癫痫脑电的递归确定性分析*

李红利[1,2], 王　江[1], 邓　斌[1], 魏熙乐[1]
(1. 天津大学 电气与自动化工程学院, 天津 300072; 2. 天津工业大学 电气工程与自动化学院, 天津 300387)

摘　要: 利用排序递归图的分析方法对癫痫脑电进行了确定性(DET)的分析,得出癫痫头皮脑电(EEG)的 DET 高于健康 EEG。DET 特征的差异性在局部导联上更明显,局部导联的 DET 特征可以作为癫痫疾病的自动诊断特征。通过分析发作阶段和发作间隙皮层脑电(ECoG)的 DET,得出整个频带的 DET 差别不大,而在 beta 频带,发作阶段的确定性明显高于发作间隙的 DET。Beta 频带的 DET 特征可以作为癫痫发作的预测特征。研究结果为癫痫疾病的自动诊断和癫痫发作预测提供了理论依据。

关键词: 癫痫; 脑电信号; 递归图; 确定性; 小波变换; 相空间重构
中图分类号: R742.1　　**文献标志码**: A　　**文章编号**: 1001-3695(2013)03-757-03
doi:10.3969/j.issn.1001-3695.2013.03.029

Analysis of recurrence determination for epileptic brain electric signals

LI Hong-li[1,2], WANG Jiang[1], DENG Bin[1], WEI Xi-le[1]
(1. *School of Electrical Engineering & Automation*, *Tianjin University*, *Tianjin* 300072, *China*; 2. *School of Electrical Engineering & Automation*, *Tianjin Polytechnic University*, *Tianjin* 300387, *China*)

Abstract: This paper used the method of order recurrence plot to analyze the determination(DET) of epileptic brain electrical signals. The results show that DET of epileptic scalp brain electric signals (EEG) is higher than the ones of healthy EEG. And the difference of DET is more obvious in some partial electrodes. DET of these partial electrodes could be used as features to auto-diagnose epilepsy. Then it conducted analysis of DET for electrocorticogram (ECoG) during a seizure and that during a seizure-free interval. The results show there is no significant difference for determination in the whole band. However, DET during a seizure is obviously higher than that during a seizure-free interval in beta band. Changes of DET in beta band could be used to predict epilepsy seizure. The research results provide a theoretical basis for auto-diagnosis of epilepsy and seizure prediction.

Key words: epilepsy; brain electric signals; recurrence plot; determination; wavelet transform; phase space reconstruction

癫痫是一种常见的大脑疾病,全世界大约有 0.5% 的人患有癫痫,癫痫的发病机制至今仍未阐明[1,2]。癫痫病人所处的阶段可分为发作间隙、发作前期和发作阶段。癫痫的主要治疗方法有药物治疗、手术治疗和磁刺激治疗。每种治疗方法都存在弊端,大约有 30% ~40% 的癫痫患者不能由这些治疗手段治愈[3]。目前,癫痫的诊断主要依赖于有经验的医生对脑电图的直接观察。然而,多数癫痫患者在癫痫发作间隙所采集的脑电图与健康人的并无明显区别,依靠人为诊断难免会出现误诊。并且癫痫疾病的主要特点是突发性,如能在癫痫发作前对其进行预测,则可提示病人避开危险,及时用药。

脑电信号包含了大量的生理与病理信息,是研究癫痫的一个重要工具。临床上,利用癫痫脑电信号提取癫痫脑电的特征,对癫痫的自动诊断和癫痫发作预测具有重要意义。虽然关于癫痫诊断和预测的研究很多,但是多数算法在分析癫痫脑电特征时,使用网上公共数据库中特定小样本的数据作为研究对象。这些数据多是癫痫病灶区域的单导联或双导联的 ECoG 数据[4,5]。将这些算法应用于这些数据时,可以提取出有效的特征值。但是,应用于临床头皮 EEG 数据时,并不能取得令人满意的效果[6]。针对这一问题,本研究临床采集了 20 个导联头皮 EEG 数据,采用排序递归图的分析方法提取了脑电信号的确定性特征。结果表明,癫痫 EEG 的确定性高于健康 EEG,发作阶段 ECoG 的确定性高于发作间隙 ECoG 的确定性。因此,确定性可以作为癫痫诊断和预测的有效特征。

1　实验数据采集与预处理

本研究的脑电实验数据由两部分组成:a)头皮 EEG 数据,该部分数据包含 8 名健康对象和 8 名癫痫患者临床采集的 EEG 数据;b)ECoG 数据,该部分数据为 5 名癫痫患者颅内记录的 ECoG 数据[7]。

1.1　EEG 数据

本研究的癫痫 EEG 数据样本来自武警医学院。对该医院癫痫患者进行筛选,选择了不同性别和年龄段的患者,共采集了 8 位癫痫患者的 EEG 数据。所记录的为患者静坐时连续采集的

收稿日期: 2012-06-10; **修回日期**: 2012-07-23　　**基金项目**: 国家自然科学基金资助项目(61072012);国家自然科学基金青年基金资助项目(50907044,60901035)

作者简介: 李红利(1978-),男(满族),辽宁葫芦岛人,副教授,博士,主要研究方向为神经系统的非线性动力学分析、脑机接口技术(lihongliln@163.com);王江(1964-),男,河北唐山人,教授,博士,主要研究方向为神经系统的非线性动力学分析、生物信息控制技术;邓斌(1979-),男,湖南衡阳人,副教授,博士,主要研究方向为神经系统的非线性动力学分析、生物信息控制技术;魏熙乐(1975-),男,河南漯河人,副教授,博士,主要研究方向为神经系统的非线性动力学分析、生物信息控制技术.

大约 1 h 的数据。EEG 数据均为癫痫患者处于发作间隙阶段的数据,并不包含癫痫发作和发作前期的数据。为了与癫痫 EEG 进行对比,该医院还采集了 8 名健康对象的 EEG 数据。电极摆放的位置按照国际标准导联 10-20 系统放置,如图 1 所示。图 1 中 A_1 和 A_2 作为参考电极,耳垂作为电极的参考地。采样频率为 256 Hz,硬件滤波器的带通频率为 0.5 ~ 100 Hz。

1.2 ECoG 数据

本研究的 ECoG 数据由德国波鸿大学的网上数据库提供,包含癫痫发作间隙和癫痫发作阶段两组数据。每组数据中包含 100 段颅内采集的 ECoG 数据。每段数据中包含 4 097 个数据,采样频率为 173.61 Hz,对应的时间长度为 23.6 s。

图 2 为随机选择的一段发作间隙的 ECoG 数据。图 3 为随机选择的一段发作阶段的 ECoG 数据。对比图 2 和 3 可以看出,癫痫发作时,ECoG 的幅值明显大于发作间隙 ECoG 幅值,即癫痫发作时,表现为大脑神经元的异常同步放电。

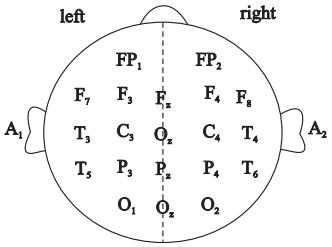

图1 电极摆放位置

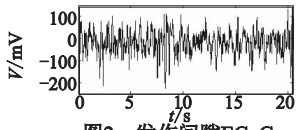

图2 发作间隙ECoG

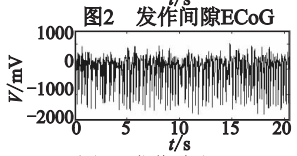

图3 发作阶段ECoG

1.3 实验数据的预处理

1.3.1 数据的限幅

眨眼、眼球移动、患者的肌肉动作均会在 EEG 中产生较大幅值的干扰。为了减小这些扰动的影响,需要对每个电极所记录的 EEG 进行限幅,限幅的大小可根据数据中的噪声进行选择。

1.3.2 数据的带通滤波

使用 5 阶 Butterworth 带通滤波器对 EEG 数据带通滤波。滤波器的截止频率为 0.5 ~ 48 Hz。利用 MATLAB 中的 butter 和 filtfilt 函数即可实现 Butterworth 带通滤波。图 4 为所记录的患者 3 的 C_3 导联的原始 EEG 信号,图 5 所示为带通滤波后的 EEG 数据。可见,经过带通滤波后,滤除了 EEG 中的高频信号。利用上述的限幅和带通滤波方法对所有电极的 EEG 进行预处理,为后面的数据分析作准备。由于 ECoG 数据中不含有眼电和肌电噪声,因此,本研究所用的 ECoG 数据无须进行限幅运算,只进行带通滤波即可。

2 排序递归图

通过相空间重构技术确定非线性时间序列的时滞和嵌入维数后,就可以在相空间内分析吸引子的特征,吸引子的特征反映了非线性系统的特性。Eckmann 等人[8]在 1987 年提出能够可视化相空间中递归状态的一种工具,即通过将相空间中的递归状态画在二维平面上便可研究任意维数的相空间系统[9]。本文利用排序递归图研究了相空间中吸引子的排序递归现象。给定一个非线性时间序列 $x(i)$,对其进行重构后的相空间中任意一点可表示为

$$X(i) = (x(i), x(i+\tau), \cdots, x(i+(m-1)\tau) \tag{1}$$

以二维状态空间为例,定义排序模式为 π,即

$$\pi_i = \begin{cases} 0 & x(i) < x(i+\tau) \\ 1 & x(i) > x(i+\tau) \end{cases} \tag{2}$$

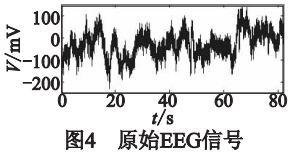

图4 原始EEG信号

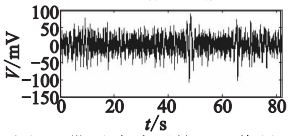

图5 带通滤波后的EEG信号

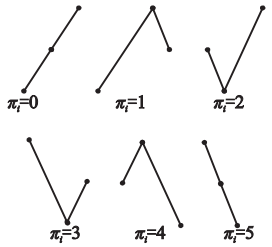

图6 嵌入维数为3时的排序模式示意图

可知维数 $m=2$ 时有上升和下降两种排序模式,轨线的这种编码会将相空间相等地分解到两个区域。对于 $m=3$ 时,有 $m!=6$ 种排序模式,则 $x(i)$,$x(i+\tau)$ 和 $x(i+2\tau)$ 的关系如图 6 所示。

如果第 i 和 j 时刻状态向量的排序模式相同,即 $\pi_i = \pi_j$,则称为排序递归状态[10],定义为

$$R_{i,j} = \begin{cases} 0, \pi_i \neq \pi_j \\ 1, \pi_i = \pi_j \end{cases} \quad i,j = 1,2,\cdots,N \tag{3}$$

通过 2 维方阵中黑点与白点描述第 i 与 j 时刻的递归状态,最后构成一幅排序递归图(order recurrence plot,ORP),当 $R_{i,j}=1$ 时称为递归状态,在递归图中用黑点表示。通过排序分类以后,m 维相空间则被相等地分为 $m!$ 个区域,也就是说,若相空间中不同时刻的状态向量被划分到同一个排序区域内时,这些状态向量就被定义为排序递归状态。递归图的主要目的是观察高维相空间中的状态轨迹,通过对递归图的观察可以发现轨迹的运行状态,它的优点在于能够处理不平稳或数据量较少的数据[11]。在排序递归图中,沿着对角线方向的线段长度(对角线长度 l)反映了轨线的发散程度,对角线长度的分布概率为

$$P(l) = \sum_{i,j=1}^{N} (1 - R_{i-1,j-1}(\varepsilon))(1 - R_{i+l,j+l}(\varepsilon)) \prod_{k=0}^{l-1} R_{i+k,j+k}(\varepsilon) \tag{4}$$

对于随机的信号,排序递归图中将不会产生很长的对角线。而对于具有确定性的过程,排序递归图中的孤立回归点会相对较少,产生对角线长度较长,因此可以通过计算构成长度大于 $l_{\min}$ 的对角线的递归点数目占所有递归点的比率来测度系统的确定性,其表达式如式(5)所示。

$$\mathrm{DET} = \frac{\sum_{l=l_{\min}}^{N} lP(l)}{\sum_{l=1}^{N} lP(l)} \tag{5}$$

其中:$l_{\min}$ 为对角线长度的阈值,一般选为不小于 2 的整数,但 $l_{\min}$ 过大,则 $P(l)$ 可能过于稀疏,DET 的可靠性会变低。DET 能够区分 ORP 中形成连续对角线方向线段的递归点和孤立的递归点。若系统确定性的 ORP 中沿主对角线的线条纹理越发育,说明其确定性就越强。

3 DET 分析结果

3.1 EEG 的 DET 分析结果

利用 8 名健康对象和 8 名癫痫患者的脑电数据作为本文的研究对象。对于每导联的 EEG 数据,连续选择 80 s 的数据段进行递归分析。首先利用相空间重构技术计算的各导联的最优时滞 m_0 和最小嵌入维数 d_m,对健康对象和癫痫患者的 20 个导联 EEG 进行相空间重构。对于健康 EEG,$m_0=5$,$d_m=8$;对于癫痫 EEG,$m_0=4$,$d_m=7$。图 7 为随机选取的 2 名健康对象和 2 名癫痫患者 T_3 导联 EEG 的排序递归图。从图 7 和 8 可以看出,癫痫患者的排序递归图分布具有一定的规律,线条纹理较多。而健康对象的排序递归图分布无明确规律,递归图中

只是一些杂乱分布的点。因此,癫痫 EEG 的确定性较强。

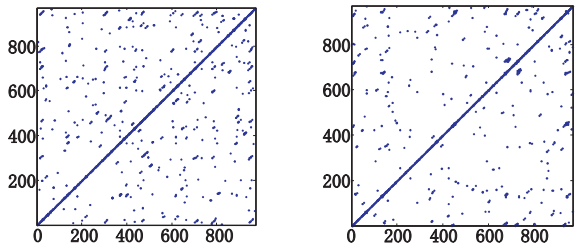

图7　健康对象的排序模式示意图

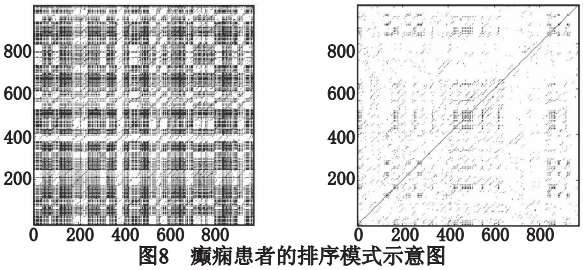

图8　癫痫患者的排序模式示意图

利用滑动窗口方法将所选 EEG 分割成长度为 4 s 的窗口,窗口移动距离为 1 s,计算每个滑动窗口内 EEG 的 DET 值,然后对该导联的所有滑动窗结果取均值,作为该导联 EEG 的 DET 值。将所得各导联平均 DET 画出柱状图,如图 9 所示。

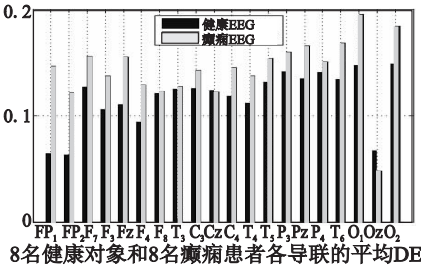

图9　8名健康对象和8名癫痫患者各导联的平均DET

从图 9 可以看出,癫痫患者的 DET 除了 O 导联的减小外,其余 19 个导联的 DET 值与健康 EEG 的 DET 相比均增大。可见,癫痫患者由于神经元的异常同步放电作用,使得大脑的确定性提高。而正常的大脑处于高度的混沌状态,复杂度较高,即确定性较低。因此,可以将较高的确定性作为诊断癫痫疾病的重要特征。

从图 9 还可以看出,不同导联的 DET 值差别很大,FP_1、FP_2、F_7、C_3 等导联的差别较大。选择 FP_1、FP_2、F_7、C_3 等导联的脑电数据作为本文的研究对象,画出 DET 随滑动窗口移动的曲线三维图,如图 10 和 11 所示。从三维图可以清楚地看出,健康 EEG 与癫痫 EEG 的 DET 值在不同的导联处存在着明显的差别。利用这些特征差别可以正确区分健康对象和癫痫患者,为癫痫疾病的诊断提供依据。

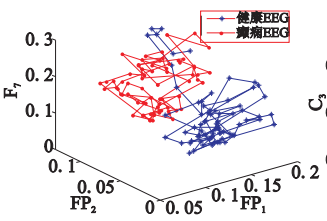

图10　FP_1、FP_2、F_7导联DET随滑动窗口移动

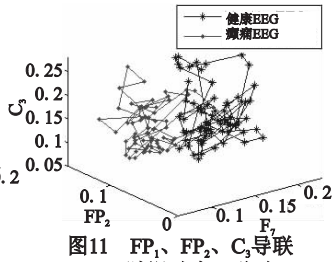

图11　FP_1、FP_2、C_3导联DET随滑动窗口移动

图 12 以 FP_1、FP_2、F_7 导联的平均 DET 为特征,对 8 名健康对象和 8 名癫痫患者 DET 特征进行了单因素方差分析。图 13 给出了 8 名健康对象和 8 名癫痫患者全脑导联平均 DET 的单因素方差分析结果。对比图 12 和 13 可以看出,图 12 是以 FP_1、FP_2、F_7 三个导联的平均 DET 为特征的箱线图,p 值小于 0.05,表示有明显差别。而图 13 中健康对象和癫痫患者全脑导联平均 DET 没有明显差别,因此,在利用 DET 对癫痫 EEG 进行分析时,应重点提取具有明显特征差别的导联,而不是全脑导联。

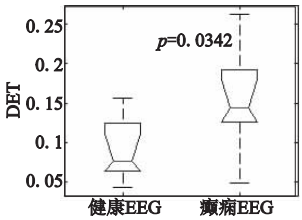

图12　健康和癫痫EEG FP_1、FP_2、F_7导联DET的单因素方差分析

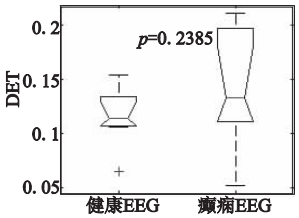

图13　健康和癫痫EEG全脑导联DET的单因素方差分析

3.2　ECoG 的 DET 分析结果

类似的方法,可以计算德国波鸿大学提供的 100 段癫痫发作间隙和 100 段发作阶段 ECoG 的 DET 值。计算时,仍然将每个导联的 ECOG 分割成长度为 4 s 的窗口,窗口移动距离为 1 s,计算每个滑动窗口内 ECOG 的 DET 值,然后对该导联的所有滑动窗结果取均值,作为该导联 ECoG 的 DET 值。为了更清楚地比较发作间隙和发作阶段 DET 值的区别,将所计算的结果的 DET 进行单因素方差分析,如图 14 所示。从图中可以看出,与发作间隙相比,发作阶段的 DET 值有所上升,但从图中的均值和方差分布可以看出,差别并不明显。

为了提取更明显的 DET 特征,利用小波变换将 ECoG 数据进行 4 层 Daubechies 小波分解,提取 beta 频带(14 ~ 30 Hz)的数据。对于 beta 节律,按照上述方法计算 DET 值,并进行单因素方差分析,如图 15 所示。从图 15 可以看出,从发作间隙到发作阶段 DET 发生了显著变化。既然癫痫发作时 DET 发生了显著性上升,那么可以通过监控 DET 的变化对癫痫病人进行监控,在癫痫发作之前,对癫痫疾病作出预测,对癫痫患者提出预警。本研究的 ECoG 数据只包含癫痫病灶区域的 ECoG 数据,若能采集癫痫患者全脑导联的脑电数据并进行监控,那么可以提取更明显的癫痫发作特征。

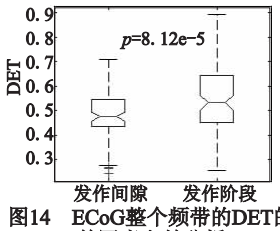

图14　ECoG整个频带的DET的单因素方差分析

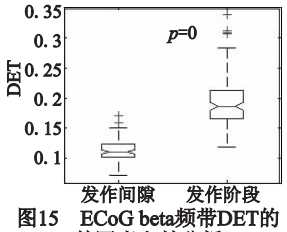

图15　ECoG beta频带DET的单因素方差分析

4　结束语

本文利用排序递归图的分析方法,提取了癫痫脑电的确定性特征。结果表明癫痫患者脑电的确定性高于健康对象,癫痫发作阶段脑电的确定性高于发作间隙。EEG 递归确定性的差别以 FP_1、FP_2、F_7、C_3 等导联较大。ECoG 的确定性在 beta 频带差别较大。这些确定性的特征差别与癫痫发作大脑神经元的异常同步放电密切相关。本文所提取的确定性特征,为癫痫自动诊断和癫痫发作预测的临床应用提供了理论依据。

参考文献:

[1]　FELDWISCH-DRENTRUP H, STANIEK M, SCHULZE-BONHAGE A,

(下转第 763 页)

山谷内,一般算法很难辨别搜索方向,极难找到全局最小点。SFLA 算法对这个函数的求解效果不理想,而 SFLA-OBL$_0$ 通过反向学习策略,提高了算法的全局探索能力并加快了收敛速度,但通过实验表明对于这个函数,在迭代过程中出现了个体趋同的现象,使算法在一定精度下的进化能力下降,基本收敛值在 27 左右就无法再继续寻优。因此仿真实验虽已表明 SFLA-OBL$_0$ 具有良好的全局探索能力。但在算法出现早熟收敛现象时如何增加个体多样性,进一步提高算法的求精能力是需要考虑的问题。

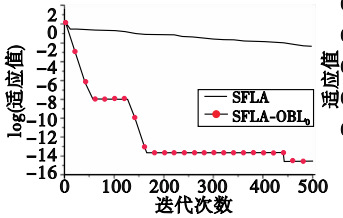

图5　Ackley函数的收敛曲线

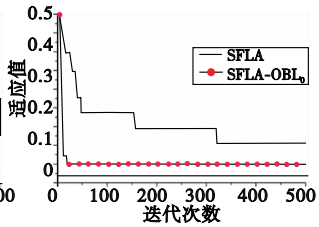

图6　Schaffer函数的收敛曲线

4　结束语

本文针对 SFLA 算法在连续函数优化中出现的收敛速度慢、求解精度不理想问题,提出了改进的算法。利用反向学习策略产生更靠近优质解的初始种群,并在迭代过程中利用该策略加速收敛。仿真实验表明,对于 SFLA 算法,当 $k=0$ 时的反向策略最有效,改进的 SFLA-OBL 相对于原算法具有更高的求解精度和更快的收敛速度。如何保持算法个体多样性,在空间探索和局部开采间取得更好平衡,进一步提高算法求精能力是下一步的研究方向。

参考文献:

[1] MUZAFFAR M E, KEVIN E L. Optimization of water distribution network design using the shuffled frog leaping algorithm[J]. Journal of Water Resources Planning and Management,2003,129(3):210-225.

[2] 韩毅,蔡建湖,周根贵,等. 随机蛙跳算法的研究进展[J]. 计算机科学,2010,37(7):16-19.

[3] ELBELTAGI E, HEGAZY T, GRIERSON D. Comparison among five evolutionary-based optimization algorithms[J]. Advanced Engineering Informatics,2005,19(1):43-53.

[4] 李英海,周建中,杨俊杰,等. 一种基于阈值选择策略的改进混合蛙跳算法[J]. 计算机工程与应用,2007,43(35):19-21.

[5] ZHEN Zi-yang, WANG Zhi-sheng, GU Zhou, *et al*. A novel memetic algorithm for global optimization based on PSO and SFLA[C]//Proc of the 2nd International Conference on Advances Computation and Intelligence. Berlin:Springer-Verlag,2007:127-136.

[6] BHADURI A. A clonally selection based shuffled frog leaping algorithm[C] //Proc of IEEE International Advance Computing Conference. 2009:125-130.

[7] 赵鹏军,刘三阳. 求解复杂函数优化问题的混合蛙跳算法[J]. 计算机应用研究,2009,26(7):2435-2437.

[8] 骆剑平,陈泯融. 混合蛙跳算法及其改进算法的运动轨迹及收敛性分析[J]. 信号处理,2010,26(9):1428-1433.

[9] 何兵,车林仙,刘初升. 一种蛙跳和差分进化混合算法[J]. 计算机工程与应用,2011,47(18):4-8.

[10] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C]//Proc of International Conference on Computational Intelligence for Modelling, Control and Automation. Washington DC:IEEE Computer Society,2005:695-701.

[11] LIN Zhi-yi, WANG Ling-ling. A new opposition-based compact genetic algorithm with fluctuation[J]. Journal of Computational Information Systems,2010,6(3):897-904.

[12] VENTRESCA M, TIZHOOSH H R. Improving the convergence of backpropagation by opposite transfer functions[C] //Proc of International Joint Conference on Neural Networks. Piscataway:IEEE Press,2006:4777-4784.

[13] MONTGOMERY J, RANDALL M. Anti-pheromone as a tool for better exploration of search space[C]//Proc of the 3rd International Workshop on Ant Algorithms. London: Springer-Verlag, 2002: 100-110.

[14] HAN Lin, HE Xing-shi. A novel opposition-based particle swarm optimization for noisy problems[C]//Proc of the 3rd International Conference on Natural Computation. Washington DC:IEEE Computer Society,2007:624-629.

[15] SHAHRYAR R, HAMID R T, MAGDY M A S. Opposition versus randomness in soft computing techniques[J]. Applied Soft Computing,2008,8(2):906-918.

[16] WANG Hui, WU Zhi-jian, SHAHRYAR R. Enhanced opposition-based differential evolution for solving high-dimensional continuous optimization problems[J]. Soft Computing,2011,15(11):2127-2140.

[17] SHAHRYAR R. Opposition-based differential evolution[J]. Evolutionary Computation,2008,12(1):64-79.

[18] 徐庆征,王磊,何宝民,等. 基于当前最优解的反向差分进化算法求解函数优化问题[J]. 应用科学学报,2011,29(3):308-315.

[19] WANG Hui , WU Zhi-jian, LIU Yong, *et al*. Space transformation search: a new evolutionary technique[C]//Proc of the 1st ACM/SIGEVO Summit on Genetic and Evolutionary Computation. New York: ACM Press,2009:537-544.

(上接第 759 页)

et al. Identification of preseizure states in epilepsy: a data-driven approach for multichannel EEG recordings[J]. Frontiers in Computational Neuroscience,2011,5(32): 1-9.

[2] RAJDEV P, WARD M, RICKUS J, *et al*. Real-time seizure prediction from local field potentials using an adaptive Wiener algorithm[J]. Computers in Biology and Medicine,2010,40(1): 97-108.

[3] SNYDER D E, ECHAUZ J, GRIMES D B, *et al*. The statistics of a practical seizure warning system[J]. Journal of Neural Engineering,2008,5(4): 392-401.

[4] FELDWISCH-DRENTRUP H, SCHELTER B, JACHAN M, *et al*. Joining the benefits: combining epileptic seizure prediction methods [J]. Epilepsia,2010,51(8):1598-1606.

[5] CHISCI L, MAVINA A, PERFERI G, *et al*. Realtime epileptic seizure prediction using AR models and support vector machines[J]. IEEE Trans on Biomedical Engineering, 2010, 57(5): 1124-1132.

[6] FELDWISCH-DRENTRUP H, SCHULZE A, TIMMER J, *et al*. Statistical validation of event predictors: a comparative study based on the field of seizure prediction[J]. Physical Review E,2011,83(6): 066704: 1-6.

[7] 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):061907.

[8] ECKMANN J P, KAMPHORST S O, RUELLE D. Recurrence plots of dynamical systems[J]. Europhysics Letters,1987,4(9): 973-977.

[9] 边洪瑞,王江,韩春晓,等. 基于复杂度的针刺脑电信号特征提取[J]. 物理学报,2011,60(11):1-9.

[10] GROTH A. Visualization of coupling in time series by order recurrence plots[J]. Physical Review E,2005,72(4):046220.

[11] 欧阳高翔. 癫痫脑电信号的非线性特征识别与分析[D]. 秦皇岛: 燕山大学, 2010.