

文章编号:1004-9037(2013)05-0664-08

MF-DFA 在癫痫发作期及发作强度检测中的应用

张 翔^{1,2} 丁 勇¹ 刘小峰^{1,2}

(1. 河海大学物联网工程学院,常州,213022;

2. 河海大学-法国 Alderbaran Robotics 认知与机器人实验室,常州,213022)

摘要: 癫痫患者的脑电特征是临床诊断、分类和预报癫痫的重要依据。作为测度时间序列内在模式变化的近似熵和样本熵成为一种临床癫痫分类和发作预报的重要方法,由于受到序列长度、嵌入维数以及阈值设置的影响,难以准确检测序列内模式突变的时刻。为准确检测脑电癫痫样放电时刻及其强度,提出了一种癫痫发作及强度检测的多分形去趋势波动分析方法(MF-DFA),并与基于样本熵的癫痫放电检测作进一步比较分析。采用头皮表面脑电与颅内脑电临床数据做测试实验,结果表明:MF-DFA 能够精确捕捉到发作时刻,并能够定量刻画癫痫发作强度。

关键词: 癫痫检测;样本熵;发作起始时刻;发作强度;多重分形去趋势波动分析

中图分类号:R318

文献标志码:A

Detection of Seizure Timecourse and Index of Seizure Intensity with Multifractal Detrended Fluctuation Analysis

Zhang Xiang^{1,2}, Ding Yong¹, Liu Xiaofeng^{1,2}

(1. School of IoT Engineering, Hohai University, Changzhou, 213022, China;

2. Hohai University-Alderbaran Robotics Laboratory for Cognition and Robotic, Hohai University, Changzhou, 213022, China)

Abstract: EEG features of epilepsy patients are an important index for the diagnosis and classification of epilepsy, as well as for long-term monitoring and predicting seizures. Both approximate entropy and sample entropy are used to extract features of epilepsy. However, both methods are sensitive to changes in their parameters, e. g. data points, embedding dimension, and tolerance. A new method based on multifractal detrended fluctuation analysis (MF-DFA) is presented, for detecting epileptic seizures and measuring seizure intensity. The performance of the new method is evaluated by either scalp EEG or intracranial EEG (EcoG). Results show that it is capable of accurately capturing the early ictal onset of epileptic seizure and extracting the quantitative description of seizure intensity.

Key words: epileptic detection; sample entropy; early ictal onset; seizure intensity; multifractal detrended fluctuation analysis

引 言

癫痫作为一种常发的中枢神经失调疾病,困扰着全球近百分之十的人口^[1]。癫痫发作是由于脑兴奋与脑抑制活动失衡引起的,是一种神经元突发

性同步神经活动^[2]。脑电(Electroencephalography, EEG)因其具有操作方便和价格低廉的优点,一直被广泛应用于临床诊断、分类和预测癫痫^[3]。临床上长期监测癫痫 EEG,产生的数据量非常大,再加上癫痫发作的多样性,很难凭借医生直观筛查完成癫痫的分类与评价等工作。研究人

基金项目:国家自然科学基金(60905060, 31101643)资助项目;中央高校基础研究(2011B11114, 2012B07314)资助项目;国家大学生创新训练项目(201302941059G)资助项目;国家重大基础研究计划(“九七三”计划)(2010CB327902)资助项目。

收稿日期:2013-06-19; **修订日期:**2013-07-24

员提出了多种基于人工神经网络的自动检测癫痫的方法^[4]。在癫痫自动检测中,EEG 的特征,如关联维数^[5]、李雅普诺夫指数^[6]、熵^[7,8]是检测精度的决定因素。近似熵^[9]或样本熵^[10]能够刻画非线性时间序列的规则程度或随机度^[11],适宜描述时间序列的内在特征变化。近似熵和样本熵具有所需数据点少、抗噪声能力强等特点,近年成为癫痫 EEG 特征提取的常用方法^[12-14]。然而,在计算 EEG 时间序列复杂度的动态变化时,所获取的时变熵(Time-dependent entropy)受到重构子序列长度和模式距离(容限)影响,近似熵或样本熵难以精确捕捉时间序列变化的时刻^[15]。

检测癫痫发作时刻在深入理解癫痫、检测和分类癫痫方面具有重要意义^[16]。去趋势波动分析(Detrended fluctuation analysis, DFA)是一种分析时间序列长程相关的方法,适合分析具有长时记忆的随机非平稳时间序列。基于 DFA 的临床癫痫检测和分类^[17,18]方法具有良好应用效果。Kantelhardt^[19,20]等在 DFA 的基础上提出了多重分形去趋势波动分析方法(Multifractal detrended fluctuation analysis, MF-DFA)。若时间序列中存在动力学结构突变,则其在突变点附近的标度指数剧烈变化;反之,则标度指数变化平缓。本文采用 MF-DFA 来预测癫痫的发作时间和发作强度,选取时变的局部赫斯特(Time evolution local hurst exponent)作为癫痫发作时间的标度指数,选取波动函数值 $F(S)$ 作为发作强度的标度指数。

1 特征提取方法

1.1 样本熵

样本熵是为了降低近似熵(Approximate entropy)的误差,由 Richman 提出的时间序列复杂度测试方法。样本熵具体算法如下: N 点的时间序列 $\{u(j); 1 \leq j \leq N\}$ 重构成 $x_m(i) \{i | 1 \leq i \leq N - m + 1\}$, 其中 $x_m(i) = \{u(i+k); 0 \leq k \leq m-1\}$, m 是重构的向量维数,定义重构的两个向量 $\mathbf{x}(i)$, $\mathbf{x}(j)$ 的距离为

$$d[\mathbf{x}(i), \mathbf{x}(j)] = \max\{|u(i+k) - u(j+k)|\} \quad i \neq j \quad (1)$$

对于给定的阈值 r , 每一个 i 值统计的 $d[\mathbf{x}(i), \mathbf{x}(j)]$ 小于 r 的数目和距离总数 $N - m$ 的比值记作

$$B_i^m(r) = \frac{\text{num}(\{d[\mathbf{x}(i), \mathbf{x}(j)] < r\})}{N - m} \quad 1 \leq i \leq N - m + 1, i \neq j \quad (2)$$

定义函数

$$B^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (3)$$

再将维数加 1, 即重构成 $m + 1$ 维向量, 得到 $B^{m+1}(r)$, 样本熵估计值可以表示为

$$\text{SampEn}(m, r) = -\ln[B^{m+1}(r)/B^m(r)] \quad (4)$$

一般按照经验取 $m=2, r=0.2 \times \text{std}$, std 是原始数据 $x(i)$ 的标准差。为了得到时变的样本熵, 定义滑动窗口

$$W(n; \omega; \Delta) = \{u(i), i = 1 + n\Delta, \dots, \omega + n\Delta\} \quad n = 0, 1, \dots, [N/\Delta] - \omega + 1 \quad (5)$$

式中: Δ 为滑动窗口的步长; ω 是窗口宽度, 即每次需要计算的子序列长度, 且 $1 \leq \omega \leq N$ 。 N 点序列共有 $(N - \omega)/\Delta$ 个窗口。

1.2 MF-DFA 算法

MF-DFA 选取一定长度的子序列, 计算该序列的标度指数(Hurst exponent), 随后逐步移动该序列, 保持子序列长度不变, 直至序列末端。

MF-DFA 算法包括以下 5 个步骤:

(1) 对于 N 点的时间序列 $\{x_N\}$, 构造去均值的和序列

$$Y(i) \equiv \sum_{n=1}^i (x_n - \bar{x}) \quad i = 1, 2, 3, \dots, N \quad (6)$$

式中: \bar{x} 表示序列 $\{x_N\}$ 的均值。

(2) 将 $Y(i)$ 分割成 N_S 个长度为 S 不相交的片段, $N_S = \text{int}(N/S)$, 为了保证划分时不丢失信息, 将 $Y(i)$ 按照 i 从小到大和从大到小划分一次, 得到 $2N_S$ 个片段。

(3) 对每个片段 $n(1 \sim 2N_S)$ 内的 S 个点, 计算去掉局部趋势的均方差。当 $n=1, 2, \dots, N_S$ 时

$$F^2(S, n) = \frac{1}{S} \sum_{i=1}^S \{Y[(n-1)S+i] - y_n^k(i)\}^2 \quad (7)$$

式中 $y_n^k(i)$ 用最小二乘法进行 k 阶多项式拟合

$$y_n^k(i) = a_0 + a_1 i + a_2 i^2 + \dots + a_k i^k \quad i = 1, 2, \dots, S; k = 1, 2, \dots \quad (8)$$

(4) 对于全部片段, 求 $F^2(S, n)$ 均值, 得到 q 阶的波动函数 $F_q(S)$

$$F_q(S) = \left\{ \frac{1}{2N_S} \sum_{n=1}^{2N_S} [F^2(S, n)]^{\frac{q}{2}} \right\}^{\frac{1}{q}} \quad (9)$$

当 $q=0$ 时

$$F_0(S) = \exp \left\{ \frac{1}{4N_S} \sum_{n=1}^{2N_S} \ln [F^2(S, n)] \right\} \quad (10)$$

当 $q=2$ 时, 就退化为 DFA。

(5) 对具有分形的特征信号, 存在片段长度 $S_{\min} < S < S_{\max}$, 给定的 q 阶, $F_q(S) \propto S^{h(q)}$ 成立。

$h(q)$ 称为赫斯特指数,所以此处称为广义赫斯特指数。把 $F_q(S) \propto S^{h(q)}$ 写成 $F_q(S) = AS^{h(q)}$,两边取对数得到

$$\ln F_q(S) = \ln(A) + h(q)\ln(S) \quad (11)$$

在双对数坐标 $(\ln(S), \ln F_q(S))$ 图中,进行线性拟合得到广义赫斯特指数 $h(q)$ 的估计值。计算时,为了保证局部趋势 $Y_n(i)$ 的有效,要求 $S \geq k+2$;为了保证 $F_q(S)$ 的稳定性, $S \leq N/4$ 。广义赫斯特指数 $h(q)$ 便是 MF-DFA 的计算结果。

2 实验测试

2.1 实验数据

实验数据来自波恩大学(Bonn University)和美国波士顿儿童医院的公开癫痫数据。这两组数据作为癫痫测试预报和分类算法的公开数据,为众多研究人员用于测试其算法。

波士顿儿童医院的癫痫数据,包括 22 名癫痫患儿脑电(其中 5 名 3~22 岁男性,17 名 1 岁半~19 岁的女性)。数据采用国际 10-20 导联标准双极导联系统采集,采样频率为 256 Hz,数模转换为 16 bit,标记了数据中癫痫发作起止时间,详细数据描述见文献[21]。

波恩大学(Bonn University)的数据为 5 位健康和 5 位癫痫患者的多种数据,包括健康志愿者在放松并且清醒的状态下睁眼和闭眼的脑电,以及癫痫患者的癫痫发作间期和癫痫发作脑电。数据均采用相同的 128 导放大器采集,采样频率 173.61 Hz,12 位的 A/D 转换,并经频率为 0.53~40 Hz 带通滤波。数据详见文献[22]。

颅内记录的癫痫 EEG 信号具有高信噪比特征,受肌电伪迹干扰比较少。因而,采用了加州理工大学的公开数据^[23]作测试,以与头皮表面记录的 EEG 癫痫检测进行比较。

2.2 癫痫特征提取的样本熵和 MF-DFA 方法比较

以波恩大学的数据作算法测试,分别采用样本熵和 MF-DFA 计算癫痫发作间期与癫痫发作的脑电特征。将伯恩大学的不同数据集,按照对应导联,将发作间期和发作期的实验数据合成一组测试数据,在 23 s 开始进入癫痫期。计算样本熵采用的嵌入维数 $m=2$,阈值 $r=0.2 \times \text{std}$ 。分别比较了数据长度的影响,如图 1 所示。实验结果表明,基于样本熵的 EEG 特征能够区分不同类别的数据。然而,EEG 特征变化的时刻点会因参数(序列长

度)不同而有差异。对同样的数据,采用 MF-DFA 算法计算标度指数(测试使用的阶数 $q=3$),结果表明,在进入癫痫时,标度指数显著下降,受序列长度的影响小于样本熵,如图 2 所示。




图 1 样本熵计算中的序列长度效应




图 2 图 1 中数据不同序列长度的标度指数的 MF-DFA 计算结果

2.3 完整癫痫 EEG 样本熵的癫痫预测

采用波士顿儿童医院的数据,测试基于样本熵的癫痫检测方法。该数据包含癫痫发作前、发作期以及发作结束后的完整过程。计算时,选取参数 $r=0.2 \times \text{std}$,std 是当前子序列的标准差,滑动窗口长度分别为 50,100,200 点,步长为 50 点。

如图 3 所示,癫痫不发作期是 0 到 60 s,从 60 s 开始进入癫痫发作前期,此时的样本熵出现下降趋势,到 110 s 左右癫痫发作达到最剧烈的时期,样本熵开始明显下降,到 175 s 左右时癫痫发作结束,熵值迅速上升。图 3 中竖实线指示癫痫开始时刻(60 s),竖实线以前为发作前期,竖虚线指示癫痫发作结束时刻(175 s),其以后为发作后期。为进一步分析癫痫过程中脑电的数量特征,本文计算了不同时期的样本熵均值和标准差,并根据脑电的时域幅度特征将癫痫发作期分为阶段 I(60~86 s)和阶段 II(86~175 s)。然而,从熵值变化来看,发作前期与发作阶段 I(60~86 s)脑电复杂度变化并不明显,样本熵的均值变化不明显(见表 1),但发作阶段 I




图 3 不同长度的癫痫 EEG 时变样本熵

的样本熵的标准差明显减小,而且标准差的变化,不受序列长度的影响。发作前后熵值的标准差发生明显变化,意味着样本熵的波动性减小,即呈现出规则性。这表明癫痫开始发作后,脑电的同步程度逐渐增大,相应地,脑电的规律性增加。由于癫痫开始发作后,脑电信号受到癫痫发作引起的运动伪迹,包括来自眼电、肌电、心电等信号干扰,导致癫痫发作前期的脑电熵值与不发作期的脑电熵值无明显差别。到发作高峰时,癫痫发作开始后,脑电同步放电的程度加大,产生非常明显的病理信号。此时脑电复杂度显著下降,样本熵明显减小。此外,由于滑动窗口的大小不同,计算的子序列长度也不一样,计算的结果也不相同(见图 1 和表 1),从表 1 可以看出子序列选择不同,对于序列检

表 1 不同时期脑电样本熵的均值(标准差)

癫痫数据对应的 时间	$L=50$	$L=100$	$L=200$
发作前期 (<60 s)	0.460 5 (0.254 4)	0.419 7 (0.137 5)	0.414 1 (0.084 0)
发作期 I ($60\sim 86$ s)	0.365 3 (0.138 5)	0.390 2 (0.087 5)	0.431 5 (0.059 5)
发作期 II ($86\sim 175$ s)	0.332 1 (0.181 4)	0.256 3 (0.153 9)	0.248 2 (0.1556)
发作结束 (>175 s)	0.801 9 (0.560 4)	0.496 6 (0.304 4)	0.341 0 (0.167 1)

测到的熵的均值和方差变化不同。这表明,采用样本熵检测癫痫发作依赖参数选择。

2.4 基于 MF-DFA 的癫痫发作和强度检测

癫痫发作期间,神经元突发性放电,脑电复杂度下降,脑电的动力结构发生改变,以 MF-DFA 的时变的局部赫斯特(Time evolution local Hurst exponent)指数($h(t)$)作为癫痫发作时间的标度指数,它能够直接反映时间序列数据在结构上发生的改变。如图 4 所示,癫痫发作间期的数据和发作期的数据标度指数的分布和盒形图存在显著不同($q=2$)。发作间期的标度指数普遍大于发作期的标度指数,两者有着明显的区分。EEG 数据来源

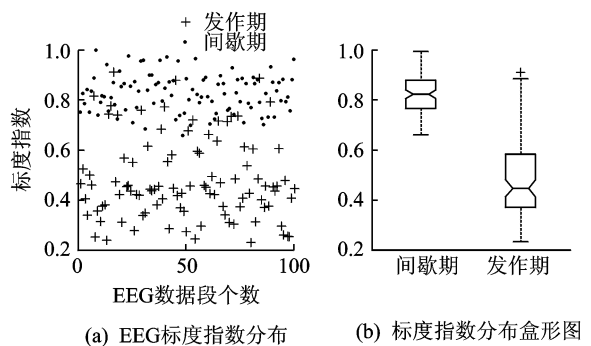


图 4 癫痫发作间歇期和发作期的 EEG 标度指数 $h(q)$ 分布及盒形图

于波恩大学公开数据库,波恩大学这组数据经过了滤波等处理,效果较好。在连续的癫痫数据中,一旦进入发作期,脑电的数据结构发生改变,标度指数就会产生易于区分的显著变化,标识着癫痫发作。

进一步采用波士顿儿童医院的连续癫痫脑电数据进行测试,该数据包含癫痫发作的不同时期,较长的发作前期、发作期和发作后期,适宜测试检测癫痫起始时刻与预测等算法的性能。计算时,取 $q=0$ 的 $h(t)$ 能反映癫痫的剧烈变化,多项式阶数 $m=3$ 。

采用波士顿儿童医院的 Fz-Cz 导脑电数据进行测试,结果如图 5 所示。图中竖实线指示癫痫发作期开始时刻(60 s),竖实线以前为发作前期,竖虚线指示癫痫发作结束时刻(175 s),虚线以后为发作结束后。

如图 5 所示,在 60 s(对应着该数据的 15 000,数据采样率 256 Hz),癫痫刚开始发作的进入发作前期,标度指数发生显著下降,进入 86 s(22 000 点)附近,发作期时动力学结构再次发生改变,标度指数发生剧烈变化,之后呈现下降趋势;在 175 s 附近(448 000 点)癫痫发作结束,标度指数再次发生剧烈变化,呈上升趋势。从图 5(d)曲线 $L=50$ 时的表现尤其突出。图 5 完整地用标度指数描述了一个癫痫患者从未发作到发作结束的具体过程。

由表 2 可知,子序列长度分别为为 $L=50, 100, 200$ 时,随着癫痫时间的发展,脑电的标度指数变化一致,比较表 1 与表 2 中 $L=200$ 一列可知,

表 2 不同时期 Fz-Cz 头皮脑电标度指数的均值(标准差)

癫痫数据对应的时间	$L=50$	$L=100$	$L=200$
发作前 (<60 s)	1.162 9 (0.099 9)	1.053 5 (0.101 5)	1.078 6 (0.081 1)
发作期 I ($60\sim 90$ s)	1.031 1 (0.084 1)	0.925 1 (0.075 1)	0.959 1 (0.058 0)
发作期 II ($90\sim 175$ s)	1.005 6 (0.140 4)	0.905 0 (0.116 7)	0.806 3 (0.096 9)
发作结束 (>175 s)	1.319 9 (0.073 5)	1.243 6 (0.083 5)	1.184 1 (0.078 8)

标度指数的计算结果与样本熵的结果显然不同。这表明脑电的标度指数基本不受序列长度的影响。

颅内数据相比于头皮数据,受到的伪迹干扰更小。图 6(a,b)分别表示 C4 导联的记录 2 位患者的颅内癫痫大发作时,子序列长度分别为 $L=50, 100, 200$ 的标度指数。数据来源于 8 位中年癫痫患者,降频采样频率为 102.4 Hz,12 位的模数转换,经过带宽 1~50 Hz 的滤波。图中竖实线之前表示发作前期,竖实线之后表示发作期,竖虚线之后表示发作结束。

从图 6 可以看出,MF-DFA 能准确地描述癫痫发作的过程。在竖线标示的位置,开始进入癫痫发作期,此时标度指数发生显著性下降(见表 3),随着癫痫的发作加深,标度指数数值不断减小。即使在图 6(a)发作期刚开始阶段,脑电幅值变化不大时,依然能显示出明显下降。在竖线后,发作结




图 5 头皮表面连续脑电不同片段长度标度指数




图 6 颅内 EEG 的标度指数

表 3 不同时期图 6(b)C4 导颅内脑电标度指数的均值(标准差)

癫痫数据对应的 时间	$L=50$	$L=100$	$L=200$
发作前期 (<63 s)	0.708 5 (0.072 4)	0.684 3 (0.093 8)	0.650 4 (0.113 4)
发作期 I ($63\sim78$ s)	0.435 3 (0.049 7)	0.450 9 (0.037 5)	0.487 5 (0.0321)
发作期 II ($78\sim127$ s)	0.332 2 (0.123 6)	0.290 3 (0.128 7)	0.289 6 (0.129 3)
发作结束 (>127 s)	0.668 5 (0.061 3)	0.631 7 (0.075 0)	0.589 7 (0.076 0)

束,数据结构再一次发生改变,标度指数迅速上升,如表 3 所示。另一位癫痫患者的颅内数据的计算结果(见图 6(b)),与这一结果完全一致。由于颅内癫痫几乎不受发作过程中肌肉运动产生的肌电等伪迹干扰,脑电的信噪比非常高。比较图 6 与图 5 可知,颅内脑电的癫痫发作检测性能更好。

随着癫痫发作时间变化,发作强度也发生相应变化。为了定量描述这一信息,并为临床诊断作出参考,采用 MF-DFA 的 $q=2$ 的波动函数值计算癫

痫发作强度,能更直观反映癫痫状况。以 Fz-Cz 导作为癫痫强度检测的对象,选取多项式阶数 $m=2$, $q=2$,MF-DFA 的波动函数值作为癫痫强度的标度指数,结果如图 7 所示,图中竖实线表示癫痫发作期开始时刻(60 s);竖虚线为癫痫发作结束时刻(175 s);方块箭头表示癫痫有所变弱的时刻,波动函数值也相应变弱,箭头表示在癫痫变强的时刻,波动函数值也相应变强。




图 7 Fz-Cz 导癫痫发作强度时序图

从图 7 可见,癫痫数据波动的剧烈程度反映了癫痫的发作强度。在 60 s 开始,波动函数随着时间逐渐加强,在 175 s 时癫痫结束。结束后,波动函数值重新回到未发作时的水平。癫痫发作期,癫痫的发作强度总体是逐步增加的^[23]。波动函数能直观地描述出癫痫发作的 3 个时期,即发作前期,发作期和发作后期的癫痫强度。同样,对颅内癫痫数据,计算了癫痫演化过程中的强度变化。如图 8 所示,上图为患者 1C4 导数据,下图为患者 1 波动函数序列,波动函数值准确地反映了癫痫发作的剧烈程度,与癫痫的起止时刻一致,图中竖实线表示癫痫发作期开始时刻(80 s);竖虚线为癫痫发作结束时刻(165 s);箭头表示在癫痫变强的时刻,波动




图 8 颅内脑电 C4 导癫痫发作强度时序图

函数值也相应变强。

比较图 8 与图 7 的结果,可知颅内癫痫的高信噪比特征,使标度指数能够更精准刻画癫痫发作起始时刻。

3 结束语

癫痫发作时,脑电信号的动力结构发生改变,为癫痫的识别、检测和预报提供关键的依据。样本熵在癫痫发作中逐渐降低,癫痫发作结束后迅速增大。这与前人研究结果^[4-7,11-13]一致。然而,受到序列长度等参数选择的影响,样本熵难以准确检测到癫痫发作开始时间。而且,从未发作转入发作期时,样本熵的变化不够明显。此外,脑电还受到发作时躯体运动伪迹的影响^[24],基于样本熵的癫痫检测不够敏感。尤其是,基于样本熵方法,对于癫痫发作和结束的时刻,受序列长度影响很大。基于 MF-DFA 的癫痫检测能够反映癫痫的发作特征,检测性能稳定,能够精确刻画癫痫发作的起止时刻,为准确识别和预报癫痫提供了至关重要的信息。在计算 MF-DFA 时,非重叠的配分容易在分割点处引起标度指数失真。尽管如此, MF-DFA 不失为一种癫痫发作与强度检测或发作预测的有效方法,为生物医学时间序列的突变检测等提供了有力的工具。

参考文献:

- [1] Iasemidis L D, Sackellares J C. REVIEW: Chaos theory and epilepsy[J]. *The Neuroscientist*, 1996, 2(2):118-126.
- [2] Fisher R S, Boas W V E, Blume W, et al. Epileptic seizures and epilepsy: Definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE)[J]. *Epilepsia*, 2005, 46(4):470-472.
- [3] Smith S. EEG in the diagnosis, classification, and management of patients with epilepsy[J]. *Journal of Neurology, Neurosurgery & Psychiatry*, 2005, 76(S2):i2-i7.
- [4] Pravin Kumar S, Sriraam N, Benakop P G, et al. Entropies based detection of epileptic seizures with artificial neural network classifiers[J]. *Expert Systems with Applications*, 2010, 37(4):3284-3291.
- [5] Wilkinson M, Mehlig B, Gustavsson K. Correlation dimension of inertial particles in random flows[J]. *EPL (Europhysics Letters)*, 2010, 89(5):50002.
- [6] Silva F, Ac Filho S, Crescêncio J C, et al. Applying Lyapunov exponents in heart rate time series to identify the anaerobic threshold in healthy men[C]// *Computing in Cardiology (CinC)*. [S. l.]: IEEE, 2012:629-632.
- [7] Vavadi H, Ayatollahi A, Mirzaei A. A wavelet approximate entropy method for epileptic activity detection from EEG and its sub-bands[J]. *Journal of Biomedical Science and Engineering*, 2010, 3:1182-1189.
- [8] 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.
- [9] Liu Hui, Xie Hongbo, He Weixing, et al. Characterization and classification of EEG sleep stage based on fuzzy entropy [J]. *Journal of Data Acquisition and Processing*, 2010, 25(4):484-489.
- [10] Pincus S M. Approximate entropy as a measure of system complexity[J]. *Proceedings of the National Academy of Sciences*, 1991, 88(6):2297-2301.
- [11] Richman J S, Moorman J R. Physiological time-series analysis using approximate entropy and sample entropy[J]. *American Journal of Physiology-Heart and Circulatory Physiology*, 2000, 278(6):H2039-H2049.
- [12] Yoo C S, Jung D C, Ahn Y M, et al. Automatic detection of seizure termination during electroconvulsive therapy using sample entropy of the electroencephalogram[J]. *Psychiatry Research*, 2012, 195(1):76-82.
- [13] Kannathal N, Choo M L, Acharya U R, et al. Entropies for detection of epilepsy in EEG[J]. *Computer Methods and Programs in Biomedicine*, 2005, 80(3):187-194.
- [14] Ocak H. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy[J]. *Expert Systems with Applications*, 2009, 36(2):2027-2036.
- [15] Yoo C S, Jung D C, Ahn Y M, et al. Automatic detection of seizure termination during electroconvulsive therapy using sample entropy of the electroencephalogram[J]. *Psychiatry Research*, 2012, 195(1):76-82.
- [16] 何文平,王启光,吴琼,等.滑动去趋势波动分析与近似熵在动力学结构突变检测中的性能比较[J]. *物理学报*, 2009, 58(4):2862-2871.
- [17] He Wenping, Wang Qiguang, Wu Qiong, et al. Comparison of characteristics of moving detrended fluctuation analysis with that of approximate entropy method in detecting abrupt dynamic change[J]. *Acta Physica Sinica*, 2009, 58(4):2862-2871.
- [18] Jouny C C, Bergey G K. Characterization of early partial seizure onset: Frequency, complexity and entropy[J]. *Clinical Neurophysiology*, 2012, 123(4):

- 658-669.
- [17] Shalhaf R, Hosseini P T, Analoui M. Epilepsy detection using detrended fluctuation analysis [C]// Wavelet Analysis and Pattern Recognition, ICWAPR 2009. [S. l.]: IEEE, 2009:235-240.
- [18] Cai D, Zhou W, Li S, et al. Classification of epileptic EEG based on detrended fluctuation analysis and support vector machine[J]. Acta Biophysica Sinica, 2011,27(2):175-182.
- [19] Kantelhardt J W, Zschiegner S A, Koscielny-Bunde E, et al. Multifractal detrended fluctuation analysis of nonstationary time series[J]. Physica A: Statistical Mechanics and Its Applications, 2002,316(1):87-114.
- [20] 李建更,郭庆雷,贺益恒. 时序基因表达缺失值的加权双向回归估计算法[J]. 数据采集与处理,2013(2):136-140.
- Li Jiangeng, Guo Qinglei, He Yiheng. Double weighted regression estimation for missing values in time series gene expression data[J]. Journal of Data Acquisition and Processing, 2013,28(2):136-140.
- [21] Hosseini P T, Shalhaf R, Nasrabadi A M. Extracting a seizure intensity index from one-channel EEG signal using bispectral and detrended fluctuation analysis[J]. Journal of Biomedical Science and Engineering, 2010,3(3):253-261.
- [22] Shoeb A H. Application of machine learning to epileptic seizure onset detection and treatment[D]. Dept Electrical Eng, MIT, USA, 2009,9:3-161.
- [23] Andrzejak R G, Lehnertz K, Mormann F, et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. Physical Review E, 2001,64(6):61907.
- [24] 张莉,何传红,何为,等. 基于典型相关分析与低通滤波的肌电伪迹去除[J]. 数据采集与处理,2010,25(2):255-258.
- Zhang Li, He Chuanhong, He Wei, et al. Method for removing EMG artifacts based on CCA and low-pass filtering[J]. Journal of Data Acquisition and Processing, 2010,25(2):255-258.

作者简介:张翔(1989-),男,硕士研究生,研究方向:生物医学信号处理;丁勇(1991-),男,本科生,研究方向:生物医学信号处理;刘小峰(1974-),男,教授,博士生导师,研究方向:自然导航、人机互动及神经工程,E-mail:xfliubme@gmail.com。