

基于脑电非线性特征和 AdaBoost 算法的诱导期麻醉深度检测

汤卫雄^{1,2}, 程云章¹, 张天逸¹, 宋金超²

1. 上海理工大学健康科学与工程学院, 上海 200093; 2. 上海理工大学附属市东医院麻醉科, 上海 200082

【摘要】提出一种结合自适应增强学习 AdaBoost 算法和脑电非线性特征的麻醉深度评估方法,通过提取脑电信号中的4种非线性特征(KC复杂度、小波熵、排序熵、模糊熵)作为输入,以双谱指数作为参考输出,将诱导期麻醉深度分为清醒、轻度麻醉、中度麻醉。使用9例全麻患者的诱导期脑电信号对该方法进行评估,3种不同麻醉状态分类准确率为86.69%, Kappa系数为0.837,表明该方法可以较好地地区分诱导期3种不同麻醉水平,为麻醉深度监测提供新思路。

【关键词】麻醉深度;诱导期;脑电信号;非线性特征;AdaBoost 算法

【中图分类号】R318;R614

【文献标志码】A

【文章编号】1005-202X(2023)05-0616-06

Monitoring depth of anesthesia during induction using EEG nonlinear characteristics combined with AdaBoost algorithm

TANG Weixiong^{1,2}, CHENG Yunzhang¹, ZHANG Tianyi¹, SONG Jinchao²

1. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Department of Anesthesiology, Shidong Hospital Affiliated to University of Shanghai for Science and Technology, Shanghai 200082, China

Abstract: A method that combines adaptive boosting (AdaBoost) algorithm with nonlinear characteristics of electroencephalogram (EEG) is proposed to estimate the depth of anesthesia. With 4 nonlinear features (KC complexity, wavelet entropy, permutation entropy and fuzzy entropy) extracted from EEG signals as input and bispectral index as reference output, the depth of anesthesia during the induction is divided into awake, mild anesthesia and moderate anesthesia. The proposed method is evaluated using the EEG signals of 9 patients during the induction of general anesthesia, and the results show that the method achieves an accuracy of 86.69% in classifying 3 different anesthetic states, with a Kappa coefficient of 0.837. The proposed method can better distinguish the depth of anesthesia during the induction, which provides a new idea for monitoring the depth of anesthesia.

Keywords: depth of anesthesia; induction period; electroencephalogram signal; nonlinear characteristic; AdaBoost algorithm

前言

全身麻醉诱导是指患者在麻醉药物的作用下,全身的感觉受到可逆性抑制,最终达到可以进行手术状态的过程^[1]。全麻药物会使机体的免疫功能降低,使机体失去对伤害性刺激的保护反射,容易引起并发症,因此全麻诱导的风险很大^[2]。合适的麻醉诱导是麻醉过程中极为重要的一个环节,也是维持患者生命体征的重要保证。有研究表明全麻药物可以

影响大脑脑电(Electroencephalogram, EEG)活动,麻醉过程与 EEG 活动有直接的生理学相关性,因此研究麻醉时的 EEG 信号是确定麻醉深度的有效方法之一^[3]。

临床上,麻醉医生通常以患者的生理特征如血压、呼吸、心率等作为确定麻醉深度的依据,该方法对麻醉医生要求较高,有一定的局限性。麻醉深度监测仪是专门用来监测患者麻醉深度的仪器,目前应用最为广泛的麻醉深度监测仪是美国 Aspect 公司研发的双谱指数(Bispectral Index, BIS),BIS 被认为是商业化麻醉深度监测仪中敏感度和特异性最好的麻醉深度监测仪之一^[4],是评价麻醉深度的可靠标准之一。国内引进 BIS 等麻醉深度监测仪器价格极其昂贵,最主要的原因是 BIS 算法的垄断,因此研究麻醉深度监测算法对国内麻醉深度监测仪的发展具有重要意义。

【收稿日期】2022-12-15

【基金项目】上海市杨浦区科委/卫健委科研面上项目(YPM202105);上海工程技术研究中心资助项目(18DZ2250900)

【作者简介】汤卫雄,硕士,研究方向:生物电信号处理、数据分析, E-mail: 18460305619@163.com

【通信作者】宋金超,主任医师,教授,硕士生导师, E-mail: sjch2013@163.com

基于 EEG 的麻醉深度研究方法包括时域分析法、频域分析法、时频域分析法和非线性动力学法。时域分析法主要表现形态学特征,可以观察到皮层觉醒等明显的 EEG 活动;频域分析法以傅里叶变换为基础,关注的是边缘频率等频域信息;时频域分析法结合时域和频域分析的优点,主要有小波变换^[5-6]、希尔伯特-黄变换^[7]、短时傅里叶变换^[8]等。大脑是一个复杂的非线性动力学系统,熵值和复杂度是用非线性模型反映系统复杂性的 EEG 监测指标^[9]。熵是一个物理概念,用于描述信息的混乱程度,信息越混乱,熵值越大。随着麻醉深度逐渐增加,从意识清晰到意识消失,大脑的生物电活动的混乱程度逐渐降低,熵值降低^[10]。用于评估麻醉深度的 EEG 非线性特征主要包括 KC 复杂度^[11-12]、近似熵^[11-12]、样本熵^[13-14]、小波熵^[5,11,13]、排序熵^[15-16]等。

本研究提取了麻醉诱导期 EEG 信号的 4 种非线性特征(KC 复杂度、小波熵、排序熵、模糊熵),利用参数建立 AdaBoost 分类模型。为了提高非线性特征的可靠性,本研究还提取了时域特征平均幅值(Aa)和频域特征边缘频率(SEF95)作为对比,最终提出一种基于 EEG 非线性特征的麻醉深度评估方法。

1 数据与方法

1.1 数据获取

本实验采集了 9 例全麻诱导期患者的 BIS 值以及 EEG 信号,数据均来源于上海理工大学附属市东医院麻醉科,并已获得医院伦理委员会同意。使用

美国 Covidien 公司制造的 BIS 模块采集患者的 BIS 值,模块接入迈瑞 BeneVision N15 监护仪。使用上海诺诚公司生产的单通道 EEG 采集装置采集患者的 EEG 信号,采样频率为 256 Hz,滤波器模式设置为高通 0.5 Hz,低通 80 Hz,带阻 50 Hz。9 例全麻手术患者年龄为 37~86 岁,身高 150~177 cm,体质量 42~90 kg,男女比例 5:4。麻醉药物选用丙泊酚、镇静药物右美托咪定、镇痛药舒芬太尼、肌松药罗库溴铵等,麻醉方式为静吸麻醉方式。

1.2 EEG 信号预处理

EEG 在采集过程中会掺杂包括肌电、眼电、工频、基线漂移等干扰,所以需要 EEG 信号进行预处理去除干扰。通过 EEG 采集装置自带的数字滤波后,获取 0.5~80.0 Hz 并滤除工频干扰 50 Hz 的 EEG 信号。针对不同噪声干扰应根据噪声的特点采用不同方法去除。对于采集到的 EEG 进行以下预处理:(1)手动去除异常 EEG 信号,根据信号的统计特征确定阈值,采用阈值法去除异常信号^[7]。(2)基线漂移一般是由于患者移动导致电极片位置的移动而造成的低频干扰,一般频率低于 1 Hz,采用经验模态分解滤除低频的干扰信号^[17]。(3)眼电信号幅值一般是 EEG 信号的 10 倍以上,频率一般在 20 Hz 以下,采用小波阈值方法去除^[5]。(4)肌电信号频率与 EEG 信号频率重叠较多,通常表现为高频瞬态大幅度,采用逆滤波器检测法去除 EMG 信号和其他高幅度噪声^[15]。未处理和预处理后的脑电信号片段对比如图 1 所示,经过以上预处理操作后,脑电信号中的噪声大幅度降低。




图1 30 s未处理EEG信号以及预处理后的EEG信号
Figure 1 30 s unprocessed EEG signal and preprocessed EEG signal

1.3 EEG 信号分段

EEG 采集装置记录了 9 例全身麻醉手术患者诱导期 EEG 片段。诱导期是指患者由清醒状态进入可以手术操作的过程,诱导时长为患者从清醒到手术开始时的时间差。9 例患者共计约 260 min 的 EEG 信号经过上述预处理之后进行分段操作,分段步长为

5 s,大小为 30 s,最终得到 EEG 信号片段 2 428 段。根据 BIS 值将分段后 EEG 片段分为清醒期 I (80≤BIS≤100)、轻度麻醉期 II (60≤BIS<80)、中度麻醉期 III (40≤BIS<60)。由于本实验研究的对象为诱导期(由清醒到手术开始)相关 EEG,因此不适用于深度麻醉 (0≤BIS<40)。

1.4 特征提取

EEG在不同的麻醉深度表现为不同的混乱程度,复杂度表现为不同的特点^[18]。随着麻醉深度的加深,复杂度呈现单调下降趋势,并在清醒转为麻醉时变化最大。为了更好地量化EEG信号随麻醉深度的变化,本实验提取KC复杂度、小波熵、排序熵、模糊熵这4种EEG非线性特征,以及时域特征Aa和频域特征SEF95共6种特征参数。从图2可以看出随着

麻醉深度的加深,KC复杂度、小波熵、排序熵、模糊熵等非线性特征也随之不同程度地减小,其中排序熵相比KC复杂度、小波熵、模糊熵可以更好地区分不同的麻醉深度。随着麻醉深度加深,EEG信号频率由高频向低频转移,频域特征SEF95也随之降低。时域特征Aa也会随麻醉深度加深而降低,但其变化趋势不明显。




图2 6种EEG参数在3种麻醉状态下的箱线图

Figure 2 Box graphs of 6 EEG parameters under 3 anesthesia conditions

1.4.1 Aa 在不同的麻醉深度下,EEG表现为不同的频率和幅值。Aa是用来衡量一段信号幅值的大小,Aa计算见式(1):

$$Aa = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (1)$$

其中, N 为信号 X 的长度。

1.4.2 SEF95 SEF95是低于95%频谱功率的频率,积分区间为0.5~80.0,在预处理时对EEG信号进行0.5~80.0 Hz高低通滤波。有研究表明SEF95可以较好地区分麻醉状态和清醒状态^[19]。SEF95满足式(2):

$$\frac{\sum_{f_i=0.5}^{SEF95} |X(f)|^2}{\sum_{f_i=0.5}^{80} |X(f)|^2} = 0.95 \quad (2)$$

1.4.3 KC复杂度 KC复杂度算法可以表示一段时间序列随长度的增加出现新模式的速率,表现序列接近随机的程度^[20]。对于完全随机时间序列,复杂度趋近于1,对于有规律的周期运动,复杂度趋于0。KC复杂度算法计算简单,实时性好,已被应用于对EEG信号的分析,并取得了较好的效果^[21]。

KC复杂度算法步骤如下:(1)对含有 n 个时间序列的EEG信号进行粗粒化处理。(2)将粗粒化后的时间序列分解为 $d(n)$ 个不同的子串,当 n 趋于无穷时, $d(n)$ 会趋于一个定值。(3)归一化处理得到复杂度 $C(n)$ 。

$$C(n) = \frac{d(n) * \log 2n}{n} \quad (3)$$

1.4.4 小波熵 小波熵算法是结合小波变换与信息熵

理论的一种非线性方法。小波熵从谱能量的角度分析信号的有序性和无序性,对时间序列的非线性特征有很好的表达,是处理EEG等非线性电生理信号的重要研究方法之一^[22]。

小波熵算法步骤如下:(1)对EEG时间序列进行二进制正交小波变换。(2)小波重构。第 i 个子小波的能量谱记为 $E(i)$,各个重构后子小波的能量比记为 $P(i)$,小波分解层数为 n 。(3)计算时间序列的小波熵WEp。其中, $P(i)$ 及WEp的计算公式如下:

$$P(i) = \frac{E(i)}{\sum_{j=1}^n E(j)} \quad (4)$$

$$WEp = -\sum P(i) * \ln(P(i)) \quad (5)$$

1.4.5 排序熵 排序熵用于衡量时间序列的复杂度,在重构子序列时引入排列的思想。排序熵可以检测突变的时刻,具有对信号的微小变化灵敏度较高的特点,是生物医学电信号的重要研究方法之一,已成功用于EEG信号的研究^[23-24]。

排序熵算法计算步骤如下:(1)引入嵌入维度 m 、时间延迟 t ,对长度为 N 的时间序列 $X(i)$ 进行重构得到 $Y(i)$ 。(2)对每个 $Y(i)$ 内部进行递增排序,将 m 维子序列映射到 $m!$ 种排列中。(3)记所有符号概率分布为 $P_1, P_2, \dots, P_K, K \leq m!$ 。(4)计算时间序列的排序熵PE。

$$PE = \frac{-\sum_{j=1}^K P_j * \ln(P_j)}{\ln(m!)} \quad (6)$$

1.4.6 模糊熵 模糊熵是在样本熵的基础上引入指数

函数模糊化相似性度量公式,使得模糊熵值能随参数变化过渡平滑,克服样本熵计算量大的缺点,同时也保留样本熵不依赖于数据长度的优点^[25]。

模糊熵算法计算步骤如下:(1)引入嵌入维数为 m ,对长度为 N 的时间序列 $X(i)$ 进行相空间重构得到 $Y(i)$ 。(2)引入模糊隶属函数计算时间序列 $Y(i)$ 、 $Y(j)$ 的相似度 D_{ij}^m 。(3)计算时间序列的模糊熵FuzzyEn(m, r, N)。本实验取经典值 $m=3, r=0.15*\text{std}(X)$ 。

$$D_{ij}^m = \exp[-\ln(2)*(d_{ij}^m/r)^2] \quad (7)$$

其中, d_{ij}^m 是 $Y(i)$ 、 $Y(j)$ 的最大绝对距离, r 为相似容限度。

$$\Psi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \frac{1}{N-m} \sum_{j=1, j \neq i}^{N-m+1} D_{ij}^m \quad (8)$$

$$\text{FuzzyEn}(m, r, N) = \ln \Psi^m(r) - \ln \Psi^{m+1}(r) \quad (9)$$

1.5 AdaBoost算法与BP神经网络

1.5.1 AdaBoost算法 AdaBoost是一种自适应增强集成学习算法,它的基本思想是通过若干个预测精度差的弱学习器增强学习为预测精度高的强学习器。前一个基本分类器会把分错的样本进行增强,而分对的样本保持不变,然后再对新的全体样本训练得到下一个分类器,并且每次都会加入一个新的弱分类器,直至到达预定的准确度或者指定的迭代次数后停止训练,最终得到一个分类精度高的强分类器^[26]。

AdaBoost算法流程如图3所示。步骤如下:(1)对训练数据权值进行初始化, m 为迭代次数, $W_{i,j}$ 指第 i 次迭代第 j 个样本的权重,设 N 个样本,每个样本初始赋予相同的权值 $1/N$ 。(2)训练弱分类器,计算系数 α_m ,表示分类器的重要程度,分类误差率 e_m 为误分样本的权值之和。(3)更新权值, Z_m 为规范因子,使得 D_{m+1} 为概率分布。 $G_m(x_i)$ 表示第 m 次迭代的第 i 个样本的预测值, y_i 表示真实值。(4)组合各个弱分类器得到强分类器 $f(x)$ 。

$$D_{m+1} = (W_{m+1,1}, W_{m+1,2}, \dots, W_{m+1,N}) \quad (10)$$

$$\alpha_m = \frac{1}{2} \log\left(\frac{1-e_m}{e_m}\right) \quad (11)$$

$$W_{m+1,i} = \frac{W_{m,i}}{Z_m} * \exp(-\alpha_m * y_i * G_m(x_i)) \quad (12)$$

$$f(x) = \text{sign}\left(\sum_{m=1}^M \alpha_m * G_m(x)\right) \quad (13)$$

1.5.2 BP神经网络 BP神经网络即误差反向传播神经网络,是一种多层单向前馈神经网络模型。BP神经网络是最常用的ANN模型之一,它主要由输入层、隐含层、输出层组成。模型训练过程主要包括前向信号传播和反向误差传播,主要目的是寻找一组最优参数,使得网络模型的误差最小。本实验采用的4层BP神经网络模型如图4所示,输入层有4个节点,

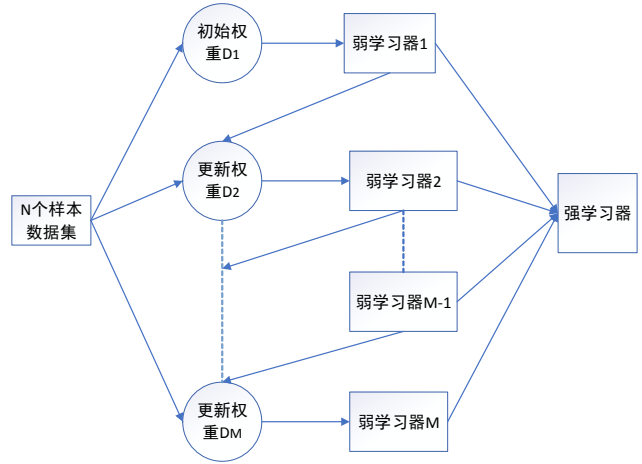


图3 AdaBoost算法流程图

Figure 3 AdaBoost algorithm flowchart

第一个隐含层有4个节点,第二个隐含层有10个节点,输出层有3个节点,网络中所有神经元单元的激活函数都是“tansig”函数,本研究的BP神经网络模型在软件MATLAB上完成建立。




图4 4层BP神经网络模型

Figure 4 Four-layer BP neural network model

2 实验结果与分析

本次实验将2428个样本随机划分为训练集和测试集,比例为7:3,最终得到1699段训练集,729段测试集。对于预测结果采用准确度和灵敏度来进行评价。准确度(ACC)是指预测正确的样本数占总样本的比例,灵敏度(TPR)是指正确预测为一种麻醉状态占所有预测为该麻醉状态的比例。

$$\text{ACC} = \frac{N_{\text{right}}}{N_{\text{total}}} \quad (14)$$

$$TPR = \frac{TP_i}{TP_i + FN_i}$$

(15)

其中, N_{right} 为所有预测正确的样本数, N_{total} 为总样本数, i 代表 3 种麻醉状态 (清醒、浅麻醉、中麻醉), TP_i 为正确预测 i 的样本数, FN_i 为其他麻醉状态错误预测为 i 的所有样本数。

为了减小不同麻醉状态样本数不同带来的影响,同时采用 Kappa 系数来评估模型的分类性能。

$$k = \frac{p_0 - p_e}{1 - p_e}$$

(16)

$$p_e = \frac{a_1 * b_1 + a_2 * b_2 + \dots + a_c * b_c}{n * n}$$

(17)

其中, p_0 为准确度, a_i 、 b_i 分别表示第 i 类真实样本数和预测为第 i 类样本数, c 为类别数, n 为样本总数。

本实验通过提取 EEG 信号的 4 种非线性特征 (KC 复杂度、小波熵、排序熵、模糊熵) 来对麻醉深度进行预测,并和 Aa 和 SEF95 进行对比,BIS 作为参考输出,麻醉深度分为清醒、轻度麻醉、中度麻醉。AdaBoost 模型在测试集上分类结果如表 1 所示,AdaBoost 模型和 BP 神经网络模型分类结果对比如表 2 所示,不同特征组合方法在 AdaBoost 分类模型下的分类准确度如表 3 所示。

表 1 AdaBoost 模型在测试集上分类结果

Table 1 Classification results of AdaBoost model on the test set

真实	预测		
	清醒	轻度麻醉	中度麻醉
清醒	194	10	4
轻度麻醉	11	224	32
中度麻醉	6	34	214

表 3 不同特征组合在 AdaBoost 模型下分类准确度 (%)

Table 3 Classification accuracy of different feature combinations in AdaBoost model (%)

特征组合	分类准确度	特征组合	分类准确度
SEF95+WE+PE+FE	86.07	Aa+WE+PE+FE	82.85
KC+SEF95+PE+FE	80.21	KC+Aa+PE+FE	83.17
KC+WE+SEF95+FE	78.60	KC+WE+Aa+FE	82.44
KC+WE+PE+SEF95	79.83	KC+WE+PE+Aa	85.18
KC+WE+PE+FE+SEF95	85.59	KC+WE+PE+FE+Aa	86.30
KC+WE+PE+FE+SEF95+Aa	86.03	KC+WE+PE+FE	86.69

等^[27]提出基于样本熵结合随机森林模型来评估麻醉深度,结果模型输出准确度为 88%。袁思念等^[5]、余陈佑等^[28]结合非线性特征和多种时频域特征预测麻醉深度准确度分别达到 85.98% 和 82.3%。

表 2 AdaBoost、BP 神经网络方法对麻醉深度的预测结果 (%)

Table 2 Prediction results of anesthesia depth using AdaBoost or

BP neural network (%)

模型	灵敏度			总分类准确度
	清醒	轻度麻醉	中度麻醉	
AdaBoost	91.94	83.58	85.60	86.69
BP 神经网络	85.04	79.63	84.83	82.83

由表 1 可知,AdaBoost 模型对于不同的麻醉分期均可以较为准确地做出预测。由表 2 可知,在不同的模型 (AdaBoost 和 BP 神经网络) 下分类准确度均高于 80%,AdaBoost 的分类准确度和不同麻醉状态灵敏度都高于 BP 神经网络模型。由表 3 可见,以 EEG 的 4 种非线性特征 (KC 复杂度、小波熵、排序熵、模糊熵) 预测麻醉深度的准确度达到最大 (86.69%), Kappa 系数为 0.837,表明模型预测值和真实值存在高度一致性。而将 Aa、SEF95 替换或者加入到非线性特征时,分类准确度均低于 4 种非线性特征组合时,表明非线性特征在本实验优于 Aa 和 SEF95。结果表明以 EEG 的 4 种非线性特征作为预测麻醉深度是可靠的,且在本实验中 AdaBoost 模型优于 BP 神经网络模型。

3 结 论

通过提取患者的 EEG 信号特征结合机器学习来预测麻醉深度是近年来较为普遍和实用的方法。其中非线性特征是应用最为广泛的特征之一,Li 等^[16]使用排序熵结合线性回归模型的方法进行麻醉深度的评估,输出和 BIS 的皮尔逊相关系数为 0.73。Liu

在过去的这些研究中,有些研究者只利用一种非线性特征或者非线性特征结合多种其他特征评估麻醉深度,前者单一指标可靠性较低,后者参数多不利于计算。本研究提出一种基于 4 种 EEG 非线性特

征(KC复杂度、小波熵、排序熵、模糊熵)作为特征参数结合AdaBoost自适应增强学习算法的方法来评估麻醉深度。该方法可以较好地地区分清醒、轻度麻醉和中度麻醉,且分类准确度达到86.69%。实验结果表明该方法对于麻醉深度的监测是可行的,这为麻醉深度的监测提供了新方法。后续的工作将增加数据样本量,验证和提高模型的性能,还将尝试引入身体质量指数作为特征加入到模型中以减少实验中个体差异性的影响。

【参考文献】

- [1] 郭曲练,姚尚龙. 麻醉学[M]. 4版. 北京:人民卫生出版社,2018: 59-63.
Guo QL, Yao SL. Anesthesiology[M]. 4th Edition. Beijing: People's Health Publishing House, 2018: 59-63.
- [2] 贾娜,张昊鹏,文爱东,等. 临床麻醉深度监测方法的新进展[J]. 临床麻醉学杂志, 2015, 31(9): 922-925.
Jia N, Zhang HP, Wen AD, et al. Clinical anesthesia depth monitoring new progress of methods[J]. Journal of Clinical Anesthesiology, 2015, 31(9): 922-925.
- [3] Al-Kadi M, Reaz M, Ali M. Evolution of electroencephalogram signal analysis techniques during anesthesia[J]. Sensors, 2013, 13(5): 6605-6635.
- [4] 干朝晖,张立群. 脑电双频指数与严重颅脑外伤程度的相关性及其预后分析[J]. 中国现代医生, 2011, 49(22): 22-23.
Gan CH, Zhang LQ. Correlation and prognosis analysis between bispectral index of EEG and severity of severe craniocerebral injury[J]. China Modern Doctor, 2011, 49(22): 22-23.
- [5] 袁思念,叶继伦,张旭,等. 基于小波变换与人工神经网络的麻醉深度计算方法研究[J]. 生物医学工程学杂志, 2021, 38(5): 838-847.
Yuan SN, Ye JL, Zhang X, et al. Research on the calculation method of anesthesia depth based on wavelet transform and artificial neural network[J]. Journal of Biomedical Engineering, 2021, 38(5): 838-847.
- [6] Tai NK, Wen P, Yan L, et al. Measuring the hypnotic depth of anaesthesia based on the EEG signal using combined wavelet transform, eigenvector and normalisation techniques[J]. Comput Biol Med, 2012, 42(6): 680-691.
- [7] 李小熊,崔素媛, Sleigh JW. 基于希尔伯特熵的麻醉深度估计[J]. 中国生物医学工程学报, 2008, 27(5): 689-694.
Li XL, Cui SY, Sleigh JW. Estimation of anesthesia depth based on Hilbert entropy[J]. Chinese Journal of Biomedical Engineering, 2008, 27(5): 689-694.
- [8] Wang Z, Cao L, Zhang Z, et al. Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition[J]. Concurr Comput, 2018, 30(23): 1-9.
- [9] 胡江,郭曲练. 熵指数在麻醉监测中的应用[J]. 实用医学杂志, 2014, 30(10): 1517-1518.
Hu J, Guo QL. Application of entropy index in anesthesia monitoring[J]. Journal of Practical Medicine, 2014, 30(10): 1517-1518.
- [10] Liang Z, Wang Y, Sun X, et al. EEG entropy measures in anesthesia[J]. Front Comput Neurosci, 2015, 9: 16.
- [11] 王锋,李晓欧. 基于脑电信号的麻醉特征参数分析[J]. 生物医学工程学杂志, 2015, 32(1): 13-18.
Wang F, Li XO. Analysis of anesthesia characteristic parameters based on EEG signal[J]. Journal of Biomedical Engineering, 2015, 32(1): 13-18.
- [12] 王胜军,郭云波,杨俊,等. 复杂度、近似熵应用于麻醉深度监测中的实验研究[J]. 医疗卫生装备, 2010, 31(1): 19-20.
Wang SJ, Guo YB, Yang J, et al. Experimental study on the application of complexity and approximate entropy in monitoring the depth of anesthesia[J]. Chinese Medical Equipment Journal, 2010, 31(1): 19-20.
- [13] 丁正敏,熊冬生,陈宇珂,等. 基于脑电样本熵和小波熵的麻醉深度监测[J]. 中国医学物理学杂志, 2018, 35(2): 243-248.
Ding ZM, Xiong DS, Chen YK, et al. Anesthesia depth monitoring based on EEG sample entropy and wavelet entropy[J]. Chinese Journal of Medical Physics, 2018, 35(2): 243-248.
- [14] 刘军,周雅琪,陈绍宾,等. 基于样本熵与决策树的麻醉意识深度评价指数的研究[J]. 生物医学工程学杂志, 2015, 32(2): 192-197.
Liu J, Zhou YQ, Chen SB, et al. Study on the depth evaluation index of anesthesia consciousness based on sample entropy and decision tree[J]. Journal of Biomedical Engineering, 2015, 32(2): 192-197.
- [15] Gu Y, Liang Z, Hagihira S. Use of multiple EEG features and artificial neural network to monitor the depth of anesthesia[J]. Sensors, 2019, 19(11): 2499.
- [16] Li TN, Sivakumar P, Tao XH. Anesthesia assessment based on ICA permutation entropy analysis of two-channel EEG signals[J]. Lecture Notes in Artificial Intelligence, 2019, 11976: 244-253.
- [17] 朱富贵. 基于脑电信号的麻醉深度监测方法研究[D]. 重庆:重庆大学, 2019.
Zhu FG. Study on anesthesia depth monitoring method based on EEG signal[D]. Chongqing: Chongqing University, 2019.
- [18] 封洲燕,郑筱祥. 不同麻醉深度下大鼠脑电复杂度与功率谱的变化过程[J]. 中国生物医学工程学报, 2004, 23(1): 87-91.
Feng ZY, Zheng XX. The change process of EEG complexity and power spectrum in rats under different anesthesia depths[J]. Chinese Journal of Biomedical Engineering, 2004, 23(1): 87-91.
- [19] Schwender D, Daunderer M, Mulzer S, et al. Spectral edge frequency of the electroencephalogram to monitor depth of anaesthesia with isoflurane or propofol[J]. Br J Anaesth, 1996, 77(2): 179-184.
- [20] 陈晓平,和卫星,温军玲. 基于脑电波复杂度的麻醉深度监测[J]. 江苏大学学报(自然科学版), 2003, 24(6): 73-75.
Chen XP, He WX, Wen JL. Anesthesia depth monitoring based on EEG complexity[J]. Journal of Jiangsu University (Natural Science Edition), 2003, 24(6): 73-75.
- [21] Zhang LY, Zheng CX. Lempel-Ziv complexity changes and physiological mental fatigue level during different mental fatigue state with spontaneous EEG[J]. Health, 2009, 1(1): 35-38.
- [22] Benzy VK, Jasmin EA, Koshy RC, et al. Wavelet entropy as a measure of depth of anaesthesia[C]. 2016 3rd International Conference on Signal Processing and Integrated Networks (SPIN). IEEE, 2016.
- [23] Bandt C, Pompe B. Permutation entropy: a natural complexity measure for time series[J]. Phys Rev Lett, 2002, 88(17): 174102.
- [24] Nicolaou N, Georgiou J. Detection of epileptic electroencephalogram based on permutation entropy and support vector machines[J]. Expert Syst Appl, 2012, 39(1): 202-209.
- [25] 刘慧,谢洪波,和卫星,等. 基于模糊熵的脑电睡眠分期特征提取与分类[J]. 数据采集与处理, 2010, 25(4): 484-489.
Liu H, Xie HB, He WX, et al. Feature extraction and classification of EEG sleep stages based on fuzzy entropy[J]. Data Acquisition and Processing, 2010, 25(4): 484-489.
- [26] 曹莹,苗启广,刘家辰,等. AdaBoost算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
Cao Y, Miao QG, Liu JC, et al. Research progress and prospect of AdaBoost algorithm[J]. Journal of Automation, 2013, 39(6): 745-758.
- [27] Liu Q, Ma L, Fan SZ, et al. Sample entropy analysis for the estimating depth of anaesthesia through human EEG signal at different levels of unconsciousness during surgeries[J]. Peer J, 2018, 6: e4817.
- [28] 余陈佑,程云章. 基于多域脑电参数分析的麻醉深度评估[J]. 中国医学物理学杂志, 2022, 39(7): 907-912.
Yu CY, Cheng YZ. Anesthesia depth assessment based on multi domain EEG parameter analysis[J]. Chinese Journal of Medical Physics, 2022, 39(7): 907-912.

(编辑:谭斯允)