

文章编号:1006-2467(2019)03-0321-06

DOI: 10.16183/j.cnki.jsjtu.2019.03.009

# 基于精细复合多尺度熵与支持向量机的睡眠分期

叶 仙<sup>1</sup>, 胡 洁<sup>1</sup>, 田 畔<sup>1</sup>, 戚 进<sup>1</sup>, 车大钊<sup>2</sup>, 丁 颖<sup>2</sup>

(1. 上海交通大学 机械与动力工程学院, 上海 200240; 2. 上海市儿童医院, 上海 200240)

**摘 要:** 提出将脑电信号与眼动信号的精细复合多尺度熵作为睡眠分期依据, 利用多层次支持向量机的机器学习算法对睡眠进行自动分期. 利用精细复合多尺度熵对睡眠信号进行特征提取, 选用脑电以及眼电通道的信号, 以保证输入特性的可靠性, 并通过 3 层支持向量机实现了睡眠的自动分期. 结果表明, 分类器的输入参数可由熵值曲线的变化特征来确定. 基于精细复合多尺度熵的多层次支持向量机算法的睡眠分期准确率达到 85.3%, 与已有的分类算法相比, 所提出的算法更加均衡, 且整体分类效果更佳.

**关键词:** 睡眠分期; 精细; 复合多尺度熵

**中图分类号:** TN 911.7; TP 391.4

**文献标志码:** A

## Automatic Sleep Scoring Based on Refined Composite Multi-Scale Entropy and Support Vector Machine

YE Xian<sup>1</sup>, HU Jie<sup>1</sup>, TIAN Pan<sup>1</sup>, QI Jin<sup>1</sup>, CHE Datian<sup>2</sup>, DING Ying<sup>2</sup>

(1. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. Shanghai Children's Hospital, Shanghai 200240, China)

**Abstract:** Sleep scoring is an important research direction in medical research and clinical medicine. Traditional visual scoring method is based on scoring rules, which is a time consuming and subjective procedure. Therefore an automatic sleep staging method based on refined composite multi-scale entropy (CMSE) and multi-level support vector machine is proposed. Firstly, to ensure the reliability of the input characteristics, refined CMSE is extracted as the feature input and two channels of electroencephalogram (EEG) and electrooculogram (EOG) are used. Then a three-layer support vector machine classification scheme is applied to classify sleep stages. Specifically, the inputs of each layer are obtained according to the trend of the entropy curves. The overall accuracy of the proposed method is 85.3%. Compared with traditional methods, the classification accuracy of the proposed method is more balanced and the global performance is much better.

**Key words:** sleep scoring; refined; composite multi-scale entropy (CMSE)

人类 1/3 的时间都在睡眠中度过. 与睡眠相关的疾病, 如睡眠呼吸暂停以及低通气等睡眠障碍严

重地影响了患者的生活质量. 调查显示<sup>[1]</sup>, 超过 2% 的成年女性以及 4% 的成年男性患有阻塞型呼吸暂

收稿日期: 2017-07-16

基金项目: 国家重点研发计划专项(2016YFF0101602, 2016YFC0104104), 国家重大科学仪器设备开发专项(2013YQ03065105), 上海交通大学“医-工交叉研究基金”(YG2014MS12)资助项目

作者简介: 叶 仙(1991-), 女, 安徽省桐城市人, 硕士生, 目前主要从事生物医学信号处理研究.

通信作者: 胡 洁, 男, 教授, 博士生导师, 电话(Tel.): 021-34206552; E-mail: hujie@sjtu.edu.cn.

停. 在睡眠疾病的研究中, 睡眠分期是必不可少的关键步骤. 临床上按照 Rechtschaffen and Kales (简称 R&K) 分期准则<sup>[2]</sup>将睡眠过程分为清醒期(W)、非快速眼动期(N)和快速眼动期(R). N 期又被分为非快速眼动 1 期(N1)、非快速眼动 2 期(N2)、非快速眼动 3 期(N3)和非快速眼动 4 期(N4), 其中 N3 和 N4 通常被整合成深睡眠期. 医疗人员根据美国睡眠医学会(AASM)标准<sup>[3]</sup>, 通过观察  $\alpha$  节律波、纺锤波和 K 复合波等特征来判别睡眠阶段. 人的整夜睡眠时间为 7~8 h, 人工进行睡眠分期通常需要花费 2~4 h, 并且不同专家的判读结果一致度低于 90%. 针对人工睡眠分期效率低、准确性不高的问题, 研究人员提出采用自动区分睡眠过程的方法代替传统的经验判读方法.

睡眠分期主要包含睡眠信号(1 帧图像)的特征提取以及睡眠时段的分类. 睡眠信号的特征提取方法主要包括时域分析、频域分析、时频分析<sup>[4]</sup>和复杂性分析方法. 其中, 复杂性分析方法是通过对表征系统的动态特性来研究信号内在特征的, 已经成为生物信号时间序列的研究方向. 熵作为表征系统复杂度的重要指标, 可用于区分人体生理信号的复杂度. Costa 等<sup>[5]</sup>提出多尺度熵(MSE)方法, 通过粗粒化的方式对时间序列进行多尺度划分, 以实现时间序列的多尺度分析. MSE 方法能够分析时间序列隐藏在多尺度模式信息, 但在多尺度样本熵粗粒化序列的研究中, 基于粗粒化定义的多尺度计算方法对时间序列长度的依赖性较强. 对于生理信号中的常见噪声(白噪声和  $1/f$  噪声), 当时间尺度增加时, 所得到的时间序列越短, MSE 与复合多尺度熵(CMSE)算法引入未定义熵的可能性越大, 从而导致算法的有效性降低. 在另一方面, 睡眠分期的分类算法也存在差异性. Flexer 等<sup>[6]</sup>采用隐马尔可夫方法(HMM)进行睡眠分期, 其准确率达到了 80.0%; 李谷等<sup>[7]</sup>利用希尔伯特-黄变换方法对睡眠进行自动分期, 其平均准确率为 81.7%. 近年来, 研究人员提出了基于决策树的多分类支持向量机(SVM)算法<sup>[8]</sup>, 并将其用于睡眠分期的多分类问题.

本文通过改进 CMSE 算法, 提出了基于精细复合多尺度熵(RCMSE)的睡眠分期算法. 对于较短的生物信号时间序列, 当使用 RCMSE 算法时引入未定义熵的概率降低, 所以 RCMSE 算法的有效性和准确性优于 MSE 以及 CMSE 算法, 并且选择特征区分度较高的 RCMSE 特征作为分类器的输入, 以保证输入的稳定性. 另外, 结合层次结构以及 SVM 的优势, 利用多层次的 SVM 分类器进行睡眠分期,

达到了快速准确的分期效果.

## 1 RCMSE 算法

睡眠分期算法的流程如图 1 所示. 首先, 以 30 s 记录 1 帧图像, 对睡眠的脑电(EEG)信号以及眼电(EOG)信号进行分段, 并且对原始信号进行滤波处理; 然后, 对睡眠信号的复杂度进行分析, 提取分类器的输入特征, 即 RCMSE; 最后, 运用多层次的 SVM 来实施睡眠分期.



图 1 睡眠分期算法流程

Fig. 1 Flow chart of the proposed sleep scoring method

### 1.1 信号的提取与预处理

本文所用数据来源于美国生理信号数据库 PhysioBank<sup>[9]</sup>中的 Sleep-EDF 数据库, 选择 10 位健康成人作为研究对象, 并对每位研究对象睡眠阶段的生理信号的记录时间为 20 h, 选用熄灯以后其 EEG(Fpz-Cz)和 EOG 通道的波形作为研究信号. 其中, 选择对象的睡眠状态良好, 各个睡眠时期已被完整地标注. 整夜的多导睡眠图(PSG)包含 Fpz-Cz 通道和 Pz-Oz 通道的 EEG 信号、EOG 信号以及肌电(EMG)信号. 采集数据的幅值单位为  $\mu\text{V}$ , EEG 信号以及 EOG 信号的采样频率均为 100 Hz. EEG 信号与 EOG 信号包含大量的生理信息, 本文选取 EEG(Fpz-Cz)和 EOG 通道的信号进行分析.

根据睡眠分期的判读规则, 睡眠监测开始后, 按照每 30 s 记录的 1 帧图像<sup>[10]</sup>进行判读. 由于 EEG 信号和 EOG 信号的频率均为 100 Hz, 所以以 3 000 个样本点为 1 段对数据进行预分割. 睡眠时, EEG 信号极其微弱, 背景噪声较强, 易于引入干扰, 如面部肌肉以及眼球的移动等; 并且 EEG 信号和 EOG 信号均是非平稳的随机信号, 难以提取特征, 因此, 需要利用有效的手段对其进行降噪处理. 根据 AASM 推荐的各通道滤波标准, EEG 信号及 EOG 信号的带通滤波标准均为 0.3~35.0 Hz, 因此, 设置巴特沃斯滤波器的通带频率为 0.3~35.0 Hz, 以对信号进行滤波处理.

### 1.2 精细复合多尺度熵特征提取

本文以生物信号的复杂度作为睡眠分期的判定标准. 目前, 复杂度的量化方法包括近似熵<sup>[11]</sup>、样本熵、多尺度样本熵和 RCMSE 等. 由于 RCMSE 的有效性、准确性较高, 所以本文利用 RCMSE 方法分

析睡眠信号的时间序列复杂度,计算 EEG 信号以及 EOG 信号的多尺度熵。以下为 RCMSE 算法的步骤。

(1) 采集研究对象的 EEG 和 EOG 信号,每一通道的信号为一维的离散时间序列。令  $x = \{x_1, x_2, \dots, x_N\}$  为长度为  $N$  的时间序列。粗粒化过程如下:

$$y_{k,j}^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau+k-1} x_i \quad (1)$$

式中:  $1 \leq j \leq N/\tau$ ,  $\tau$  为尺度值;  $1 \leq k \leq \tau$ 。

通过式(1)可以得到不同时间尺度上的粗粒化时间序列。

(2) 对于每一尺度值  $\tau$ , 计算所有  $\tau$  的粗粒度序列对应的匹配向量对的数目  $n_{k,\tau}^{m+1}$  和  $n_{k,\tau}^m$ ,  $m$  为维数;

(3) 令  $\bar{n}_{k,\tau}^{m+1}$  和  $\bar{n}_{k,\tau}^m$  分别为  $1 \leq k \leq \tau$  时  $n_{k,\tau}^{m+1}$  和  $n_{k,\tau}^m$  的平均值。对应尺度  $\tau$  值, 将  $\bar{n}_{k,\tau}^{m+1}$  与  $\bar{n}_{k,\tau}^m$  比值的对数值定义为 RCMSE, 即

$$\text{RCMSE}(x, \tau, m, r) = -\ln \frac{\bar{n}_{k,\tau}^{m+1}}{\bar{n}_{k,\tau}^m} \quad (2)$$

式中:

$$\bar{n}_{k,\tau}^{m+1} = \frac{1}{\tau} \sum_{k=1}^{\tau} n_{k,\tau}^{m+1}, \quad \bar{n}_{k,\tau}^m = \frac{1}{\tau} \sum_{k=1}^{\tau} n_{k,\tau}^m$$

式(2)可简化为

$$\text{RCMSE}(x, \tau, m, r) = -\ln \frac{\sum_{k=1}^{\tau} n_{k,\tau}^{m+1}}{\sum_{k=1}^{\tau} n_{k,\tau}^m} \quad (3)$$

由式(3)可知, 只有在所有的  $n_{k,\tau}^{m+1}$  为 0 或  $n_{k,\tau}^m$  为 0 的情况下, RCMSE 才会引入未定义熵。因此, 与 CMSE 算法相比, 利用 RCMSE 算法能够降低诱导未定义熵的可能性。

通过考虑多方面的因素来选择合适的参数。其中: 嵌入的维数  $m$  越大, 包含的细节信息越多, 但  $m$  值越大, 需要的数据长度越长, 综合考虑, 本文选取  $m = 2^{[12]}$ ;  $r$  值一般为原始数据标准差  $b$  的  $0.10 \sim 0.25$  倍, 本文选取  $r = 0.15b$ ; 由于选择太大的  $\tau$  值将会影响计算效率, 而选择太小的  $\tau$  值将导致无法提取足够多的有效信息, 因而本文设置粗粒化的最高  $\tau$  值为 20。

### 1.3 多层次支持向量机分类器设计

本文使用 SVM 方法进行模式分类。从本质上来说, SVM 是一种二分类的方法。假设  $\{(x_i, y_i), i = 1, 2, \dots, N\}$  为训练集, 其中  $x_i \in \mathbf{R}^d$  是输入数据,  $y_i \in \{-1, +1\}$  为分类的标签, 分别代表不同的睡眠状态。将超平面定义为

$$\mathbf{w}^T \mathbf{x} + b = 0$$

其中:  $\mathbf{w}$  是  $d$  维的向量;  $b$  是标准偏差。为获得更大的

边界以及更强的泛化能力, 引入正的松弛变量  $\xi_i$ 。根据以下约束的二次优化问题的求解来确定最优的超平面:

$$\min_{\mathbf{w}, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \quad (4)$$

使得

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \quad (5)$$

式中:  $C$  是惩罚参数。通过求解优化问题来估计  $\mathbf{w}$  和  $b$ 。然后, 定义离散决策函数, 对输入数据进行分类:

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j) + b\right) \quad (6)$$

式中:  $\alpha_i$  是拉格朗日乘子;  $K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)\varphi(\mathbf{x}_j)$ , 为核函数,  $\varphi(\mathbf{x})$  为非线性函数, 形成从训练数据到高维特征空间的映射。

本文的研究目标是将睡眠阶段分为 5 个不同的时期, 即 W 期、N1 期、N2 期、N3 期和 R 期, 该分期属于多分类问题。针对睡眠分期的多分类问题<sup>[13]</sup>, 一般采用将多分类问题转化为两分类问题来求解。具体方法: ① 一对一法, 即在每两类之间训练一个分类器。对于一个  $k$  类问题, 存在  $k(k-1)/2$  个分类函数。② 一对多分类法, 在每一类别与其他类别之间构造分类函数 ( $K$  类问题构造  $K$  个两分类器)。该方法存在分类重叠以及不可分类的缺点。与一对一以及一对多方法对比, 多层次 SVM 分类方法的复杂度更低, 能够快速完成分类。多层次 SVM 分类算法的框图如图 2 所示。首先, 对 RCMSE 进行特征提取, 然后, 根据 RCMSE 曲线的分布特征来确定不同层次的输入参数。分类器由 3 层组成: 第 1 层将信号分为睡眠期以及清醒期, 第 2 层以及第 3 层分别在上一层分类结果的基础上进行更深层次的分类, 直到将睡眠阶段分为 5 个独立的时期。其中,

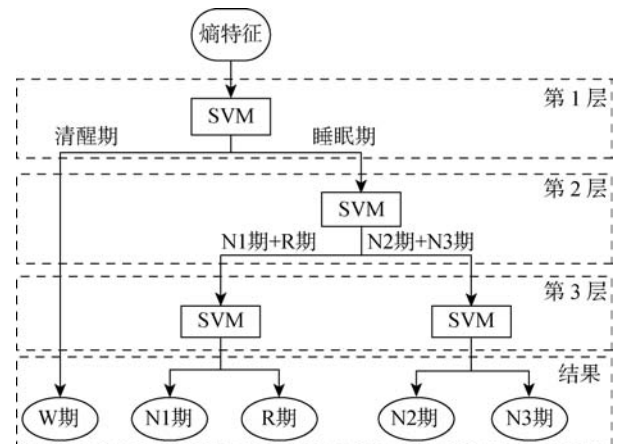


图 2 多层次 SVM 分类算法框图

Fig. 2 Block diagram of the proposed multi-classification SVM

RCMSE 值为输入特征,随机选取其中的部分数据进行分类器训练,剩下的睡眠数据用于分类器的预测.通过对比预测的睡眠分期结果与人工判读的睡眠分期标签,获得睡眠自动分期的准确率.

2 结果与分析

2.1 RCMSE 分析

EEG 信号是睡眠分期准则的主要判别标准,所以本文首先选取 EEG 信号,参考导联为 Fpz-Cz 通道,所得 EEG 信号的 RCMSE 的变化曲线如图 3 所示.其中,不同的点表示各个时期的 RCMSE 均值,其上下竖线表示 RCMSE 标准差.根据 RCMSE 的变化趋势确定分类器的层数以及设置每一层次的输入参数.由图 3 可见:W 期与其他时期 EEG 信号的 RCMSE 的差别较为明显,所以在分类器的第 1 层将数据分为清醒期和睡眠期;N1 期、R 期与 N2 期、N3 期的 RCMSE 的区分度较高,在第 2 层 SVM 中对其进行分类;N2 期与 N3 期的 RCMSE 的差异明显,可在第 3 层分类器中对其进行分类.




图 3 脑电信号 EEG 通道的 RCMSE 变化曲线  
Fig. 3 RCMSE curves of channel EEG

参考 AASM 睡眠及相关事件判读手册<sup>[14]</sup>,可以发现睡眠 R 期的低波幅混合频率与 N1 期的相似,2 个时期的 EEG 信号相似度较高,但其 EOG 信号存在差异.其中,N1 期为缓慢眼动,而 R 期出现了快速眼动的现象.相应地,由图 3 可见,N1 期与 R 期 EEG 信号的 RCMSE 变化趋势非常相似,且其区分度较差,通过 EEG 信号的 RCMSE 变化特征难以区分这 2 个时期.为此,本文提取研究对象的 EOG 信号进行 N1 期以及 R 期的分类.图 4 所示为 EOG 信号的 RCMSE 变化曲线.可见,N1 期与 R 期的区分效果得到了改善.




图 4 眼电信号 EOG 通道的 RCMSE 变化曲线  
Fig. 4 RCMSE curves of channel EOG

人工的睡眠分期准则对于特征的选择具有重要的参考价值.这个睡眠分期准则充分结合信号的整体与局部信息,根据不同的规则判别睡眠时期.具体方法:① 在判读 N1 期时,1 帧图像中整体背景特征满足低波幅混合频率(3~7 Hz)的成分所占比例超过 50%,即低波幅混合频率波的宽度所占比例超过 50%,该准则表征了信号的整体特点;② 在判读 N2 期时,需要运用局部短时的 K-复合波特征,该准则表征了信号的局部特点.与人工的睡眠分期准则对应,本文提出的基于 RCMSE 特征的睡眠分期方法能够通过特征尺度的变化来表征信号的整体或局部特点:当特征尺度  $\tau=1$  时,能够表征信号的整体特征;当  $\tau$  不断增大时,能够表征信号的局部特征.通过比较 RCMSE 的均值以及标准差,优先区分差异性较大的睡眠时期,因此,将 RCMSE 作为信号的特征输入能够较好地反映睡眠信号的复杂度.

分析上述 RCMSE 的变化曲线可以看出,N1 期与 R 期的区分度较低,N2 期与 N3 期的变化趋势相似.其中,N2 期与 N3 期在  $\tau$  处于 1~10 范围内的区分度较高.因此,选择容易区分的尺度范围作为多层次 SVM 分类算法的特征输入,可以保证分类效果并且提高工作效率.对于每层的分类节点,选取的 RCMSE 特征尺度以及对应的通道见表 1.

表 1 多层次 SVM 分类的通道以及特征提取		
Tab. 1 RCMSE features and channel for SVM classification method		
分类器	$\tau$	通道
清醒期与睡眠期	1~20	EEG(Fpz-Cz)
N1 期和 R 期与 N2 期和 N3 期	1~20	EEG(Fpz-Cz)
N1 期与 R 期	1~20	EOG
N2 期与 N3 期	1~10	EEG(Fpz-Cz)

## 2.2 睡眠分期结果

表 2 列出了睡眠的 SVM 自动分期结果与人工判读分期结果的对比. 表中, 对角线上的黑体数值为准确判读的数据量, 非对角线的数值为误判数据. 根据表 2 中的内容, 采用本文算法计算所得各个独立睡眠时期的分类准确率如表 3 所示. 由表 3 可见: 清醒期的分类在第 1 层 SVM 分类器中完成, 其分类准确率最高, 达到了 92.4%; 第 3 层 SVM 分类器完成对 N1 期的分类, 由于 N1 期与 R 期的特征最相似, 其中 N1 期的部分数据被人工误判为 R 期, 同时, 在整个睡眠阶段的 N1 期数据较少, 所以最终导致 N1 期的人工判读准确率较低; N2 期及 N3 期的分类准确率分别达到了 89.2% 以及 90.0%. SVM 分类器每一层次的分类效果都会对最终的分类结果产生影响, 其中 W 期、N2 期、N3 期、R 期的分类准确率均高达 85% 以上, 从而保证了各个睡眠阶段的分类效果.

表 2 SVM 分类和人工判读结果

Tab. 2 The classification results of SVM

SVM 分类	人工分期				
	W	N1	N2	N3	R
W	<b>378</b>	65	11	1	21
N1	20	<b>131</b>	21	1	53
N2	1	10	<b>978</b>	96	1
N3	1	1	44	<b>891</b>	2
R	9	98	43	1	<b>529</b>

表 3 独立睡眠时期的准确率

Tab. 3 Accuracy for individual stages

睡眠时期	准确率/%
W	92.4
N1	43.0
N2	89.2
N3	90.0
R	87.3

## 2.3 睡眠分期方法比较

将本文算法与文献[15-17]中的算法进行比较, 所得到的分类准确率如表 4 所示. 由表 4 可见, 与文献[15-17]中的算法相比, 本文所提出的算法的分类准确率有所提高. 另外, 由表 5 可见, 本文算法在 W 期、N1 期、N2 期以及 N3 期的分类效果均比文献[18]中的算法更优, 同时, 在 R 期也保持了较高的分类准确率. 针对文献[19]中的算法不能准确区分睡眠 R 期的问题, 本文算法有所改进, 在该阶段的

分类准确率有所提高, 并且在其他阶段也保持了较高的分类准确率. 通过对比各个独立时期的分类结果可见, 本文算法具有更加平衡的输出, 并且总体的分类准确率更高. 因此, 相对其他的算法, 本文提出的算法具有较好的稳定性.

表 4 不同算法的分类准确率比较

Tab. 4 Comparison of classification accuracy

算法	特征	采用方法	准确率/%
文献[15]	熵度量	J-means 方法	81.00
文献[16]	混合特征	人工神经网络	81.55
文献[17]	频率特征	遗传模糊分类器	84.60
本文算法	RCMSE	多层 SVM	85.30

表 5 独立时期的分类准确率比较

Tab. 5 Performance comparison of individual stages

算法	准确率/%				
	W	N1	N2	N3	R
文献[18]	39.6	25.5	88.5	82.8	90.3
文献[19]	93.4	46.6	82.7	85.6	66.0
本文算法	92.4	43.0	89.2	90.0	87.3

## 3 结语

本文提出了基于 RCMSE 特征的多层次 SVM 睡眠自动分期模型. 从研究对象的 EEG 信号以及 EOG 信号中提取 RCMSE 特征, 以 RCMSE 值作为研究的唯一特征, 它可以从多个尺度表征生理信号的复杂度, 对于较短的数据可得稳定的 RCMSE 值, 其抗噪能力强, 为睡眠分期提供了良好的输入参数来源. 总体的分类器框架基于多层次 SVM 分类展开, 根据 RCMSE 的变化曲线对分类器层次进行设置, 所得睡眠分期的准确率达到 85.3%, 从而验证了所提算法对睡眠分期的可行性和有效性.

然而, 在本文的研究中, 仅选用 EEG 信号以及 EOG 信号作为评价标准, 其分类准确率有待于进一步提高. 研究表明, 在不同的睡眠状态下, 周期性的腿动信号与翻身信号有明显的差异. 其中, 腿动信号的相对频率、持续时间和引起醒觉的效应都随着睡眠的加深而逐渐下降, 而腿动间隔时间将随之增加, 这对于判别睡眠阶段有所帮助. 因此, 下一步将研究受试者的体动信号, 以获取体动能值, 并利用多信息融合技术分析受试者的睡眠阶段.

## 参考文献:

[1] MAHOWALD M W, SCHENCK C H. Insights

- from studying human sleep disorders [J]. **Nature**, 2005, 437: 1279-1285.
- [2] HIRSHKOWITZ M. COMMENTARY—Standing on the shoulders of giants: The standardized sleep manual after 30 years [J]. **Sleep Medicine Reviews**, 2000, 4(2): 169-179.
- [3] 王菡侨. 有关美国睡眠医学学会睡眠分期的最新判读标准指南解析[J]. **诊断学理论与实践**, 2009, 8(6): 575-578.
- WANG Hanqiao. Analysis of the latest interpretation standards for sleep staging of the american academy of sleep medicine [J]. **Diagnostics Theory and Practice**, 2009, 8(6): 575-578.
- [4] 戴冷湜. 脑电信号的特征提取与分析方法研究[D]. 杭州: 浙江大学, 2011: 21-23.
- DAI Lengshi. Research on feature extraction and analysis methods of EEG signals [D]. Hangzhou: Zhejiang University, 2011: 21-23.
- [5] COSTA M, GOLDBERGER A, PENG C K. Multi-scale entropy analysis of biological signal [J]. **Physical Review E, Statistical, Nonlinear, and Soft Matter Physics**, 2005, 71(2): 021906.
- [6] FLEXER A, GRUBER G, DORFFNER G. A reliable probabilistic sleep stager based on a single EEG signal [J]. **Artificial Intelligence in Medicine**, 2005, 33(3): 199-207.
- [7] 李谷, 范影乐, 李轶, 等. 基于脑电信号 Hilbert-Huang 变换的睡眠分期研究 [J]. **航天医学与医学工程**, 2007, 20(6): 458-463.
- LI Gu, FAN Yingle, LI Yi, *et al.* Sleep staging based on EEG signal Hilbert-Huang transform [J]. **Space Medicine and Medical Engineering**, 2007, 20(6): 458-463.
- [8] SOUSA T, CRUZ A, KHALIGHI S, *et al.* A two-step automatic sleep stage classification method with dubious range detection [J]. **Computers in Biology and Medicine**, 2015, 59: 42-53.
- [9] KEMP B, ZWINDERMAN A H, TUK B, *et al.* Analysis of a sleep-dependent neuronal feedback loop: The slow-wave microcontinuity of the EEG [J]. **IEEE Transactions on Biomedical Engineering**, 2000, 47(9): 1185-1194.
- [10] SHI J, LIU X, LI Y, *et al.* Multi-channel EEG-based sleep stage classification with joint collaborative representation and multiple kernel learning [J]. **Journal of Neuroscience Methods**, 2015, 254: 94-101.
- [11] 袁琦, 周卫东, 李淑芳, 等. 基于 ELM 和近似熵的脑电信号检测方法 [J]. **仪器仪表学报**, 2012, 33(3): 514-519.
- YUAN Qi, ZHOU Weidong, LI Shufang, *et al.* EEG signal detection method based on ELM and approximate entropy [J]. **Chinese Journal of Scientific Instrument**, 2012, 33(3): 514-519.
- [12] WU S D, WU C W, LIN S G, *et al.* Analysis of complex time series using refined composite multi-scale entropy [J]. **Physics Letters A**, 2014, 378(20): 1369-1374.
- [13] 张涛, 陈万忠, 李明阳. 基于频率切片小波变换和支持向量机的癫痫脑电信号自动检测 [J]. **物理学报**, 2016, 65(3): 038703-1-7.
- ZHANG Tao, CHEN Wanzhong, LI Mingyang. Automatic detection of epileptic EEG signals based on frequency slice wavelet transform and support vector machine [J]. **Acta Physica Sinica**, 2016, 65(3): 038703-1-7.
- [14] BERRY R B, BROOKS R, GAMALDO C E, *et al.* The AASM manual for the scoring of sleep and associated events: Rules, terminology and technical specifications [S/OL]. Darien, Illinois, USA: American Academy of Sleep Medicine, 2012: 16-56 [2017-07-10]. <http://aasm.org/resources/pdf/scoring-manual-preface.pdf>.
- [15] RODRÍGUEZ-SOTELO J, OSORIO-FORERO A, JIMÉNEZ-RODRÍGUEZ A, *et al.* Automatic sleep stages classification using EEG entropy features and unsupervised pattern analysis techniques [J]. **Entropy**, 2014, 16(12): 6573-6589.
- [16] RONZHINA M, JANOUŠEK O, KOLÁŘOVÁ J, *et al.* Sleep scoring using artificial neural networks [J]. **Sleep Medicine Reviews**, 2012, 16(3): 251-263.
- [17] JO H G, PARK J Y, LEE C K, *et al.* Genetic fuzzy classifier for sleep stage identification [J]. **Computers in Biology and Medicine**, 2010, 40(7): 629-634.
- [18] HSU Y L, YANG Y T, WANG J S, *et al.* Automatic sleep stage recurrent neural classifier using energy features of EEG signals [J]. **Neurocomputing**, 2013, 104: 105-114.
- [19] HASSAN A R, BASHAR S K, BHUIYAN M I H. On the classification of sleep states by means of statistical and spectral features from single channel electroencephalogram [C] // **International Conference on Advances in Computing, Communications and Informatics (ICACCI)**. Kochi, India: IEEE, 2015: 2238-2243.

(本文编辑:何雪)