n} D_{k+1,l} \end{cases} \quad (1)$$

[0035] 式中, $A_{k,n}$ 和 $D_{k,n}$ 是分解系数, k 是分解尺度。

[0036] 据该分解算法原理分析可知:对信号进行 i 层小波分解,小波系数 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。临床医学中关注的EEG频率范围在0.5~30Hz,EMG的有效信号频率一般在0~500Hz,代表肌肉运动的高频成分多集中在30~125Hz。

[0037] 根据表1中各睡眠阶段对应的EEG、EMG特征波的频率范围和EEG、EMG的有效频率范围可知,将EEG利用“db4”小波函数进行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(8~13Hz)、 β 波(13~30Hz)、 θ 波(4~7Hz)、 δ 波(1~4Hz)在0~30Hz上所占有能量和的比值;将EMG利用“sym3”小波函数进行3层小波分解,选择D1+D2代表肌肉运动频率(30~125Hz),计算其在0~125Hz上所占有能量和的比值。能量比计算公式如式(1)~(3):

$$[0038] \quad \eta_i = \frac{\sum_{k=1}^n |D_i(k)|^2}{E_s} \quad (2)$$

$$[0039] \quad E_s = \sum_{k=1}^N |D_i(k)|^2 \quad (3)$$

[0040] 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。

[0041] 1.1.2、样本熵算法

[0042] 样本熵(Sample Entropy, SampEn)是对近似熵算法的改进,是度量序列复杂度的测度方法,其计算速度更快,精度更高。

[0043] 样本熵算法的具体流程如下:

[0044] (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:

$$[0045] \quad X(i) = [u(i), u(i+1), \dots, u(i+m-1)] \quad (4)$$

[0046] 式中, $i=1, 2, \dots, N-m+1$;

[0047] (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:

$$[0048] \quad d[X(i), X(j)] = \max [|u(i+k) - u(j+k)|] \quad (5)$$

[0049] 式中, $k=1, 2, \dots, m-1, i, j=1, 2, \dots, N-m+1$;

[0050] (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 $B_i^m(r)$:

$$[0051] \quad B_i^m(r) = \frac{1}{N-m} \{d[X(i), X(j)] < r \text{ 的数目}\} \quad (6)$$

[0052] 式中, $i, j=1, 2, \dots, N-m+1, i \neq j$;

[0053] (4) 求所有i的平均值 $B^m(r)$, 即:

$$[0054] \quad B^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (7)$$

[0055] (5) 把维数加1, 组成m+1维矢量, 重复(1)-(4)步骤, 得到 $B^{m+1}(r)$;

[0056] (6) 定义样本熵为:

$$[0057] \quad \text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \right\} \quad (8)$$

[0058] (7) 当N为有限值时, 样本熵可写为:

$$[0059] \quad \text{SampEn}(m, r, N) = -\ln [B^{m+1}(r) / B^m(r)] \quad (9)$$

[0060] 计算样本熵 $\text{SampEn}(m, r, N)$, 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, 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, 实验总结认为 $N=1000$ 时效果最好。

[0061] 1.2、支持向量机(SVM)分类

[0062] 针对非线性问题, SVM的基本思想是通过非线性变换 $x \rightarrow \phi(x)$ 将其映射到某个高维空间中的线性问题, 然后在变换后的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:

$$[0063] \quad y = \text{sgn} \left\{ \sum_{i=1}^m \alpha_i y_i K(x_i, x) + b \right\} \quad (10)$$

[0064] 本案选取径向基核函数:

$$[0065] \quad K(x_i, x) = \exp(-\gamma * ||x - x_i||^2) \quad (11)$$

[0066] SVM实现分类的步骤: 将数据分为训练和测试两个部分, 数据库中专家判读结果作为分类标签, 把训练数据和标签输入SVM分类器中得到分类模型, 再把测试数据输入SVM分类模型中得到分类结果, 将其与分类标签比较, 计算出分类精度。

[0067] 实验结果:

[0068] 2.1、数据预处理

[0069] EEG和EMG通常会包含一些未知频率的成分, 尤其是EEG受到的干扰更大(心电、肌

肉运动、眼球运动和闪烁都会对其产生影响)。所以,应抑制这些噪声以提高测量准确度。本案使用小波去噪的方法进行滤波预处理。

[0070] 本案使用“db4”小波函数对原始EEG进行7层分解,采用“sym3”小波函数对EMG进行3层分解,采用启发式阈值法对信号进行去噪处理,截取测试对象slp45的一段数据(3000个数据),EEG和EMG的去噪效果如图2所示。

[0071] 2.2、特征提取结果

[0072] 根据专家人工分期结果,对受试者的各睡眠阶段(Wake、N1、N2、N3、REM)截取一段数据进行特征分析。以被测对象slp45为例,其睡眠时间为380分钟,每组数据长度7500点(30s),选取每个睡眠阶段各25分钟的EEG和EMG(共 50×5 组数据)进行特征提取,计算各睡眠阶段 α 、 β 、 θ 、 δ 波及EMG高频成分的能量比,如图3所示,EEG样本熵如图4所示。六个特征参数在各睡眠阶段平均值如表2所示。

[0073] 表2不同特征参数在睡眠各阶段的平均值

[0074]

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 高频成分	0.1163	0.0863	0.0331	0.0805	0.0133
EEG 样本熵	1.3060	1.0451	0.5054	0.3827	0.7550

[0075] 2.3、分类结果与分析

[0076] 从图3和表2中分析可见: α 波的能量比在Wake期最明显,随着睡眠的深入开始逐渐降低,到REM期时有所增加; β 波能量比较 α 波能量比小,其在每期的变化和 α 波相似; θ 波在整个睡眠过程中较其他波少,但其在REM期明显增多; δ 波在整个睡眠过程中所占的比重较大,在N3期达到最大;EMG高频部分在Wake期较高,随着睡眠的深入逐渐减少,到REM期几乎没有。这些特征符合表1中所列的特征,表明基于离散小波变换提取EEG和EMG特征能量比方法可以实现睡眠分类。由图4和表2可知:Wake期的样本熵最大,这是由于Wake期脑活动强,脑电复杂度高。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,大脑开始做梦,脑电活动增强,复杂度又开始增加,样本熵开始增大。由此表明EEG样本熵在睡眠各期差异明显,能够进一步表明睡眠结构信息。因此,采用以上六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。

[0077] 2.4、分类结果与分析

[0078] 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)的六个特征属性:EEG的 α 、 β 、 θ 、 δ 波能量比、样本熵和EMG高频部分能量比,把样本slp45和slp48的特征参数混合,组成共有1515组特征的样本,其中70%(1062组)作为训练样本,用来建立SVM睡眠分类模型,剩余30%作为测试集,用来测试

分类准确性,分别用slp32、slp41两个样本测试该模型的泛化能力。

[0079] 为验证该方法的优越性,设计两种方法对比实验:基于单EEG的睡眠分类方法和基于EEG和EMG相结合的睡眠分类方法。两种方法的分类效果对比如表3所示,各睡眠阶段的平均准确率如图5所示,其准确度的平均提高率如表4所示。

[0080] 为了进一步验证该方法的泛化能力,本实验采用交叉验证法对不同样本进行训练和测试。由表3可以看出样本slp32没有REM期,所以容易造成误判,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4所示。

[0081] 表3加入EMG与不加入EMG的睡眠自动分期结果对比

[0082]

睡眠 状态	训练集 (slp45、slp48)			测试集 (slp45、slp48)			测试集 (slp32)			测试集 (slp41)		
	数量	正确率/%		数量	正确率/%		数量	正确率/%		数量	正确率/%	
		不加	加入		不加	加入		不加	加入		不加	加入
		EMG	EMG		EMG	EMG		EMG	EMG		EMG	EMG
W	232	96.98	98.28	99	85.86	95.96	394	83.25	90.10	229	86.46	93.45
N1	207	88.52	100	88	84.09	86.36	27	74.07	77.78	230	82.17	85.65
N2	470	95.32	95.74	201	89.05	94.03	159	88.05	88.68	218	81.65	84.86
N3	74	98.65	100	31	87.10	90.32	60	80.00	81.67	13	61.54	69.23
REM	79	98.73	100	34	88.24	97.06	0	—	—	90	86.67	92.22
总体	1062	96.99	98.12	453	87.20	92.94	640	83.75	88.44	780	83.46	88.21

[0083] 表4加入EMG后各睡眠阶段准确度的平均提高率

[0084]

睡眠阶段	W	N1	N2	N3	R	总体
平均提高率/%	6.31	2.49	2.31	3.49	5.22	3.96

[0085] 表5基于EEG和EMG多特征的睡眠分期方法的泛化能力测试结果

[0086]

测试样本 训练样本	slp41	slp45	slp48	平均准确率
slp41	—	82.01%	86.43%	84.22%

[0087]

slp45	81.41%	—	84.45%	82.93%
slp48	82.69%	79.10%	—	80.90%
平均准确率	—	—	—	82.68%

[0088] 表3显示了本案所设计的基于EEG和EMG多特征的睡眠分期效果较好,总体准确率可以达到92.94%,优于现有技术中的睡眠分期方法,且通过样本slp32和slp41测试,平均准确率也可以达到88.44%。

[0089] 通过图5和表4可以看出,在添加EMG前,REM期准确率最高,N2期次之,N1和N3的分期准确率最低;在添加EMG后,对觉醒期的影响最大,准确率提高6.31%,其次是REM期,这两个睡眠阶段准确率都达到了94.45%以上;在添加EMG后,对N1和N2的影响最小,所以提高N1和N2期准确率仍然是后续研究的重点方向。总体来看,加入EMG后睡眠分期准确率平均提高3.96%,说明通过提取EMG的高频成分能量比可以有效提高睡眠分期的准确率。

[0090] 通过表5的泛化能力测试可知,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82.68%,相较于现有技术的算法,基于多信号融合的睡眠分期具有一定的泛化能力。

[0091] 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3




图4




图5

专利名称(译)	基于脑电和肌电多特征的自动睡眠分期方法		
公开(公告)号	CN106709469A	公开(公告)日	2017-05-24
申请号	CN201710002025.9	申请日	2017-01-03
[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 吕甜甜 陈骁 俞乾		
发明人	王心醉 吕甜甜 陈骁 俞乾		
IPC分类号	G06K9/00 G06K9/62 A61B5/0476 A61B5/0488 A61B5/00		
代理人(译)	韩飞		
其他公开文献	CN106709469B		
外部链接	Espacenet SIPO		

摘要(译)

本案涉及基于脑电和肌电多特征的自动睡眠分期方法，包括采集脑电信号和肌电信号；采用小波分解去除脑电信号和肌电信号中的高频噪声；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；将第一特征参数、第二特征参数和第三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和EMG多个特征的方法，结合支持向量机分类器，提高了睡眠分期的准确率；交叉验证结果表明该方法具有一定的泛化能力；实验结果可信度高，具有良好的应用前景。

