

DOI: 10.3724/SP.J.1219.2012.00628

## 基于隐马尔可夫模型的躯感网心电图信号特征提取方法

凤超<sup>1,2</sup>, 梁炜<sup>1</sup>, 张晓玲<sup>1</sup>, 杨雨沱<sup>1,2</sup>, 谈金东<sup>1</sup>

(1. 中国科学院沈阳自动化研究所工业控制网络及系统研究室, 辽宁 沈阳 110016; 2. 中国科学院研究生院, 北京 100049)

**摘要:** 为了解决躯感网的心电信号特征提取问题, 结合心电图信号波形的特征区间, 建立了面向心电图信号特征提取的离散隐马尔可夫模型; 并面向该模型定制了专家标注选取、导联选取、观察数据归一化、三元组初始值选取以及训练数据量选取等方法. 最后, 采用 Baum-Welch 算法训练 HMM 模型的参数, 并利用 Viterbi 算法提取心电图的信号特征. 仿真结果表明, 基于 HMM 的心电图信号特征提取算法的复杂度较低、精确度较高、实时性较好, 适合在线处理非线性、动态变化的心电图信号, 能够满足基于躯感网的心电图信号特征提取的性能要求.

**关键词:** 躯感网; 心电图信号; 隐马尔可夫模型; 特征提取

中图分类号: TP391

文献标识码: A

文章编号: 1002-0411(2012)-05-0628-09

### Feature Extraction Method for ECG Signal Based on HMM in Body Sensor Network

FENG Chao<sup>1,2</sup>, LIANG Wei<sup>1</sup>, ZHANG Xiaoling<sup>1</sup>, YANG Yutuo<sup>1,2</sup>, TAN Jindong<sup>1</sup>

(1. Laboratory of Industrial Control Networks and Systems, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;

2. Graduate University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** A discrete hidden Markov model (HMM) for ECG (electrocardiogram) signal feature extraction is built, which solves problems of ECG signal feature extraction in body sensor network and considers the feature partition of ECG waveform. Based on the proposed HMM, methods of expert annotation selection, lead selection, normalization of observation data, triple initial value selection, and training data quantity selection are customized. Finally, the HMM model parameters are trained by using the Baum-Welch algorithm, and the ECG signal feature is extracted by using the Viterbi algorithm. Simulation results show that this feature extraction method for ECG signal based on HMM has lower complexity, higher accuracy, and better timeliness, which is suitable for processing nonlinear and dynamic changing ECG signal on-line and can satisfy the performance requirements of ECG signal feature extraction in body sensor network.

**Keywords:** body sensor network; ECG (electrocardiogram) signal; hidden Markov model (HMM); feature extraction

## 1 引言 (Introduction)

心血管疾病是威胁人类生命和健康的“头号杀手”. 在所有的心血管疾病中, 心律失常是主要的死亡诱因之一, 并且往往伴随并发症, 所以心律失常问题的及时发现至关重要.

目前, 关于心律失常的检测、诊断和评估主要基于心电图 (electrocardiogram, ECG)<sup>[1]</sup>. 传统的 ECG 检测包括两种方法: 静态 ECG 和动态 ECG. 静态 ECG 要求病人在静态下卧床测试, 干扰少、波形清晰, 但存在检查时间短、记录数据少、不易发现偶发性问题、无法实现全天候监测等问题. 动态 ECG<sup>[2]</sup> 要求病人 24 小时以上长时间随身携带心电图仪, 随时捕捉病人在工作紧张劳累、精神受到刺

激、情绪激动等特殊状态下的心脏病变反应, 但目前只提供心电信号的记录和存储功能, 不具备实时分析和诊断功能. 采用基于躯感网的 ECG 信号检测方法, 通过移动设备和无线传感器实时捕捉人体的生理状态, 并实时传送给医生进行在线分析和诊断, 克服了传统 ECG 检测方法的缺陷, 具有灵活性、时效性、连续性、经济性等优点, 成为目前的研究热点.

目前国内外针对基于躯感网的 ECG 信号检测方法的研究刚刚起步<sup>[3]</sup>. 研究的主要难点在于准确实时的 ECG 信号特征提取方法, 这是因为资源受限的嵌入式设备对算法的时间复杂度和空间复杂度要求苛刻. 目前用于 ECG 信号特征提取的方法主要有

基金项目: 国家自然科学基金资助项目 (60725312, 61100159, 61174026, 61172145); 国家科技重大专项基金资助项目 (2010ZX03006-005-01, 2011ZX03005-002); 国家 863 计划资助项目 (2011AA040101, 2011AA040103); 国家 973 计划前期研究专项课题 (2010CB334705); 中国科学院知识创新工程重要方向性项目 (KGCX2-EW-104).

通讯作者: 梁炜, weiliang@sia.cn 收稿/录用/修回: 2011-11-24/2012-03-09/2012-03-16

神经网络<sup>[4-5]</sup>、小波变换<sup>[6-7]</sup>、启发式规则<sup>[8]</sup>、卡尔曼滤波<sup>[9]</sup>以及隐马尔可夫模型法(HMM)<sup>[10-12]</sup>. 其中, 神经网络法模型训练时间长, 不能满足数据的实时处理要求; 启发式规则法在处理动态变化信号的过程中需要根据经验设定阈值, 阈值的选择直接影响算法的性能, 不能准确反映信号的动态变化情况且无法跟踪突发信号; 小波变换法特征提取精度较高, 但算法复杂度较高, 不适用于嵌入式设备和移动设备; 卡尔曼滤波法不适合非线性系统, 对 ECG 信号的处理性能逊于其它算法. HMM 的特点是处理非线性动态信号的精度高, 算法复杂度低, 因此, 适用于资源严格受限的躯感网 ECG 信号特征提取.

本文面向躯感网, 结合 ECG 信号的特征以及特征提取的性能要求和约束, 提出了一个基于离散 HMM 模型的低开销、实时 ECG 信号特征提取方法. 该方法在建立了面向 ECG 信号特征提取的离散隐马尔可夫模型基础上, 采用 Baum-Welch 算法训练 HMM 模型的参数, 在模型训练过程中, 重点解决了 5 个可以影响模型优化参数获取的问题, 并利用 Viterbi 算法提取 ECG 的信号特征, 使得 ECG 信号特征提取的精度和实时性得到了较大幅度的提高.

## 2 ECG 信号特征及 HMM 原理概述 (Overviews of ECG signal feature and HMM theory)

### 2.1 ECG 信号波形及生理意义

ECG 信号周期性产生, 其波形包括 4 个波段: P 波、QRS 复合波、T 波和 U 波, 如图 1 所示<sup>[13]</sup>. 单个周期内, 各个波段的特征及生理意义具体介绍如下.

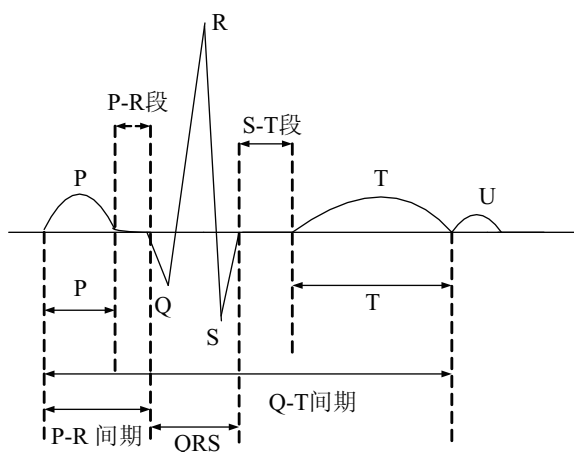


图 1 单个周期内的心电图波形  
Fig.1 ECG waveform in one cycle

(1) P 波: 心房除极波, 反映左右两心房的电激动过程. 正常 P 波的历时  $0.08\text{ s} \sim 0.11\text{ s}$ , 波幅不超

过  $0.25\text{ mV}$ .

(2) P-R 间期 (或 P-Q 间期): 指从 P 波起点到 QRS 波群起点之间的时间. 代表由窦房结产生的兴奋, 经心房、房室交界、房室束及其分支传到心室, 并引起心室开始兴奋所需的时间, 正常为  $0.12\text{ s} \sim 0.20\text{ s}$ . 若超过  $0.20\text{ s}$ , 一般表明有房室传导阻滞.

(3) QRS 波群: 反映两心室细胞膜内外电位差消失过程中的电位变化. 典型的 QRS 波群包含 3 个紧密相连的电位波动: 第一个向下的波称为 Q 波; 紧接着是向上且高而尖锐的 R 波; 最后是向下的 S 波. QRS 波群的持续时间为从心室开始激动至心室完全激动所经过的时间, 一般历时  $0.06\text{ s} \sim 0.08\text{ s}$ , 不超过  $0.10\text{ s}$ .

(4) T 波: 为心室的晚期复极波, 反映两心室细胞膜内外恢复电位差过程的电位变化. T 波方向应与 QRS 波群的主波方向一致, 在 V1 导联中可不一致. 在以 R 波为主的导联中, 其波幅应不低于本导联 R 波的  $1/10$ . T 波的宽度一般为  $0.1\text{ s} \sim 0.25\text{ s}$ .

(5) Q-T 间期: 指从 Q 波开始至 T 波终止的时间, 代表心室由开始激动状态至完全恢复静止状态所需时间, 与心跳的快慢有关. 当心率为  $75\text{ 次/min}$  时, Q-T 间期为  $0.30\text{ s} \sim 0.40\text{ s}$ . 心率增快, Q-T 间期缩短; 心率减慢, Q-T 间期延长. 我国人体的平均 Q-T 间期为  $0.36\text{ s}$ .

ECG 信号特征提取的目的在于对上述波形区间进行划分, 根据划分结果计算重要间期, 如 P-R 间期、Q-T 间期等.

### 2.2 HMM 基本原理

HMM 包括两个随机变量序列: 一个是观察不到的马尔可夫链  $\{q_t \geq 0\}$ , 称为隐马尔可夫链; 另一个是可以观察到的随机序列  $\{o_t \geq 0\}$ , 称为观察链.

HMM 主要包括以下几种元素:

- 隐藏状态空间  $S = \{s_1, s_2, \dots, s_N\}$ , 其中,  $q_t \in \{s_1, s_2, \dots, s_N\}$ ,  $q_t$  表示  $t$  时刻的状态,  $N$  表示隐藏状态数;

- 观察序列状态空间  $V = \{v_1, v_2, \dots, v_M\}$ , 其中,  $M$  表示每一个状态的不同符号数;

- 状态转移概率分布  $\mathbf{A} = (a_{ij})$ , 其中,

$$a_{ij} = p(q_{t+1} = s_j | q_t = s_i), \quad 1 \leq i, j \leq N \quad (1)$$

- 状态  $i$  中观察序列的概率分布  $\mathbf{B} = [b_i(k)]$ , 其中,

$$b_i(k) = p(o_t = v_k | q_t = s_i), \quad 1 \leq k \leq M, 1 \leq i \leq N \quad (2)$$

$o_t$  表示在  $t$  时刻状态为  $s_i$  的观察值;

- 初始状态分布  $\boldsymbol{\pi} = [\pi_i]$ , 其中,

$$\pi_i = p(q_i = s_i), \quad 1 \leq i \leq N \quad (3)$$

利用  $\mathbf{A}$ 、 $\mathbf{B}$ 、 $\boldsymbol{\pi}$  可以完全确定一个 HMM. 通常将一个 HMM 简记为三元组  $\boldsymbol{\lambda} = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$ .

将一个 HMM 应用到实际, 需要解决以下 3 个基本问题:

**问题 1** 已知观察序列  $O = o_1, o_2, \dots, o_T$  和模型  $\boldsymbol{\lambda} = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$ , 给定模型  $\boldsymbol{\lambda}$ , 如何有效地计算产生观察序列  $O$  的条件概率, 即计算  $P(O|\boldsymbol{\lambda})$ .

**问题 2** 已知观察序列  $O = o_1, o_2, \dots, o_T$  和模型  $\boldsymbol{\lambda} = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$ , 如何选择在某种意义上最佳 (即能最好解释观察序列) 的状态序列.

**问题 3** 如何调整模型参数  $\boldsymbol{\lambda} = (\mathbf{A}, \mathbf{B}, \boldsymbol{\pi})$ , 以使条件概率  $P(O|\boldsymbol{\lambda})$  最大.

第一个问题是模型参数训练过程中的概率求取问题, 目前采用的常用方法是前向-后向算法; 第二个问题是特征提取问题, 目前的常用方法是 Viterbi 算法<sup>[13-14]</sup>; 第三个问题是模型参数训练问题, 目前的常用方法是 Baum-Welch 算法<sup>[15]</sup>.

### 3 基于 HMM 的 ECG 信号特征提取方法 (Feature extraction method for ECG signal based on HMM)

本文提出的基于 HMM 的 ECG 信号特征提取方法的流程见图 2.

#### 3.1 面向 ECG 信号特征提取的 HMM 模型

本节利用离散 HMM 模型对 ECG 信号特征提取进行建模. 首先, 根据如图 1 所示的 ECG 信号波形特征, 将 HMM 的隐藏状态空间  $S$  划分为等电位基准 1 (ISO1)、P 子波、等电位基准 2 (ISO2)、QRS 波群、等电位基准 3 (ISO3) 和 T 子波. 躯感网中的传感器检测到人体的 ECG 信号, 将其通过 A/D 转换为数字信号. 该信号的数值空间范围太大, 不能直接作为观察序列状态空间, 尽管观察序列状态空间越大, 处理效果就越好, 但对应的计算量也越大, 不适合躯感网的应用, 因此本节根据 ECG 信号电压的幅值, 将 ECG 数字信号的数值空间划分为三个部分  $v_1$ 、 $v_2$ 、 $v_3$ , 并将这三个部分作为 HMM 的观察序列状态空间  $V$ .

本文所建面向 ECG 信号特征提取的 HMM 模型如图 3 所示, 包括 HMM 模型的隐藏状态空间和观察序列状态空间. 其中, 面向 ECG 信号特征提取的 HMM 模型的隐藏状态空间由 ISO1、P 波、ISO2、QRS 波、ISO3 以及 T 波组成, 观察序列状态空间由  $v_1$ 、 $v_2$ 、 $v_3$  组成.

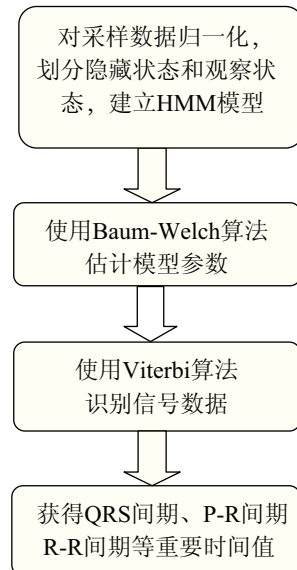


图 2 基于 HMM 的 ECG 信号特征提取方法流程图  
Fig.2 Process of ECG signal feature extraction method based on HMM




图 3 面向 ECG 信号特征提取的 HMM 模型  
Fig.3 HMM oriented to ECG signal feature extraction

图 3 所示的 HMM 模型结构适合处理正常的 ECG 信号, 对于异常的 ECG 信号, 如 P 波不存在或者 QRS 波群后面直接是 T 波的情况, HMM 的隐藏状态空间中不包含 ISO3. 针对如前所述的两类异常情况, 本文在图 3 的基础上对 HMM 的参数进行了微调, 如图 4(a) 和图 4(b) 所示. 图 4(a) 中的隐藏状态空间只有 5 个状态, 去掉了图 3 中的 P 状态. 图 4(b) 中的隐藏状态空间在图 3 的基础上去掉了 ISO3 状态空间.

此外, 针对含有 U 波的 ECG 信号, 本文建立的 HMM 模型如图 5 所示, 图中隐藏状态空间由 7 个状态组成, 在图 2 中的状态空间基础上增加了 U 波状态. 当处理不包含 U 波的 ECG 信号时, 这个模型可以提高对 T 波的划分精度, 但由于增加了一个状态, 因此会增加用于训练 HMM 模型的数据量, 从而增加了算法的复杂度.

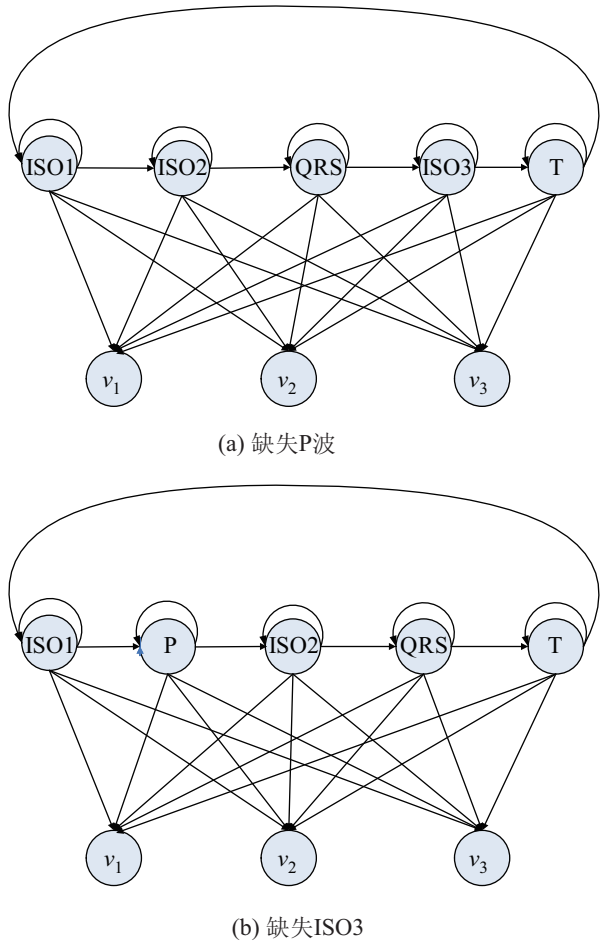


图4 提取异常 ECG 信号特征的 HMM 模型  
Fig.4 HMM for extracting abnormal ECG signal feature




图5 提取包含 U 波 ECG 信号特征的 HMM 模型  
Fig.5 HMM for extracting ECG signal feature with U waveform

### 3.2 面向 ECG 信号特征提取的 HMM 模型训练

本文主要采用经典的 Baum-Welch 算法来对 HMM 模型进行训练，在模型训练的过程中，为了更有效和精确地提取 ECG 信号的特征，本文主要考虑了 5 个问题：专家标注选取、导联选取、观察数据归一化、三元组初始值选取以及训练数据量选取。在处理专家标注选取和导联选取问题时，主要结合了 ECG 信号本身的特点和 ECG 信号获取方式的特点，

另外本文还设计了一种统计方法来选取三元组的初始值，以便获得优化的 HMM 模型参数。

#### 3.2.1 专家标注选取

HMM 模型训练主要分为监督式训练和非监督式训练。监督式训练将医学专家的经验融合到特征提取过程中，准确性更高。为此，本文采用 HMM 模型的监督式训练方法，以实现实时精确的 ECG 信号特征提取。具体步骤如下：

- 利用无线传感器检测到的 ECG 数字信号对 HMM 模型参数进行训练。
- 利用训练得到的参数提取 ECG 信号的特征，并将提取的信息与专家的标注信息进行比较。
- 将比较的结果反馈给 HMM 模型，修正 HMM 模型的参数。
- 利用修正后的 HMM 模型参数提取 ECG 信号的特征。
- 依次循环，最终获得优化的 HMM 模型参数。

监督式训练的样本数据需要有专家标注，从而利用专家的知识 and 经验来训练出优化的参数，所以专家标注对 HMM 模型的训练至关重要。然而，不同专家对相同 ECG 信号的标注结果可能不同，采用不同专家标注的样本数据对参数进行训练会影响 HMM 参数训练的最后结果。为了解决不同专家标注影响 HMM 参数训练结果的问题，本文采用基于多专家标注的模型训练方法，原因在于：1) 使用多个专家标注的数据将会增加用于训练 HMM 模型参数的样本数据量，从而增强训练出来的模型参数的鲁棒性；2) 使用多个专家标注的数据将使训练出来的模型不会对单个专家标注过分敏感，减少了对某个特定专家标注的依赖性。

多专家标注的模型训练方法的主要步骤如下：

- 利用无线传感器检测到的 ECG 数字信号对 HMM 模型参数进行训练。
- 利用训练得到的参数提取 ECG 信号的特征，并将提取的信息与第一个专家的标注信息进行比较。
- 将比较的结果反馈给 HMM 模型，修正 HMM 模型的参数。
- 利用修正后的 HMM 模型参数提取 ECG 信号的特征。
- 依次循环，获得第一个专家标注下的 HMM 模型优化参数。
- 利用第一个专家标注下训练得到的 HMM 模型参数提取 ECG 信号的特征，将提取的信息与第二个专家的标注信息进行比较。
- 将比较的结果反馈给 HMM 模型，修正 HMM

模型的参数.

- 利用修正后的 HMM 模型参数提取 ECG 信号的特征.

- 依次循环, 获得第二个专家标注下的 HMM 模型优化参数.

- 循环利用上面的步骤, 获得最后一个专家标注下的 HMM 模型优化参数.

采用多专家标注的模型训练方法得到的 HMM 模型优化参数将会反映所有专家标注信息的特征. 当某个专家的标注信息与其他专家的标注信息差异很大时, 为了模型训练的稳定性以及参数的优化, 本文将会在训练的过程中不考虑该专家的标注信息.

### 3.2.2 导联选取

所谓导联, 即将两个电极置于人体表面上不同的两点, 通过导线与心电图仪相连, 就可以描出一种心电图波形, 描记心电图时的电极安放位置及导线与放大器的联接方式称为心电图导联. ECG 信号的获取是多导联的, 目前世界上流行的是 12 个导联, 不同导联获得的 ECG 信号波形是不同的, 反映不同的心电信息. 用于 HMM 模型训练的 ECG 样本数据可以由某个特定导联获得的, 也可以是由多个导联获得的. 如果训练 HMM 模型只用某个特定导联获得的 ECG 数据, 则训练出来的 HMM 模型将会对这个特定导联的 ECG 信号敏感. 这种情况下, 该 HMM 模型在识别其他导联的 ECG 信号时性能会大打折扣. 为了克服单个导联带来的依赖性较强的问题, 本文选取多个导联获得的 ECG 信号样本数据训练 HMM 模型参数.

### 3.2.3 观察数据归一化

在对 ECG 信号进行处理之前, 为了归一化信号的动态范围和稳定信号的基线部分, 首先需要归一化观察数据. 目前简单有效的归一化方法是线性整流器方法, 具体包括能量归一化和范围归一化. 由于采用能量归一化方法将会降低检测到的 ECG 信号幅值, 不利于心电信号的准确判断, 因此, 本文选用范围归一化方法, 范围归一化方法将信号数据的变化范围限定在  $(-1, +1)$  之间. 具体包括两个步骤, 如式 (4) 和 (5) 所示.

$$ro'_i = o_{fi} - \left( \frac{o_{fmin} + o_{fmax}}{2} \right), \quad 1 \leq i \leq l \quad (4)$$

$$o_i = \frac{o'_i}{o'_{max}}, \quad 1 \leq i \leq l \quad (5)$$

其中,  $l$  是样本数,  $o_{fi}$  是第  $i$  个原始数据,  $o_{fmin}$  是原始数据中的最小值,  $o_{fmax}$  是原始数据中的最大值,  $o'_{max}$  是初步处理后数据的最大值,  $o_i$  是最后的结果.

### 3.2.4 三元组初始值选取

HMM 模型训练的主要目的是为了获得三元组参数的优化值. 在开始 HMM 模型训练之前, 需要一组初始值, 初始值的选取在一定程度上影响最后结果的优劣. 为此, 本文在对 HMM 模型进行训练之前, 根据专家标注的结果以及 ECG 信号各个特征区间在整个 ECG 信号中所占的比例统计出一个初始值, 然后使用该初始值对 HMM 模型进行训练, 从而使得参数的最后结果比较接近最优解.

本文提出的初始值选取方法的主要步骤如下:

- 根据 ECG 信号的周期和采样率, 获得一个 ECG 信号周期内的采样的数据量.

- 在一个 ECG 信号周期内, 为隐藏状态空间中各状态划分子状态, 其中, 子状态的总数最多不能超过单周期内信号的采样数的一半, 各隐藏状态拥有的子状态数比例是根据专家对 ECG 信号数据的标注信息进行估计的.

- 为每个子状态设定一个隐藏计算因子, 第  $t$  个周期内的隐藏状态  $i$  的子状态  $j$  的隐藏计算因子如下:

$$ch^t_{i,j} = 1, \quad 1 \leq i \leq N, 1 \leq j < L^i, 1 \leq t \leq T \quad (6)$$

其中,  $L^i$  是隐藏状态  $i$  的子状态数,  $N$  是隐藏状态数,  $T$  是 ECG 信号的周期数, 第  $t$  个周期位于隐藏状态  $i$  与隐藏状态  $i+1$  边界处的子状态的隐藏计算因子的计算公式如下:

$$ch^t_{i,bo} = n^t_{i,label} - n^t_{i,substate}, \quad 1 \leq i \leq N, 1 \leq t \leq T \quad (7)$$

其中,  $n^t_{i,label}$  是专家标注属于隐藏状态  $i$  的信号采样数,  $n^t_{i,substate}$  是估算的属于隐藏状态  $i$  的子状态数, 当  $i = N$  时,  $ch^t_{i,bo}$  表示的是第  $t$  个周期位于隐藏状态  $N$  与隐藏状态 1 边界处的子状态的隐藏计算因子.

- 统计所有周期内隐藏状态  $i$  的子状态  $j$  的隐藏计算因子, 计算公式如下:

$$ch_{i,j} = \sum_{t=1}^T ch^t_{i,j}, \quad 1 \leq i \leq N, 1 \leq j < L^i \quad (8)$$

- 统计所有周期内位于隐藏状态  $i$  与隐藏状态  $i+1$  边界处的子状态的隐藏计算因子, 计算公式如下:

$$ch_{i,bo} = \sum_{t=1}^T ch^t_{i,bo}, \quad 1 \leq i \leq N, 1 \leq t \leq T \quad (9)$$

- 位于隐藏状态  $i$  内的子状态  $j$  的状态转移概率分布为  $a[j][j] = 0.0$ ,  $a[j][j+1] = 1.0$ , 位于隐藏状

态  $i$  与隐藏状态  $i+1$  边界处子状态的状态转移概率分布为  $a[j][j] = 1 - T/ch_{i,bo}$ ,  $a[j][j+1] = T/ch_{i,bo}$ .

• 为每个子状态设定一个观察计算因子, 在第  $t$  个周期内隐藏状态  $i$  的子状态  $j$  下, 观察序列状态是  $v_k$  的观察计算因子的计算公式如下:

$$co_{i,j}^{t,k} = 1, \\ 1 \leq i \leq N, 1 \leq j < L^i, 1 \leq t \leq T, 1 \leq k \leq M \quad (10)$$

其中,  $M$  为观察序列状态数.

• 在第  $t$  个周期内位于隐藏状态  $i$  与隐藏状态  $i+1$  边界处的子状态下, 观察序列状态是  $v_k$  的观察计算因子记为  $co_{i,bo}^{t,k}$ , 计算  $co_{i,bo}^{t,k}$  的主要方法如下:

■ 设定  $co_{i,bo}^{t,k}$  的初始值为 0.

■ 根据专家的标注信息, 获得位于隐藏状态  $i$  内的样本采样数  $n$ , 隐藏状态  $i$  的子状态数为  $m$ , 则位于隐藏状态  $i$  和隐藏状态  $i+1$  边界处的样本采样数为  $n-m$ .

■ 在隐藏状态  $i$  和隐藏状态  $i+1$  边界处得样本采样数  $n-m$  内, 如观察序列状态是  $v_k$ , 则  $co_{i,bo}^{t,k}$  自加 1, 如此便统计出  $co_{i,bo}^{t,k}$  的值.

• 统计所有周期内, 在隐藏状态  $i$  的子状态  $j$  下, 观察序列状态是  $v_k$  的观察计算因子, 计算公式如下:

$$co_{i,j}^k = \sum_{t=1}^T co_{i,j}^{t,k}, \\ 1 \leq i \leq N, 1 \leq j < L^i, 1 \leq k \leq M \quad (11)$$

• 统计所有周期内, 在隐藏状态  $i$  与隐藏状态  $i+1$  的边界处的子状态下, 观察序列状态是  $v_k$  的观察计算因子, 计算公式如下:

$$co_{i,bo}^k = \sum_{t=1}^T co_{i,bo}^{t,k}, \quad 1 \leq i \leq N, 1 \leq k \leq M \quad (12)$$

• 位于隐藏状态  $i$  内的子状态  $j$  的观察序列概率分布为  $b[j][k] = co_{i,j}^k/ch_{i,j}$ , 初始状态概率分布  $\pi_i = ch_{i,j}/l$ ,  $l$  为采样的总样本数.

• 位于隐藏状态  $i$  与隐藏状态  $i+1$  的边界处子状态的观察序列概率分布为  $b[j][k] = co_{i,bo}^k/ch_{i,bo}$ , 初始概率分布  $\pi_i = ch_{i,bo}/l$ .

采用上面所述的方法可以依次估算出三元组  $(A, B, \pi)$  的初始值, 进而用此初始值去训练 HMM 模型以便获得优化参数.

### 3.2.5 训练数据量选取

在训练 HMM 模型参数的过程中, 需要确定样本数据的大小. 如果样本数据的数据量太大, 则训

练的时间就会过长; 反之, 如果样本数据的数据量太小, 训练的结果偏离最优值. 而数据量的大小跟 HMM 模型结构的复杂度是相关的, HMM 模型的结构越复杂, 样本数据量就越大. 图 6 显示了随着隐藏状态数的增加, 样本采样数的变化曲线图.




图 6 样本采样数与隐藏状态数之间的关系

Fig.6 Relationship between sampling numbers and hidden state numbers

本文根据正常和畸形 ECG 信号波形的特征划分 HMM 模型的隐藏状态数为 5 个~7 个, 经过多次实验比较, 比较适合本文设计的 HMM 模型训练的样本数据量大小是 10 个~12 个 ECG 信号周期的数据, 样本的采样数大概是 600 个~720 个数据.

### 3.3 ECG 信号特征提取

本文利用 Baum-Welch 算法训练 HMM 模型, 并根据建立的 HMM 模型结构以及训练出来的优化参数, 使用经典的 Viterbi 算法提取特征信号.

## 4 仿真结果 (Simulation results)

为了验证基于 HMM 的 ECG 信号特征提取方法的性能, 本文在 Matlab 仿真平台上, 选用 MIT-BIH<sup>[16]</sup> 心电数据库的样本数据对 HMM 模型进行训练, 并用训练完成的模型提取样本的 ECG 信号特征.

为了评估方法的性能, 本文使用 P-R 间期、QRS 波间期和 T 波间期表示 ECG 信号特征并定义了一个评价指标, 其计算公式如下:

$$A = \frac{N - N_e}{N} \times 100\% \quad (13)$$

其中, 指标  $A$  表示精确度,  $N$  为 ECG 信号记录中所有三个间期值的总数,  $N_e$  为间期值提取发生错误的数目. 精确度可以用来评估 ECG 信号特征算法的整体性能. 当提取的间期值与专家标注的间期值的误差大于或等于 5% 的时候, 本文则认为提取的间期值是错误的.

为了验证基于 HMM 的 ECG 信号特征提取算法的性能, 本文从 MIT-BIH 心电数据库中随机地选取了 16 组记录, 这些记录主要被分成两类: 类型 1 记录只包含正常 ECG 信号, 类型 2 记录包含正常 ECG 信号和畸形 ECG 信号. 表 1 显示了本文提出算法对两种类型的 ECG 信号特征提取的精确度, 其中,  $N$  代表记录中信号的三个间期的总数,  $N_{\text{reg}}$  代表记录中正常 ECG 信号的三个间期数,  $N_a$  代表记录中畸形 ECG 信号的三个间期数. 为了验证三元组初始值的选取对算法性能的影响, 在 HMM 模型训练的过程中, 分别采用普通方法和本文设计的方法来选取三元组初始值, 进而训练得到不同的模型参数, 并利用得到的不同模型参数提取类型 1 记录中的 ECG 信号特征, 实验结果见表 2.

表 1 基于 HMM 的 ECG 信号特征提取算法性能  
Tab.1 Performance of ECG signal feature extraction method based on HMM

类型	记录	$N$	正常信号		畸形信号	
			$N_{\text{reg}}$	A(%)	$N_a$	A(%)
1	115	1952	1952	99.87	0	0
	122	2474	2474	99.74	0	0
	123	1517	1517	99.60	0	0
	101	1864	1864	99.84	0	0
	103	2083	2083	99.18	0	0
	112	2537	2537	99.67	0	0
	117	1534	1534	99.70	0	0
	220	2046	2046	99.51	0	0
2	119	1987	1543	99.51	444	99.18
	221	2427	2031	99.46	396	99.24
	106	2027	1507	99.54	520	98.07
	230	2255	2254	99.43	1	100.00
	100	2271	2237	99.65	34	99.14
	116	2411	2301	99.52	110	99.11
	215	3361	3194	99.40	167	99.25
	228	2053	1688	99.58	365	99.38

从表 1 中可以看出, 类型 1 中的正常 ECG 信号特征提取的精确度都超过 99.70%, 类型 2 中的正常 ECG 信号特征提取的精确度位于 99.50% 左右, 畸形 ECG 信号特征提取的精确度都超过 99.00%, 这说明基于 HMM 的 ECG 信号特征提取算法在提取正常信号和畸形信号方面的性能都较好, 同时, 表中的结果可以反映出本文提出算法提取畸形 ECG 信号的性能比提取正常 ECG 信号的性能要差一些, 主要原因是用于训练 HMM 模型参数的样本数据是正常

的 ECG 信号数据. 采用不同方法获取三元组初始值对算法性能的影响结果如表 2 所示, 从表中可以看出, 本文设计的三元组初始值选取方法相较于普通方法对算法的性能有了进一步的提高. 基于 HMM 的 ECG 信号特征提取算法与其他算法的性能比较结果如表 3 所示, 表中  $N_{\text{rec}}$  代表 ECG 信号的记录数,  $N$  代表记录中三个间期的总数. 从表中可以看出, 基于 HMM 的 ECG 信号特征提取算法的精确度比其他算法的精确度要高 2% 左右.

表 2 不同三元组初始值选取方法对算法性能的影响  
Tab.2 Influence on the performance of the algorithm using different selection methods of initial value of triple

类型	记录	$N$	本文的方法	普通方法
			A(%)	A(%)
1	115	1952	99.87	96.32
	122	2474	99.74	96.21
	123	1517	99.60	95.24
	101	1864	99.84	95.13
	103	2083	99.18	95.78
	112	2537	99.67	96.51
	117	1534	99.70	95.47
	220	2046	99.51	95.65

表 3 各种算法在 ECG 信号特征提取方面的性能比较  
Tab.3 Performance comparison among different algorithms on ECG signal feature extraction

算法	数据库		性能评估
	$N_{\text{rec}}$	$N$	A(%)
PCA <sup>[17]</sup>	20	17031	97.50
	44	20193	96.48
NNs <sup>[18-20]</sup>	40	20874	95.20
	44	20874	97.00
	7	2859	97.04
KNN Classifier <sup>[21]</sup>	20	17031	94.24
	44	20193	93.18
Gaussian process <sup>[22]</sup>	18	8160	97.10
	27	12240	96.90
本文的方法	16	20868	99.20

图 7 所示为利用 MIT-BIH 心电数据库的样本数据训练 HMM 模型后的 ECG 信号特征提取结果图.

本文提出的 ECG 信号特征提取方法是基于离散 HMM 的, 在算法的处理过程中主要涉及到的又是概率计算和统计问题, 所以算法的复杂度比较低. 本方法中的模型训练是监督式训练, 算法中要多次比较和修正 HMM 模型的参数, 同时在选取三元组

初始值的过程中也花费不少时间, 所以模型训练时间在整个算法运行时间中所占的比重最大. 为了验证基于 HMM 的 ECG 信号特征提取方法的时间复杂度, 本文在 VC6.0 平台上运行本文提出的算法代码, 运行时间在 600 ms ~ 1.5 s 之间, 比小波变换方法和 KNN (k-nearest neighbour) 算法的复杂度要低很多, 完全可以满足临床医学上基于 ECG 进行心血管疾病诊断的要求.




图7 ECG 信号特征提取结果图

Fig.7 Result of ECG signal feature extraction

## 5 结束语 (Conclusion)

本文面向躯感网, 根据 ECG 信号的特征区间, 基于 HMM 提出了一种 ECG 信号特征提取的方法. 仿真结果表明, 基于 HMM 的 ECG 信号特征提取算法的时间复杂度较低, 准确度较高, 且实时性较好, 适合处理非线性的、动态变化的 ECG 信号, 也适合在躯感网中使用. 但本算法主要用来提取 ECG 信号特征, 并不能进一步地对 ECG 信号进行分类, 下一步的工作将研究一种 ECG 信号特征提取和分类方法.

## 参考文献 (References)

- [1] 魏太星, 魏经汉, 魏毅东. 临床心电图学及图谱 [M]. 4 版. 郑州: 河南科学技术出版社, 2006.  
Wei T X, Wei J H, Wei Y D. Clinical electrocardiography and map[M]. 4th ed. Zhengzhou: Henan Science and Technology Press, 2006.
- [2] 庄亚纯. 动态心电图 (DCG) 的发展与展望 [J]. 上海生物医学工程, 1996, 17(1): 58-59.  
Zhuang Y C. Advanced and future perspectives of ambulatory electrocardiogram (DCG)[J]. Shanghai Journal of Biomedical Engineering, 1996, 17(1): 58-59.
- [3] 滕晓霏, 张元亭. 移动医疗: 穿戴式医疗仪器的发展趋势 [J]. 中国医疗器械杂志, 2006, 30(5): 330-340.  
Teng X F, Zhang Y T. M-Health: Trends in wearable medical devices[J]. Chinese Journal of Medical Instrumentation, 2006, 30(5): 330-340.
- [4] Ham F, Han S. Classification of cardiac arrhythmias using fuzzy ARTMAP[J]. IEEE Transactions on Biomedical Engineering, 1996, 43(4): 425-429.
- [5] Risk M, Sobh J, Saul J. Beat detection and classification of ECG using self organizing maps[C]//Proceedings of the 19th IEEE Annual International Conference on Engineering in Medicine and Biology Society. Piscataway, NJ, USA: IEEE, 1997: 89-91.
- [6] Afonso V, Tompkins W, Nguyen T, et al. ECG beat detection using filter banks[J]. IEEE Transactions on Biomedical Engineering, 1999, 46(2): 192-202.
- [7] Martinez J, Almeida R, Olmos S, et al. A wavelet-based ECG delineator: Evaluation on standard databases[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(4): 570-581.
- [8] de Chazal P, O'Dwyer M, Reilly R. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(7): 1196-1206.
- [9] Sayadi O, Shamsollahi M, Clifford G. Robust detection of premature ventricular contractions using a wave-based Bayesian framework[J]. IEEE Transactions on Biomedical Engineering, 2010, 57(2): 353-362.
- [10] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. Proceedings of the IEEE, 1989, 77(2): 257-286.
- [11] Fan G L, Xia X G. Improved hidden Markov models in the wavelet-domain[J]. IEEE Transactions on Signal Processing, 2001, 49(1): 115-120.
- [12] Hu S, Shao Z Z, Tan J D. A real-time cardiac arrhythmia classification system with wearable electrocardiogram and accelerometers[C]//2011 International Conference on Body Sensor Networks. Piscataway, NJ, USA: IEEE, 2011: 119-124.
- [13] 张开滋, 刘海洋, 吴杰. 心电信息学 [M]. 北京: 科学技术文献出版社, 1998.  
Zhang K Z, Liu H Y, Wu J. Electrocardiographic informatics[M]. Beijing: Science and Technology Literature Press, 1998.
- [14] Rabiner L, Juang B H. An introduction to hidden Markov models[J]. IEEE ASSP Magazine, 1986, 3(1): 4-16.
- [15] Welch L. Hidden Markov models and the Baum-Welch algorithm[J]. IEEE Information Theory Society Newsletter, 2003, 53(4): 10-13.
- [16] Goldberger A L, Amaral L, Glass L, et al. Components of a new research resource for complex physiologic signals[DB/OL]. (2000-06-13)/[2011-08-22]. <http://www.physionet.org/physiobank/database/mitdb/>.
- [17] de Chazal P, O'Dwyer M, Reilly R. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(7): 1196-1206.
- [18] Inan O, Giovangrandi L, Kovacs G. Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing interval features[J]. IEEE Transactions on Biomedical Engineering, 2006, 53(12): 2507-2515.
- [19] Ince T, Kiranyaz S, Gabbouj M. Automated patient-specific classification of premature ventricular contractions[C]//Proceedings of the 30th IEEE EMBS Annual International Conference. Piscataway, NJ, USA: IEEE, 2008: 5474-5477.



- [20] Shyu L, Wu Y, Hu W. Using wavelet transform and fuzzy neural network for VPC detection from the Holter ECG[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(7): 1269-1273.
- [21] Christov I, Jekova I, Bortolan G. Premature ventricular contraction classification by the Kth nearest-neighbours rule[J]. Physiological measurement, 2005, 26(1): 123-130.
- [22] Melgani F, Bazi Y. Classification of hyperspectral remote sensing images using Gaussian processes[C]//Proceedings of 2008 IEEE International Geoscience & Remote Sensing Symposium. Piscataway, NJ, USA: IEEE, 2008: 1013-1016.

(上接第 627 页)

- [9] 王明顺, 于滨, 高宪文. 非匹配不确定输入时滞系统的自适应滑模控制 [J]. 东北大学学报: 自然科学版, 2008, 29(8): 1069-1072.
- Wang M S, Yu B, Gao X W. Adaptive sliding mode control of mismatched uncertain input delay systems[J]. Journal of Northeastern University: Natural Science, 2008, 29(8): 1069-1072.
- [10] Niu Y, Chen B, Wang X. Sliding mode control for a class of nonlinear Ito stochastic systems[J]. International Journal of Control, Automation, and Systems, 2009, 7(3): 365-370.
- [11] 夏元清, 韩京清. 同时含有状态和输入时滞系统的滑模控制 [J]. 控制与决策, 2003, 18(5): 563-567.
- Xia Y Q, Han J Q. Sliding mode control of the system with input and state delay[J]. Control and Decision, 2003, 18(5): 563-567.

### 作者简介:

- 凤 超 (1988-), 男, 硕士生, 助理研究员. 研究领域为躯感网, 心电图信号处理.
- 梁 炜 (1974-), 女, 博士, 研究员. 研究领域为无线传感器网络, 工业通信, 躯感网, 系统仿真.
- 张晓玲 (1982-), 女, 博士, 助理研究员. 研究领域为工业无线传感网, 通信调度.

- [12] El Ghaoui L, Oustry F, AitRami M. A cone complementarity linearization algorithm for static output-feedback and related problems[J]. IEEE Transactions on Automatic Control, 1997, 42(8): 1171-1176.

### 作者简介:

- 祝乃杰 (1985-), 男, 硕士. 研究领域为滑模控制, 模糊控制等.
- 陈 蓓 (1985-), 女, 博士. 研究领域为滑模变结构控制, 马尔可夫跳跃系统等.
- 牛玉刚 (1964-) 男, 教授, 博士生导师. 研究领域为随机控制系统, 滑模控制, 网络化控制系统, 非线性控制等.