

基于递归量化分析与支持向量机的 癫痫脑电自动检测方法*

孟庆芳[†] 陈珊珊 陈月辉 冯志全

(济南大学信息科学与工程学院, 济南 250022)

(山东省网络环境智能计算技术重点实验室, 济南 250022)

(2013年10月11日收到; 2013年11月27日收到修改稿)

癫痫脑电信号的自动检测对癫痫的临床诊断与治疗具有重要意义. 基于递归图(recurrence plot)的递归量化分析(recurrence quantification analysis, RQA)重现了非线性时间序列的动力学行为, 分析了其递归特性, 本文提出了基于RQA的癫痫脑电信号特征提取方法. 实验结果表明: 直接基于RQA特征的癫痫脑电的检测准确率较高, 其中直接基于确定率DET的分类准确率可达到90.25%. 本文还把提取的RQA特征值和变化系数、波动指数相结合组成特征向量, 输入到SVM分类器, 实现癫痫脑电信号的自动检测; 实验结果表明: 该方法的分类准确率可达到99%.

关键词: 递归量化分析, 递归图, 癫痫脑电, 支持向量机

PACS: 05.45.Tp, 05.45.Pq, 05.45.Ac

DOI: 10.7498/aps.63.050506

1 引言

癫痫是一种常见的慢性脑部疾病, 对患者身体健康有极大的伤害, 其发作时大脑神经异常性兴奋及过度同步放电, 并引起中枢神经功能暂时性失常, 症状表现为抽搐、精神异常、发作性意识改变等. 目前癫痫病的检测与诊断主要由医学专家根据记录的脑电图波形通过视觉检测, 识别与正常脑电信号波形不同的特征癫痫波. 由于癫痫发作的不确定性, 常常需要对病人的脑电波进行长期的实时监测, 检测时间长、效率低, 并且根据医生的临床经验判断容易出现不一致的判断情况; 因此, 癫痫脑电信号的自动检测有助于减轻医疗工作者的工作量, 进一步推进癫痫脑电信号自动检测的研究, 在临床应用中具有现实且重大的意义^[1].

越来越多的证据表明大脑是一个复杂的非线性动力学系统, 脑电信号具有非线性和非平稳的特

性, 非线性动力学方法被广泛的应用于脑电信号的分析^[1-8]. 人们尝试把非线性时间序列的度量方法, 如最大Lyapunov指数^[2]、关联维数^[4]、近似熵^[3,5,6]、样本熵^[5,7]、Hurst指数^[8]等用于癫痫脑电信号的分析. 文献^[2]分析了脑电信号的短时最大Lyapunov指数在癫痫发作过程中的变化. 文献^[1]提出了基于非线性预测效果的癫痫脑电信号特征提取方法. 文献^[3]采用了四种熵(Kolmogorov熵、Spectral熵、Renyi熵、近似熵)来分析正常脑电与癫痫脑电信号. 文献^[5]进一步应用近似熵、样本熵、Phase熵1与Phase熵2并结合多种分类器来分析正常脑电、发作前脑电、癫痫发作期脑电.

递归图是由Eckmann等提出的分析相空间中时间序列递归特性的分析方法^[9]. 该方法与传统方法相比, 克服了对时间序列的长度和稳态性的严格要求, 具有较好的分析性能, 适用于非线性动力学系统的分析. 近年来, 递归量化分析RQA被广泛的应用于分析生理信号, 如脑电信号^[10-13], 肌

* 国家自然科学基金(批准号: 61201428, 61070130, 61173079)、山东省自然科学基金(批准号: ZR2010FQ020, ZR2011FZ003)、山东省优秀中青年科学家科研奖励基金(批准号: BS2009SW003)和中国博士后科学基金(批准号: 20100470081)资助的课题.

[†] 通讯作者. E-mail: ise_mengqf@ujn.edu.cn

电信号^[14], 心率变异信号^[15,16], 血压变化信号^[17]等. Acharya等^[12]分析睡眠脑电信号, 发现不同睡眠阶段脑电信号的递归图量化分析非线性特征参数有显著的差异. 钟季康等^[14]应用RQA分析了肱二头肌及肱桡肌在不同负重下的肌电信号, 发现肱二头肌肌电信号的递归点百分数均比肱肌高, 有较强的周期性嵌入. Marwan等^[15]对复杂系统进行递归图分析, 并将递归量化分析用于心率变异信号的检测.

支持向量机SVM是在统计学习理论上发展起来的一种解决监督分类问题的工具^[18]. 它通过结构风险最小化原理来提高泛化能力, 较好地解决了小样本、非线性、高维数、局部极小点等实际问题, 得到了广泛的应用^[19,20].

本文提出了基于递归量化分析和支持向量机的癫痫脑电分类算法. 在特征提取部分, 现有非线性特征都是把非线性参数如最大Lyapunov指数、相关维数、近似熵等作为特征^[1,4,6]. 本文提出基于递归量化分析(RQA)的癫痫脑电特征提取方法, 提取RQA量化值作为非线性特征. 非线性特征对应系统的动力学特性, 线性特征反映时间序列的时频特性, 采用非线性和线性特征相结合的方法, 将RQA量化值与变化系数、波动指数一起组成特征向量作为SVM的输入, 实现癫痫脑电的自动检测. 在临床脑电数据实验中, 该算法取得了较理想的检测准确率.

2 基于RQA的癫痫脑电特征提取方法

递归图是一种重现时间序列的系统动力学行为的非线性动力学分析方法, 该方法克服了对过程平稳的严格要求, 递归量化分析方法对时间序列的长度没有严格要求, 且对噪声不敏感. 脑电信号是非线性非平稳信号, 因此递归图可用来分析脑电信号.

递归图通过抽取系统中时间序列来重现系统的动力学行为. 相空间重构是非线性时间序列分析方法的基础与首要步骤, 对于长度为 N 的时间序列 $\{x_1, x_2, \dots, x_n\}$, 由延迟坐标相空间重构法可得到延迟向量

$$X(n) = [x_n, x_{n-\tau}, \dots, x_{n-(m-1)\tau}]^T, \\ n = (m-1)\tau + 1, (m-1)\tau + 2, \dots, N, \quad (1)$$

其中 m 为嵌入维数, τ 为延迟时间, 重构向量总个数为 $N = L - (m-1) \times n$.

递归图(RP)根据相空间中任意两个矢量之间的距离定义为

$$R_{i,j} = \Theta(\varepsilon - \|X(i) - X(j)\|), \\ i, j = 1, 2, \dots, N - (m-1)\tau, \quad (2)$$

其中, ε 为截止距离; $\|\cdot\|$ 为欧式范数; $\Theta(x)$ 为Heaviside函数,

$$\Theta(x) = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0. \end{cases} \quad (3)$$

截止距离 ε 是一个经验值, 它确定了一个以向量 $X(i)$ 为中心, ε 为半径的领域. 如果向量 $X(j)$ 位于该领域中, 就认为时间序列具有递归特性, 此时 $R_{i,j} = 1$, 反之则 $R_{i,j} = 0$, 通过(2)式可以把一个 $N \times N$ 的距离矩阵转换成0—1矩阵, 将 $R_{i,j} = 1$ 的值用黑点表示, 这样就可将时间序列的递归特性以图形的形式表示出来.

时间序列的递归特性依赖于递归点的几何形状, 观察递归图只能定性的分析系统的动力学特性. RQA方法是在递归图的基础上发展起来的一种非线性指标量化方法, 它根据递归点的密度、对角线段结构和垂直/水平线段结构的分析得到一系列的量化值. 本文提出的基于RQA的特征提取方法提取的特征能够很好的反映癫痫脑电的非线性动力学特征. RQA中的一些递归量化分析值定义如下:

递归率(RR): 指递归图中出现的点的个数与 $N \times N$ 矩阵中总数的比值, 较高的递归率通常意味着一个较强的周期性嵌入过程.

$$RR = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j}. \quad (4)$$

确定率(DET): 指递归图中出现的构成对角线段的点(有两个或两个以上的点组成)与总的重现点之间的比值. 它把个别发散的递归点与有规律而形成的特定图案的递归点区分开来.

$$DET = \frac{\sum_{l=l_{\min}}^N lP(l)}{N \sum_{i,j} R_{i,j}}, \quad (5)$$

其中, l 为线段长度, l_{\min} 为线段的最小长度, 对于随机信号, 相邻递归点较少, 因此, l_{\min} 一般取为2, $P(l)$ 是长度为 l 的对角线结构相应的比例.

信息熵 (ENTR): 对角线结构长度分布的香农熵. 信息熵用来衡量 RP 图所蕴含的信息量的多少, RP 图的周期性越强, 其信息熵越小.

$$\text{ENTR} = - \sum_{l=l_{\min}}^N p(l) \ln p(l), \quad (6)$$

$P(l)$ 是对角线结构长度分布的概率密度.

层状度 (LAM): 递归图中构成垂线/水平线的递归点与总的重现点之间的比值, 代表动力学系统的随机程度, 用来说明递归图的复杂程度.

$$\text{LAM} = \frac{\sum_{l=l_{\min}}^N vp(v)}{\sum_{i,j} R_{i,j}}, \quad (7)$$

$p(v)$ 是长度为 v 的垂直线/水平线相应的比例.

递归图中构成垂线段的平均长度 TT 和最大长度 V_{\max} 分别为

$$\text{TT} = \frac{\sum_{v=v_{\min}}^N vP(v)}{\sum_{v=v_{\min}}^N P(v)}, \quad (8)$$

$$V_{\max} = \max \left(\{v_l\}_{l=1}^N \right). \quad (9)$$

RQA 方法被广泛应用于分析非线性时间序列. 用递归图方法对重构后的数据进行分析, 应用递归量化分析方法量化递归图中递归点的几何特性, 得到一系列递归量化值. 本文提出了基于 RQA 的癫痫脑电信号特征提取方法, 研究了直接基于 RQA 特征的癫痫脑电自动检测方法, 从脑电信号中自动检测出癫痫脑电信号.

3 基于线性特征、非线性特征与支持向量机的癫痫脑电自动检测方法

3.1 支持向量机

支持向量机 (SVM) 是一种很好的解决小样本监督分类问题的工具. 在 VC 维理论和结构风险最小化原理下, SVM 对分析高维数非线性系统具有良好的性能, 在分析小样本数据方面得到了广泛的应用. SVM 的基本思想是, 对于线性不可分样本, 先进行非线性变换将数据映射到高维特征空间, 寻找能将这个特征空间分为两个区域的最优分类面, 或称超平面, 尽可能将输入数据分开.

假设存在这样的超平面, 对于一个训练样本 $G = \{(\mathbf{x}_i, y_i)\}_i^N$, \mathbf{x}_i 是输入向量, y_i 是类别标号 $y_i \in \{-1, 1\}$, N 是数据分段总数. 规定在超平面的正侧为 $y_i = +1$; 若在超平面的负侧则为 $y_i = -1$. 学习的目标就是构造这样一个分类面方程, 记为

$$\mathbf{w} \cdot \mathbf{x} + b = 0. \quad (10)$$

最优分类面满足两个条件: 一是将两类尽量正确的分开, 二是使两类的间隙最大, 即 $\|\mathbf{w}\|$ 最小, 用公式表示为

$$y_i[(\mathbf{w} \cdot \mathbf{x}_i) + b] - 1 \geq 0, \quad i = 1, 2, \dots, N. \quad (11)$$

使上式等号成立的样本叫做支持向量. 为简化计算, 使用 Lagrange 方法求上述最优分类面问题:

$$\min W(a) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j k(\mathbf{w}_i \cdot \mathbf{x}_j) - \sum_{j=1}^N a_j, \quad (12)$$

满足的约束条件为

$$\sum_{i=1}^N a_i y_i = 0, \quad a_i \in [0, C], \quad i = 1, 2, \dots, N, \quad (13)$$

其中, C 为惩罚因子, 起控制对错分样本惩罚的程度的作用. $k(x, x_i)$ 为满足 Mercer 条件的核函数. 用核函数 $k(x, x_i)$ 代替点积, 就相当于把原特征空间换到了新的特征空间, 相应的判别函数式变为

$$f(x) = \text{sgn} \left(\sum_{i=1}^N a_i^* y_i K(x, x_i) + b^* \right), \quad (14)$$

式中 m , a_i^* , b^* 分别表示支持向量的个数、支持向量系数和分类阈值. SVM 核函数选择径向基核函数

$$k(x, x_i) = \exp \left(-\frac{\|x - x_i\|^2}{2\delta^2} \right), \quad (15)$$

其中, δ 为宽度参数.

3.2 癫痫脑电自动检测方法

基于 RQA 的特征提取方法提取的特征能够很好的反映出癫痫脑电信号的非线性动力学特征. 变化系数和波动指数是反映癫痫脑电信号的时频特性的最常用的两个线性特征.

变化系数: 描述信号幅度的变化. 对于幅度变化规则的信号, 例如癫痫发作时 EEG 信号, 变化系数是一个较小的值. 定义如下:

$$V_c = \delta^2 / u^2, \quad (16)$$

其中 δ 为脑电信号的标准差, u 为信号的均值.

波动指数: 根据癫痫发作期信号波动较为剧烈, 常用波动指数衡量信号变化的强度, 对于长度为 n 的脑电信号波动指数定义为

$$F = \frac{1}{n} \sum_{i=1}^{n-1} |x(i+1) - x(i)|. \quad (17)$$

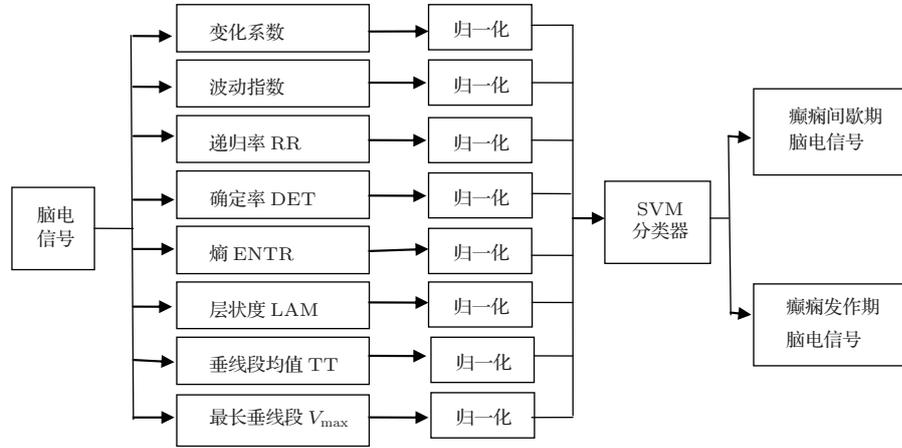


图1 癫痫脑电检测流程图

4 实验结果与分析

实验数据来自德国波恩癫痫研究室临床采集的脑电数据库, 采样频率为 173.6 Hz, 为临床颅内脑电. 其中癫痫患者未发作的间歇期脑电 (D 组) 和发作时的癫痫脑电 (E 组), 各 100 段, 每段 4096 点. 癫痫发作间歇期脑电记为 F 数据, 癫痫发作期脑电记为 S 数据. 实验选取癫痫发作间歇期和癫痫发作期脑电数据各 50 组, 每组 4096 点, 将每组数据再平均分为 4 个样本, 得到癫痫发作间歇期脑电和癫痫发作期脑电信号各 200 个样本, 每个样本长度为 1024 点数据.

实验中将癫痫发作期脑电作为负类, 癫痫发作间歇期脑电作为正类. 用三个指标来评价分类性能: 敏感度 (sensitivity)、特异性 (specificity) 和准确率 (accuracy). 本文用符号 Sen 表示敏感度, Spec 表示特异性, ACC 表示准确率, 三个指标的计算公式如下:

$$\text{Sen} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (18)$$

$$\text{Spec} = \frac{\text{TN}}{\text{TN} + \text{FP}}, \quad (19)$$

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{(\text{TP} + \text{FP} + \text{TN} + \text{FN})}, \quad (20)$$

为了进一步提高癫痫脑电自动检测的精度, 将非线性特征与线性特征相结合, 把提取的每段脑电信号的 RQA 特征值和变化系数、波动指数组成一个 8 维的特征向量, 对每一维特征向量进行归一化后输入到 SVM 分类器中, 从而实现癫痫脑电信号的自动检测. 具体流程图如图 1 所示.

其中是真阳个数 TP (true positive) 表示正样本预测正确的个数; FN (false negative) 表示被错分为负样本的正样本个数; FP (false positive) 表示被错分为正样本的负样本个数; TN (true negative) 为被正确预测的负样本的个数. 敏感性也被称为真正率, 代表的是被模型正确分类的正样本比例, 特异性也叫真负率, 代表被模型正确分类的负样本的比例.

利用递归量化分析方法分别对每个样本进行处理, 直接提取 RQA 特征值进行癫痫脑电的自动分类, 为进一步分析癫痫脑电和间歇期脑电信号的 RQA 特征值的差异, 分别分析了提取的癫痫发作间歇期脑电和发作期脑电的 RQA 特征分布图及其盒形图, 如图 2 至图 5 所示. 图 2 至图 5 中横坐标代表癫痫脑电样本序号, 纵坐标表示提取的 RQA 特征值; 图中 ‘+’ 代表间歇期脑电, ‘o’ 代表发作期脑电; 虚直线为间歇期脑电与发作期脑电直接基于 RQA 特征值的分类阈值, 阈值上方的特征值为分类正确的间歇期脑电, 阈值下方的特征值则为分类正确的发作期脑电.

从图 2 至图 5 可见, 对绝大多数样本, 提取的癫痫间歇期脑电的 RQA 特征值明显大于癫痫发作期脑电的, 两类样本有明显区别. 提取的癫痫脑电和间歇期脑电的递归率均值差异很大 (癫痫脑电均值为 0.75、标准差为 0.1; 间歇期脑电均值为

为0.57、标准差为0.14)。表1给出了直接基于递归量化分析的癫痫脑电信号的特征提取方法提取的RQA特征值的分类结果。表1的结果表明：直接基于RQA特征值的分类准确率较高，其中直接基

于确定率DET的分类准确率可达到90.25%，因此本文提取的RQA特征值能较好地反映间歇期脑电与发作期脑电这两种不同脑电状态的非线性动力学特性。

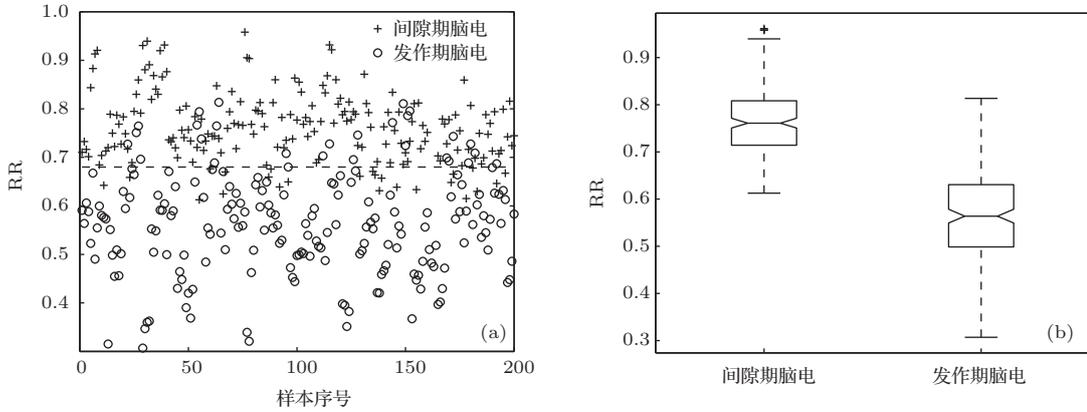


图2 癫痫发作间歇期和发作期脑电信号的递归率RR的分布图及盒形图 (a) 递归率RR的分布图; (b) 递归率RR的盒形图

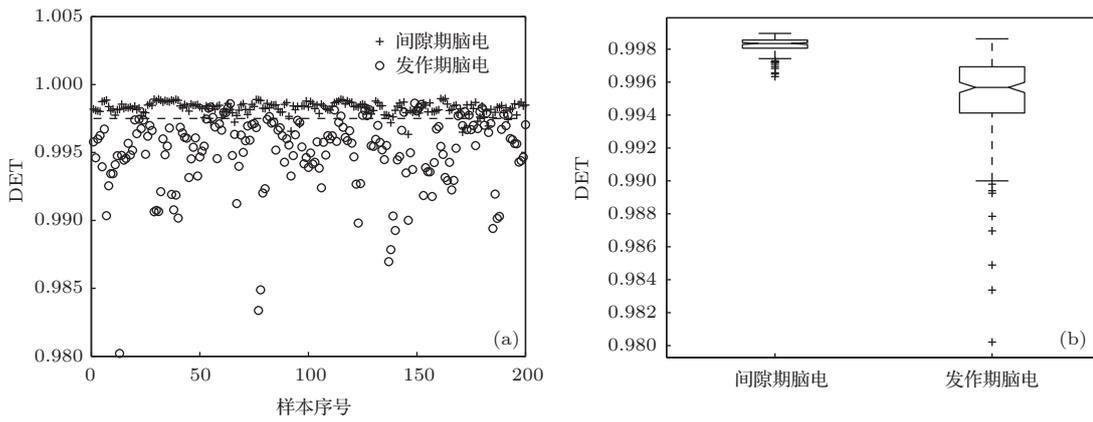


图3 癫痫发作间歇期和发作期脑电信号的确定率DET的分布图及盒形图 (a) 确定率DET的分布图; (b) 确定率DET的盒形图

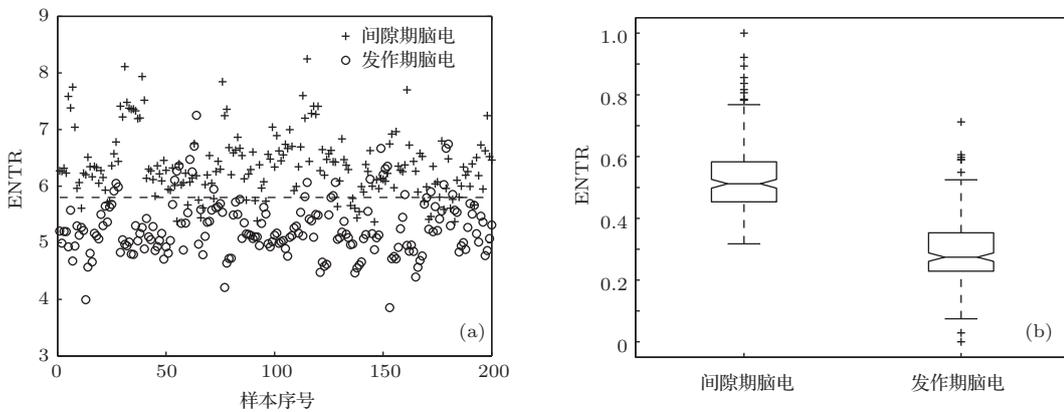


图4 癫痫发作间歇期和发作期脑电信号的熵ENTR的分布图及盒形图 (a) 熵ENTR的分布图; (b) 熵ENTR的盒形图

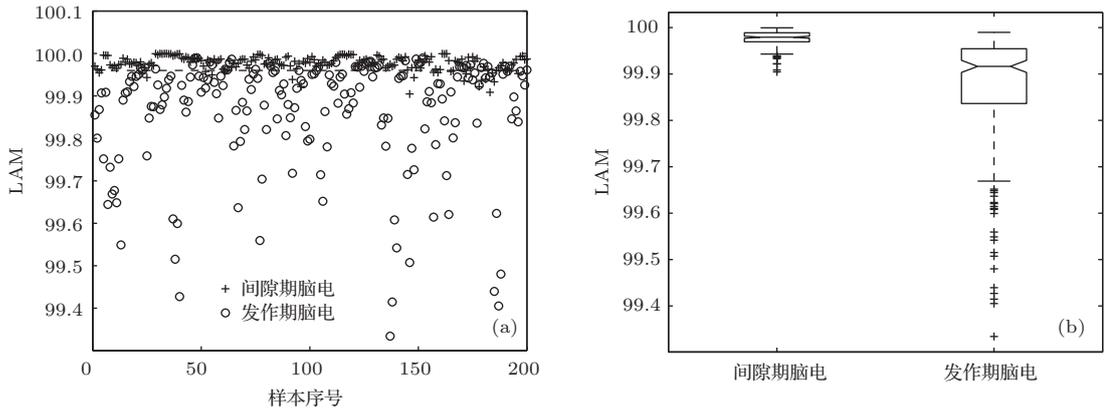


图5 癫痫发作间歇期和发作期脑电信号的层状度 LAM 的分布图及盒形图 (a) 层状度 LAM 的分布图; (b) 层状度 LAM 的盒形图

表1 癫痫脑电的 RQA 量化分析结果

	分类阈值	敏感度	特异性	准确率/%
RR	0.68	88.00	86.00	87.00
DET	0.9975	94.50	86.00	90.25
ENTR	5.80	86.00	87.00	86.50
LAM	99.96	87.50	78.50	83.00
TT	25.00	86.50	85.00	85.75
V_{max}	200.00	89.50	88.50	89.00

本文分别将6维 RQA 特征值与变化系数、波动指数相结合组成的8维特征向量作为SVM的输入。使用50段间歇期脑电和50段癫痫脑电作为SVM

分类器的测试样本, 剩余数据作为训练样本。将训练样本的RQA 特征值和变化系数、波动指数特征输入到SVM分类器训练, 获得最优参数, 然后将测试样本输入到已训练好的SVM分类器进行分类测试。当宽度参数 δ 取值4, C 取无穷大时, 训练的正确率为100%, 测试样本正确率为99%。实验中使用RQA 非线性特征值作为检测特征, 基于支持向量机的癫痫脑电检测结果为: 训练样本正确率为95%, 测试样本正确率为94%。实验结果如表2所示。

表2 基于 RQA 和 SVM 的癫痫脑电分类结果

	训练样本集/%			测试样本集/%		
	敏感度	特异性	准确率	敏感度	特异性	准确率
RQA+SVM	94.00	96.00	95.00	96.00	92.00	94.00
RQA+Linear+SVM	100.0	100.0	100.0	100.0	98.00	99.00

表3 所用特征及方法与现有方法比较

所用特征与方法	准确率/%
DFA+SVM ^[19]	74.00
Hurst 指数+SVM ^[8]	87.25
近似熵+SVM ^[6]	88.25
RQA+SVM	94.00

表4 本方法与其他方法的比较

采用的方法	准确率/%
小波系数+神经网络 ^[21]	94.25
样本熵+EML ^[22]	94.16
本方法	99.00

表3给出了基于RQA的癫痫脑电特征提取方法提取的特征与其他特征比较。从表2可见, 基于递归量化分析方法提取的RQA 特征值比去趋势波动分析(DFA)、Hurst 指数、近似熵特征等非线性

特征分类准确率高。将本文提出的方法与现有方法比较, 结果如表4所示。实验结果表明: 本文提出的直接基于递归量化分析特征的癫痫脑电自动检测方法的检测准确率较高, 结合RQA 特征值与线性特征基于支持向量机的癫痫脑电自动检测方法的准确率高于表4中列出的现有方法, 分类准确率可达到99%。

5 结 论

癫痫脑电的检测工作目前主要由由医疗工作者根据脑电图通过视觉检测来完成, 由于视觉检测费时、效率低, 因此癫痫脑电信号的特征提取和自动检测在临床上有很重要的意义, 可以减轻医疗工作者的劳动量^[1]。考虑到大脑是一个非常复杂的

非线性系统, 使用非线性动力学方法来研究脑电信号比传统的线性方法更能体现系统的内在本质特性. 本文试图从量化的复杂度角度来表征癫痫脑电的非线性动力学本质特性. RQA方法对信号数据的长度及稳态性要求较低, 受噪声影响小, 且无需考虑是否具有低维混沌特性, 广泛地应用于分析检测不同生理或病理状态脑电信号的动力学特征. 本文提出了基于RQA的癫痫脑电信号特征提取方法. 该方法克服了传统非线性统计量如最大Lyapunov指数、相关维数等需要长时稳态数据的缺点. 实验结果表明: 直接基于RQA特征的癫痫脑电自动检测方法的准确率高于直接基于去趋势波动分析(DFA)、Hurst指数与近似熵特征的. 采用非线性和线性特征相结合的方法, 将递归量化分析值和变化系数、波动指数一起组成癫痫检测的特征向量输入到SVM分类器中. 实验结果表明: 该方法的分类准确率可达到99%.

参考文献

- [1] Meng Q F, Zhou W D, Chen Y H, Peng Y H 2010 *Acta Phys. Sin.* **59** 123 (in Chinese)[孟庆芳, 周卫东, 陈月辉, 彭玉华 2010 物理学报 **59** 123]
- [2] Swiderski B, Osowski S, Rysz A 1995 *Chaos* **5** 82
- [3] Kannathal N, Min L C, Rajendra A U, Sadasivan P K 2005 *Computer Methods and Programs in Biomedicine* **80** 187
- [4] Kai C H, Sung N Y 2010 *Computers in Biology and Medicine* **40** 823
- [5] Rajendra A U, Molinari F, Vinitha S S, Chattopadhyay S, Hoong N K, Suri J S 2012 *Biomedical Signal Processing and Control* **7** 401
- [6] Yuan Q, Zhou W D, Li S F, Cai D M 2012 *Chinese Journal of Scientific Instrument* **33** 514 (in Chinese) [袁琦, 周卫东, 李淑芳, 蔡冬梅 2012 仪器仪表学报 **33** 514]
- [7] Yuan Q, Zhou W D, Li S F, Cai D M 2011 *Epilepsy Research* **96** 29
- [8] Cai D M, Zhou W D, Liu K, Li S F, Geng S J 2010 *Chinese Journal of Biomedical Engineering* **29** 836 (in Chinese)[蔡冬梅, 周卫东, 刘凯, 李淑芳, 耿淑娟 2010 中国生物医学工程学报 **29** 836]
- [9] Eckmann J P, Kamphorst S O, Ruelle D 1987 *Europhysics Letters* **5** 973
- [10] Acharya U R, Sree V, Chattopadhyay S, Yu W W, Alvin P C 2011 *International Journal of Neural Systems* **21** 199
- [11] Thomasson N, Hoepfner T J, Webber C L, Zbilut J P 2001 *Physics Letters A* **279** 94
- [12] Rajendra A U, Faustand O, Kannathal N 2005 *Computer Methods and Programs in Biomedicine* **80** 37
- [13] Ouyang G X, Li X L, Dang C Y, Richards D A 2008 *Clinical Neurophysiology* **119** 1747
- [14] Zhong J K, Song Z H, Hao W Q 2002 *Acta Biophysica Sinica* **18** 241 (in Chinese)[钟季康, 宋志怀, 郝为强 2002 生物物理学报 **18** 241]
- [15] Marwan W N, Kurths J 2002 *Phys. Rev. E* **66** 1539
- [16] Chen X M, Qiu Y H, Zhu Y S 2008 *Journal of Biomedical Engineering* **25** 39 (in Chinese)[陈晓鸣, 邱意弘, 朱贻盛 2008 生物医学工程杂志 **25** 39]
- [17] Liu X, Cheng J H, Lu H B, Zhang L P, Ma J, Dong X Z 2006 *Space Medicine & Medical Engineering* **19** 394 (in Chinese)[刘欣, 程九华, 卢虹冰, 张立藩, 马进, 董秀珍 2006 航天医学与医学工程 **19** 394]
- [18] Deng N Y, Tian Y J 2004 *A new method of data mining: support vector machines* (Science Press) (in Chinese) [邓乃扬, 田英杰 2004 数据挖掘中的新方法-支持向量机 (科学出版社)]
- [19] Cai D M, Zhou W D, Li S F, Wang J W, Jia G J, Liu X W 2011 *Acta Biophysica Sinica* **27** 175 (in Chinese)[蔡冬梅, 周卫东, 李淑芳, 王纪文, 贾桂娟, 刘学伍 2011 生物物理学报 **27** 175]
- [20] Nicolaou N, Georgiou J 2012 *Expert Systems with Applications* **39** 202
- [21] Ubeyli E D 2009 *Digital Signal Processing* 2009(19) 297
- [22] Song Y, Lio P 2010 *Journal of Biomedical Science and Engineering* **3** 556

Automatic detection of epileptic EEG based on recurrence quantification analysis and SVM*

Meng Qing-Fang[†] Chen Shan-Shan Chen Yue-Hui Feng Zhi-Quan

(School of Information Science and Engineering, University of Jinan, Jinan 250022, China)

(Shandong Provincial Key laboratory of Network Based Intelligent Computing, Jinan 250022, China)

(Received 11 October 2013; revised manuscript received 27 November 2013)

Abstract

Automatic detection and classification of epileptic EEG signals have been a significance method for the clinical diagnosis and treatment of epilepsy. The recurrence quantification analysis (RQA) based on the recurrence plot could visualize the recurrence behaviors of dynamical systems from the nonlinear time series and analysis of the recurrence properties. This paper presents a new feature extraction method for epileptic EEG signals based on the recurrence quantification analysis. Experimental results show that the seizure detection directly based on recurrence quantification analysis features has a higher detection performance; especially the classification accuracy based on the deterministic feature can be up to 90.25%. This paper also combines the RQA features with the variation coefficient and fluctuation index, and then puts the feature vectors into a support vector machine (SVM) to automatically detect the epileptic EEG from EEG recordings. Experimental results shows that the proposed methods could achieve a great classification accuracy of 99%.

Keywords: recurrence quantification analysis, recurrence plot, epileptic EEG, support vector machine

PACS: 05.45.Tp, 05.45.Pq, 05.45.Ac

DOI: [10.7498/aps.63.050506](https://doi.org/10.7498/aps.63.050506)

* Project supported by the National Natural Science Foundation of China (Grant Nos. 61201428, 61070130, 61173079), the Natural Science Foundation of Shandong Province, China (Grant Nos. ZR2010FQ020, ZR2011FZ003), the Shandong Distinguished Middle-aged and Young Scientist Encourage and Reward Foundation, China (Grant No. BS2009SW003), and the China Postdoctoral Science Foundation (Grant No. 20100470081).

[†] Corresponding author. E-mail: ise_mengqf@ujn.edu.cn