

· 论 著 ·

基于 RR 间期和多特征值的房颤自动检测分类



陈志博, 李健, 李智, 彭韵陶, 高兴姣

四川大学 电子信息学院 (成都 610041)

【摘要】 房颤 (AF) 是一种常见的心率失常疾病, 基于心电图 (ECG) 的房颤检测对临床诊断具有十分重要的意义。由于 ECG 信号的非线性和复杂性, 人工检测 ECG 信号的过程需要耗费大量时间且极易出现错误。为了克服上述问题, 本文提出基于 RR 间期的特征提取方法, 以稳健变异系数 (RCV) 描述 RR 间期的离散程度, 以偏态参数 (SKP) 描述 RR 间期的分布形状, 以 Lempel-Ziv 复杂度 (LZC) 描述 RR 间期的复杂度。最后将 RCV、SKP、LZC 特征值组成特征向量输入支持向量机 (SVM) 分类器模型, 实现房颤的自动分类检测。为验证本文方法的有效性和实用性, 以 MIT-BIH 房颤数据库数据进行验证, 最终分类结果显示, 灵敏度为 95.81%、特异度为 96.48%、准确率可达到 96.09%, 同时在 MIT-BIH 窦性心律数据库中实现了 95.16% 的特异度。实验结果表明, 本文所提方法是一种有效的房颤分类方法。

【关键词】 房颤; 稳健变异系数; 偏态; Lempel-Ziv 复杂度; 支持向量机

Automatic detection and classification of atrial fibrillation using RR intervals and multi-eigenvalue

CHEN Zhibo, LI Jian, LI Zhi, PENG Yuntao, GAO Xingjiao

School of Electronic Information, Sichuan University, Chengdu 610041, P.R.China

Corresponding author: LI Zhi, Email: lizhi@scu.edu.cn

【Abstract】 Atrial fibrillation (AF) is a common arrhythmia disease. Detection of atrial fibrillation based on electrocardiogram (ECG) is of great significance for clinical diagnosis. Due to the non-linearity and complexity of ECG signals, the procedure to manually diagnose the ECG signals takes a lot of time and is prone to errors. In order to overcome the above problems, a feature extraction method based on RR interval is proposed in this paper. The discrete degree of RR interval is described with the robust coefficient of variation (RCV), the distribution shape of RR interval is described with the skewness parameter (SKP), and the complexity of RR interval is described with the Lempel-Ziv complexity (LZC). Finally, the feature vectors of RCV, SKP, and LZC are input into the support vector machine (SVM) classifier model to achieve automatic classification and detection of atrial fibrillation. To verify the validity and practicability of the proposed method, the MIT-BIH atrial fibrillation database was used to verify the data. The final classification results show that the sensitivity is 95.81%, the specificity is 96.48%, the accuracy is 96.09%, and the specificity of 95.16% is achieved in the MIT-BIH normal sinus rhythm database. The experimental results show that the proposed method is an effective classification method for atrial fibrillation.

【Key words】 atrial fibrillation; robust coefficient of variation; skewness; Lempel-Ziv complexity; support vector machine

引言

在全球医疗保健系统中, 房颤 (atrial fibrilla-

tion, AF) 患者的检测和治疗变得越来越重要^[1-2]。由于房颤可使患者发生中风的风险增加近 5 倍^[3], 所以其早期的检测和治疗显得尤为重要。虽然市场上出现了一些基于一次性贴片系统^[4]和 iPhone 心电图 (electrocardiogram, ECG) 技术^[5]的新设备可专门用于房颤检测, 但是当患者表现出房颤症状

DOI: 10.7507/1001-5515.201710050

基金项目: 四川省科技计划项目 (2016GZ0092)

通信作者: 李智, Email: lizhi@scu.edu.cn

时,医生通过 12 导联 ECG 信号进行房颤检测仍然是最科学的方法^[6]。ECG 信号是能够反映心脏活动的周期性电信号,当房颤发生时,其 ECG 信号会表现为 P 波消失,代之以一系列形态不一致、方向各不相同的 f 波信号,且 RR 间期(两个 QRS 波中 R 波之间相隔的时间)绝对不规则^[7]。一些学者先将 ECG 信号中的 QRS-T 波消除,得到仅包含 P 波或 f 波的信号,然后再通过分析这部分信号进行房颤检测。Ladavich 等^[8]使用 P 波特征的高斯混合模型对 ECG 信号进行分类,灵敏度(sensitivity, Se)达到 98.10%,特异度(specificity, Sp)达到 91.70%。Weng 等^[9]采用小波分解,将 ECG 信号分解成不同频域段信号,然后提取各频域段信号的峰值平均功率比特征值输入支持向量机(support vector machine, SVM)分类器进行分类;Asgari 等^[10]在 Weng 等^[9]的基础上增加了各频域段信号的 log 熵特征,使用 SVM 交叉验证方法对房颤数据进行实验,实现了 97.00% 的灵敏度、97.10% 的特异度、97.10% 的准确率(accuracy, Acc)。但是 ECG 信号中 QRS-T 波群形态变异很大,一般情况下,难以被完全消除,且残存的信号容易使 P 波误检。Babaeizadeh 等^[11]结合 f 波或 P 波分析提高了算法的准确率,但是心房活动中 P 波或 f 波属于微弱信号,检测特征点会比较困难,而且在动态 ECG 信号中,极易受到噪声干扰的影响。Parvaresh 等^[12]提出直接提取 ECG 信号分段的自回归(auto regressive, AR)模型参数特征,不需要 R 波、P 波、f 波检测,也不需要 QRS-T 波消除,对 ECG 信号进行房颤检测,实现了 96.14% 的灵敏度、93.20% 的特异度。可是该方法模型必须自相关,且自相关系数要大于 0.5,否则会造成预测结果极不准确。

RR 间期在一定程度上可以反映心率^[13]。房颤 ECG 信号的一个突出特征是 RR 间期绝对不规则,且 R 波幅值较大,相比于对 P 波、f 波的检测定位,RR 间期的检测定位更容易且准确。目前 ECG 信号的 R 波检测方法较多,准确率可达到 99.00%^[14-15]。基于 RR 间期的房颤检测具有较强鲁棒性,可实现移动端的房颤检测。Li 等^[16]使用 RR 间期信息熵、RR 间期差概率密度分布和空白窗比率特征进行房颤分类,实现了 95.30% 的灵敏度、96.30% 的特异度、95.90% 的准确率。

从 ECG 信号中提取有效反映疾病的特征,是一个特征选择的过程^[17]。在实践应用中,统计学分析方法仅是对数据进行定性的分析,而非线性理论却能提取系统的演变信息,定量地描述系统的复杂

性。所以可以将 RR 间期的非线性参数分析法看作传统统计方法的一种补充,可以通过结合 RR 间期的统计量特征和非线性参数特征得到 RR 间期的多角度分布特征,以提高房颤检测的准确性。本文提取 RR 间期的统计特征——稳健变异系数(robust coefficient of variation, RCV)、偏态参数(skewness parameter, SKP)和非线性参数特征——Lempel-Ziv 复杂度(Lempel-Ziv complexity, LZC)组成特征向量,进行房颤分类检测。

1 实验数据

本文以麻省理工学院-贝斯以色列医院(Massachusetts Institute of Technology-Beth Israel Hospital, MIT-BIH)房颤数据库(MIT-BIH Atrial Fibrillation, MIT-BIH-AF) (<https://www.physionet.org/physiobank/database/afdb/>)^[18]中的数据作为实验数据测试来源,共选择包含了 25 条 ECG 信号的记录数据,每条 ECG 信号记录时间长度为 10 h。ECG 信号的采样频率是 250 Hz、分辨率为 12 bit、采样带宽是 0.1 ~ 40 Hz。

本文还选择了 MIT-BIH 窦性心律(MIT-BIH Normal Sinus Rhythm, MIT-BIH-NSR)数据库 (<https://physionet.org/physiobank/database/nsrdb/>)^[18]中 18 条时长达 24 h 的 ECG 信号记录数据。所有信号记录均无明显的心律失常,因而可用于验证房颤检测算法的特异度。MIT-BIH-AF 数据库与 MIT-BIH-NSR 数据库中房颤与非房颤心搏的具体数量如表 1 所示。

2 房颤分类

房颤分类系统流程如图 1 所示,主要包含 3 个技术步骤:

(1) 预处理:进行 ECG 信号 RR 间期的获取与分段;

(2) 特征提取:提取表征房颤段与非房颤段 RR 间期的特征向量;

(3) 分类:训练 SVM 分类器模型用于预测输入样本标签。

2.1 预处理

本文研究的重点是房颤的分类,所以将 MIT-BIH-AF 数据库中前 12 条 ECG 信号记录(记录号较小的 12 条)作为训练集训练分类模型,后 13 条 ECG 信号记录(记录号较大的 13 条)作为测试集进行分类模型准确性的检验。在对一个患者的全程 ECG 信号 RR 间期进行分段与实际类别标注时,分

表 1 MIT-BIH 数据库统计

Tab.1 Statistics sorted out from MIT-BIH database

数据库	记录数/个	心搏数/个		房颤段数/个	房颤总持续时间/h
		房颤	非房颤		
MIT-BIH-AF	25	519 816	701 747	299	93.4
MIT-BIH-NSR	18	—	1 729 629	0	0




图 1 房颤分类系统流程图

Fig.1 Flow diagram of atrial fibrillation classification system

别取 32、64 和 128 个心搏为一段，如图 2 所示，有的 RR 间期段内不仅包含房颤心搏，也包含非房颤心搏，对于这些 RR 间期段，若房颤心搏数量超过该段总心搏数量的一半时，则标注这些段是房颤段，否则标注为非房颤段。对 MIT-BIH 数据库进行分段、标注整理，各数据库中的不同分段长度，房颤与非房颤段数目如表 2 所示。

2.2 特征提取

实验中本文提取了 RR 间期的 3 个特征值：稳健变异系数、偏态参数、Lempel-Ziv 复杂度。

(1) 稳健变异系数：

在稳健统计技术中，稳健变异系数（以符号 RCV 表示）定义为归一化 RR 间期四分位间距与 RR 间期中位数的比值。其中，四分位间距（interquartile range, IQR），以符号 IQR 表示；中位数（median, M），以符号 M 表示，则计算公式如式 (1) 所示：

$$RCV = \frac{IQR \times 0.7413}{M} \quad (1)$$

式 (1) 中的 $IQR \times 0.7413$ 表示的是归一化 RR 间期四分位间距，使之等于正态分布的标准差。

(2) 偏态参数：

偏态参数（以符号 SKP 表示）可以评估数据分布形态中表现的偏斜方向和程度，能够对数据分布的非对称性进行描述。一组 RR 间期序列的偏态参数计算公式如式 (2) 所示：

$$SKP = \frac{1}{N-1} \sum_{i=1}^N \frac{(RR_i - \overline{RR})^3}{SD^3} \quad (2)$$

其中， RR_i 表示第 i 个 RR 间期， \overline{RR} 表示 RR 间期平均值， N 是 RR 间期长度，标准差（standard deviation, SD），以符号 SD 表示。

(3) Lempel-Ziv 复杂度：

Lempel-Ziv 复杂度算法，是将一个长度一定的序列的复杂度视为该序列中新模式随序列长度的递增而产生的速度^[19]，其具体算法如下：

步骤一：首先将已知序列 $X = (x_1, x_2, \dots, x_n)$ 重构，计算该序列的平均值 \bar{x} ，将序列中满足 $x_i > \bar{x}$ 的部分都置“1”，满足 $x_i \leq \bar{x}$ 的部分都置“0”，通过这样的方法将原序列 X 重构为一个仅包括“0”和“1”的符号序列 $S = (s_1, s_2, \dots, s_n)$ 。

步骤二：对上面所得（“0”，“1”）序列中已存在的一个子串 $S = (s_1, s_2, \dots, s_m)$ ，在其后加上一个字符 s_{m+1} ，或者是加上一串 k 个字符的 $Q = (s_{m+1}, s_{m+2}, \dots, s_{m+k})$ ，得到一符号序列 $SQ = (s_1, s_2, \dots, s_{m+1}, s_{m+2}, \dots, s_{m+k})$ ；将字符串 SQ 去除最后一个字符得到 SQv ，即 $SQv = (s_1, s_2, \dots, s_{m+1}, s_{m+2}, \dots, s_{m+k-1})$ ，然后检查 Q 是否与 SQv 中已出现过的子串相同，即查看是否存在某个 $i, 1 \leq i \leq m$ ，使 $(s_{m+1}, s_{m+2}, \dots, s_{m+k}) = (s_i, s_{i+1}, \dots, s_{i+k-1})$ ；若是存在，就将 Q 加到后面的方式称为“复制”，此时，将 Q 延长，也就是增加 k ，不停重复上面的步骤，一直到 Q 不属于 SQv 中已出现过的子串为止；而将 Q 不属于 SQv 中已出现过的子串的过程称为“插入”，在“插入”时将一个“.”符号放在 Q 后；然后将“.”前面的全部字符都作为 S ，循环上面的步骤。

步骤三：如上，一个序列被“.”断分为多个字符串段，定义得到的字符串段数量为“复杂度”（以符号 $C(n)$ 表示）。

步骤四：根据文献 [19]，一个 $S \in \{“0”, “1”\}$ 的序列，其复杂度会趋近一个值 $b(n)$ ，计算




图2 RR 间期与对应的类别标注
Fig.2 RR interval and corresponding class labeling

表 2 MIT-BIH 数据库 RR 间期分段统计

Tab.2 Statistics of RR interval segment sorted out from MIT-BIH database

数据	32 个心搏为一段		64 个心搏为一段		128 个心搏为一段	
	房颤段	非房颤段	房颤段	非房颤段	房颤段	非房颤段
MIT-BIH-AF 训练集	4 431	13 564	2 221	6 756	1 110	3 286
MIT-BIH-AF 测试集	11 779	8 312	5 901	4 148	2 920	2 069
MIT-BIH-NSR	—	62 675	—	28 204	—	15 781

公式如式 (3) 所示:

$$\lim_{n \rightarrow \infty} C(n) = b(n) = \frac{n}{\log_2 n} \quad (3)$$

$b(n)$ 表示的是序列的渐进形态, 可以使用 $b(n)$ 将 $C(n)$ 进行归一化, 得到“相对复杂度”测度 (以符号 $c(n)$ 表示), 计算公式如式 (4) 所示:

$$c(n) = \frac{C(n)}{b(n)} \quad 0 \leq c(n) \leq 1 \quad (4)$$

从计算过程可知, Lempel-Ziv 复杂度度量的是一个序列中产生新模式的速度, $c(n)$ 取不同值, 序列中产生新模式的速度不同, 该序列表现了不同的特性; 或者可以从另一个角度认为 $c(n)$ 是计算一个时间序列同随机序列相似的程度。

2.3 SVM 分类器

在机器学习领域, SVM 是一个基于统计理论的、有监督的学习模型, 是一种常见的分类判别方法。给定一个训练集, 如式 (5) 所示:

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (5)$$

其中, $x_i \in R^n, y_i \in \{+1, -1\}, i = 1, 2, \dots, N$ 。 x_i 为第 i 个特征向量, 也称为实例, y_i 为 x_i 的两种 +1、-1 类标记, (x_i, y_i) 称为样本点。设定这一训练集实例能够被一个超平面进行线性划分, 该超平面对应于一个方程, 如式 (6) 所示:

$$(w \cdot x) + b = 0 \quad (6)$$

因为支持向量与超平面之间的距离为 $\frac{1}{\|w\|}$, 所以线性可分情况下的 SVM 的最优化问题分别如式 (7)、(8) 所示:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (7)$$

$$s.t. \quad y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, N \quad (8)$$

这是一个凸二次规划问题, 使用拉格朗日对偶性, 最后可求得最优分类决策函数如式 (9) 所示:

$$f(x, w, b) = \text{sgn} \left\{ \sum_{i=1}^n \alpha^* y_i K(x_i \cdot x) + b^* \right\} \quad (9)$$

上式训练集中对应于 α^* 的样本点就是支持向

量, b^* 表示的是分类阈值, $K(x_i, x_j)$ 是将输入空间映射到高维特征空间的核函数。SVM 由于其具有良好的结构风险最小化的生成能力, 已被广泛应用于实际分类问题^[20]。

2.4 评估指标

本文利用灵敏度(以符号 Se 表示)、特异度(以符号 Sp 表示)、准确率(以符号 Acc 表示)来评估房颤分类效果, 且这 3 个指标由真阳性(true positive, TP)(以符号 TP 表示)、真阴性(true negative, TN)(以符号 TN 表示)、假阳性(false positive, FP)(以符号 FP 表示)、假阴性(false negative, FN)(以符号 FN 表示)决定, 计算公式分别如式(10)、(11)、(12)所示:

$$Se = \frac{TP}{TP + FN} \times 100\% \quad (10)$$

$$Sp = \frac{TN}{TN + FP} \times 100\% \quad (11)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (12)$$

3 实验分析

3.1 分类的实现

房颤分类实验首先提取 RR 间期的稳健变异系数、偏态参数和 Lempel-Ziv 复杂度, 组成特征向量, 然后再结合 MIT-BIH 数据库中房颤的类型标注, 将训练集特征向量与房颤标注一起输入 SVM 分类器进行训练, 最后将测试集的特征向量输入上述已经训练好的分类器, 对测试集进行分类。其中, 本文采用了径向基函数(radial basis kernel, RBF)核的 SVM, 该分类器包含了 Chang 等^[21]开发的支持向量机库(a library for support vector machines, LIBSVM)工具箱。

3.2 实验结果分析

如前文 2.1 小节所述, 当 RR 间期段长度分别为 32、64、128 个点时, MIT-BIH-AF 数据库和 MIT-BIH-NSR 数据库的分类效果如表 3 所示, 本方法对于不同 RR 间期长度均获得了不错的分类效果, 其中当取 RR 间期长度为 64 个点时, 得到的分类效果

最好, 在 MIT-BIH-AF 数据库测试集中达到了 95.81% 的灵敏度、96.48% 的特异度和 96.09% 的准确率, 在 MIT-BIH-NSR 数据库中达到了 95.16% 的特异度。

当 RR 间期长度为 64 个点时, 测试集的稳健变异系数、偏态参数、Lempel-Ziv 复杂度特征组成的三维图如图 3 所示, 可以看出房颤与非房颤三维特征值的分布区域存在明显差异。理论上非房颤 RR 间期的稳健变异系数值应较小, 但是部分非房颤 RR 间期的稳健变异系数出现较大值, 与房颤 RR 间期的特征值发生交叠, 降低了分类的准确性。分布在图中左上部的为非房颤特征点, 这些非房颤点的稳健变异系数值较大, 出现了异常, 但 Lempel-Ziv 复杂度特征的加入, 得到这些点的 Lempel-Ziv 复杂度值较小, 使这些点分布在了 Lempel-Ziv 复杂度轴的靠负轴方向, 而房颤的 Lempel-Ziv 复杂度值较大, 分布在了 Lempel-Ziv 复杂度轴的靠正轴方向, 使房颤与非房颤的三维特征值分布区域有了明显的可分性, 提高了分类准确性。

近年来房颤分类检测文献的分类效果, 以及本文所提统计特征结合非线性参数特征的分类效果如表 4 所示, 所得分类效果都是基于 MIT-BIH-AF 数据库。从表中可以发现, 与其他算法对比, 本文所提房颤检测算法在灵敏度、特异度和准确率方面都具有优势, 实现了房颤的准确诊断。

4 结论

计算机自动分析、检测房颤具有很大的实用性。本文从离散程度、分布形态、复杂度等多个角度对 RR 间期进行特征分析, 并且在各角度分析中选择较有效的参数进行特征表征。基于 RR 间期房颤检测局限性的根源在于: 没有加入 ECG 信号的其他特征(如 P 波), 这是因为 ECG 信号上的 P 波幅度相对较低, 在移动期间可能难以准确记录。若 ECG 信号采集设备能够采集到低噪声的 ECG 信号数据, 可以考虑结合 P 波特征进行检测, 使房颤检测系统更加精确、高效。

表 3 测试集的分类评估指标值

Tab.3 Clustering values of evaluation indicators for testing set

数据库	32 个点			64 个点			128 个点		
	灵敏度 (%)	特异度 (%)	准确率 (%)	灵敏度 (%)	特异度 (%)	准确率 (%)	灵敏度 (%)	特异度 (%)	准确率 (%)
MIT-BIH-AF	94.03	95.43	94.61	95.81	96.48	96.09	95.07	96.33	95.59
MIT-BIH-NSR	—	92.62	—	—	95.16	—	—	92.78	—




图3 稳健变异系数、偏态参数、Lempel-Ziv 复杂度特征值三维图

Fig.3 Three-dimensional map for the eigenvalue of robust coefficient of variation, parameter of skewness and Lempel-Ziv complexity

表4 不同算法分类效果对比

Tab.4 Comparison of classification effects of different algorithm

文献	特征	灵敏度 (%)	特异度 (%)	准确率 (%)
Du 等 ^[22]	TQ 间期内 f 波的平均数	94.13	—	93.67
Ladavich 等 ^[8]	P 波特征高斯混合模型	98.10	91.70	—
García 等 ^[23]	TQ 间期相对小波能量	91.20	94.50	93.30
Kennedy 等 ^[24]	样本熵 + 变异系数 + 差值均方平方根 + 绝对中位差	92.80	98.30	—
Li 等 ^[16]	空白窗比率 + 信息熵 + RR 间期差概率密度分布	95.30	96.30	95.90
Afdala 等 ^[25]	RR 间期香农熵	85.31	84.82	85.39
本文	稳健变异系数 + 偏态参数 + Lempel-Ziv 复杂度	95.81	96.48	96.09

参考文献

- Chugh S S, Havmoeller R, Narayanan K, *et al.* Worldwide epidemiology of atrial fibrillation a global burden of disease 2010 study. *Circulation*, 2014, 129(8): 837-847.
- Healey J S, Connolly S J, Gold M R, *et al.* Subclinical atrial fibrillation and the risk of stroke. *N Engl J Med*, 2012, 366(2): 120-129.
- Sanna T, Diener H C, Passman R S, *et al.* Cryptogenic stroke and underlying atrial fibrillation. *N Engl J Med*, 2014, 370(26): 2478-2486.
- Barrett P M, Komatireddy R, Haaser S, *et al.* Comparison of 24-hour Holter monitoring with 14-day novel adhesive patch electrocardiographic monitoring. *Am J Med*, 2014, 127(1): 95.e11-95.e17.
- Lowres N, Neubeck L, Salkeld G, *et al.* Feasibility and cost-effectiveness of stroke prevention through community screening for atrial fibrillation using iPhone ECG in pharmacies. *The SEARCH-AF study. Thromb Haemost*, 2014, 111(6): 1167-1176.
- Harris K, Edwards D, Mant J. How can we best detect atrial fibrillation? *J R Coll Physicians Edinb*, 2012, 42(Suppl 18): 5-22.
- 魏晓玲, 刘明, 苑新, 等. 基于多特征融合与卷积神经网络的房颤检测. *激光杂志*, 2017, 38(5): 176-179.
- Ladavich S, Ghoraani B. Rate-independent detection of atrial fibrillation by statistical modeling of atrial activity. *Biomed Signal Process Control*, 2015, 18: 274-281.
- Weng Binwei, Wang J J, Michaud F, *et al.* Atrial fibrillation detection using stationary wavelet transform analysis. *Conf Proc IEEE Eng Med Biol Soc*, 2008, (2008): 1128-1131.
- Asgari S, Mehrnia A, Moussavi M. Automatic detection of atrial fibrillation using stationary wavelet transform and support vector machine. *Comput Biol Med*, 2015, 60: 132-142.
- Babaeizadeh S, Gregg R E, Helfenbein E D, *et al.* Improvements in atrial fibrillation detection for real-time monitoring. *J Electrocardiol*, 2009, 42(6): 522-526.
- Parvaresh S, Ayatollahi A. Automatic atrial fibrillation detection using autoregressive modeling//*The International Conference on Biomedical Engineering and Technology*. Kuala Lumpur: Asia-Pacific Chemical, Biological & Environmental Engineering Society, 2011: 105-108.
- 武扬. 心电特征提取及分类方法研究. 上海: 上海交通大学, 2012.

- 14 Yazdani S, Vesin J M. Adaptive mathematical morphology for QRS fiducial points detection in the ECG//The 41st Annual International Conference of Computing in Cardiology, Cambridge, MA: MIT's Laboratory for Computational Physiology, 2014: 725-728.
- 15 Yeh Y C, Wang Wenjune. QRS complexes detection for ECG signal: the difference operation method. *Comput Methods Programs Biomed*, 2008, 91(3): 245-254.
- 16 Li Yanjun, Tang Xiaoying, Wang Ancong, *et al.* Probability density distribution of delta RR intervals: a novel method for the detection of atrial fibrillation. *Australasian Physical & Engineering Sciences in Medicine*, 2017, 40(3): 707-716.
- 17 赵勇, 洪文学, 孙士博. 基于多特征和支持向量机的心律失常分类. *生物医学工程学杂志*, 2011, 28(2): 292-295.
- 18 Goldberger A L, Amaral L A, Glass L, *et al.* PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 2000, 101(23): E215-E220.
- 19 Lempel A, Ziv J. On the complexity of finite sequences. *IEEE Transactions on Information Theory*, 1976, 22(1): 75-81.
- 20 Byun H, Lee S W. A survey on pattern recognition applications of support vector machines. *International Journal of Pattern Recognition and Artificial Intelligence*, 2003, 17(3): 459-486.
- 21 Chang C C, Lin C J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3, SI): 389-396.
- 22 Du Xiaochuan, Rao N, Qian Mengyao, *et al.* A novel method for real-time atrial fibrillation detection in electrocardiograms using multiple parameters. *Ann Noninvasive Electrocardiol*, 2014, 19(3): 217-225.
- 23 García M, Ródenas J, Alcaraz R, *et al.* Application of the relative wavelet energy to heart rate Independent detection of atrial fibrillation. *Comput Methods Programs Biomed*, 2016, 131: 157-168.
- 24 Kennedy A, Finlay D D, Guldenring D, *et al.* Automated detection of atrial fibrillation using R-R intervals and multivariate-based classification. *J Electrocardiol*, 2016, 49(6): 871-876.
- 25 Afdala A, Nuryani N, Nugroho A S. Automatic detection of atrial fibrillation using basic shannon entropy of RR interval feature. *International Conference on Science and Applied Science*. Indonesia: IOPScience, 2017, 795(1): 012038.

收稿日期: 2017-10-23 修回日期: 2018-04-27
本文编辑: 陈咏竹