

一种新的心率变异性度量方法*

邵士亮^{1)2)3)†} 王挺²⁾³⁾ 宋纯贺²⁾³⁾ 崔婀娜¹⁾ 赵海¹⁾ 姚辰²⁾³⁾

1) (东北大学计算机科学与工程学院, 沈阳 110819)

2) (中国科学院沈阳自动化研究所, 机器人学国家重点实验室, 沈阳 110016)

3) (中国科学院机器人与智能制造创新研究院, 沈阳 110169)

(2019年3月15日收到; 2019年6月13日收到修改稿)

心率变异性的复杂波动反映了心脏的自主调节功能. 本文提出了一种新的心率变异性度量方法——ICBN方法, 该方法通过改进的自适应噪声完备集合经验模态分解方法对心率变异性信号进行分解, 得到多个模态分量, 计算每个模态分量的 bubble 熵得到熵值向量, 将该向量映射成复杂网络, 通过计算网络的特征参数, 对心率变异性在不同时频尺度状态下的非线性特征之间的耦合关系进行度量. 首先, 采用时域、频域和 ICBN 分析方法对 29 名充血性心力衰竭病人和 29 名正常窦性心律对象的心率变异性进行分析, 结果表明: 时域指标三角指数 HRVTi, 频域指标 LF/HF, 网络层级加权值 WB, 平均点权值 PW, 特征路径长度 CL 具有统计学差异; 基于网络层级加权值 WB, 特征路径长度 CL, 频域指标 LF/HF 和 Fisher 判别方法的识别模型对充血性心力衰竭病人的识别正确率达到 89.66%. 然后, 又对 43 名房颤心律失常患者和 43 名正常窦性心律对象的心率变异性进行分析, 结果表明: 时域指标 SDNN, pNN50, RMSSD, 频域指标 LF/HF, 网络层级加权值 WB, 平均点权值 PW 具有统计学差异; 时域指标 pNN50, RMSSD, 频域指标 LF/HF 和网络层级加权值 WB, 平均点权值 PW 作为特征向量, Fisher 判别方法作为分类器, 对房颤心律失常患者的识别正确率达到 91.86%. 综合以上实验结果可知, 本文为心率变异性的度量研究提供了一种新的思路.

关键词: 心率变异性, 改进的自适应噪声完备集合经验模态分解 (ICEEMDAN), bubble 熵, 复杂网络

PACS: 87.80.-y, 05.45.-a

DOI: 10.7498/aps.68.20190372

1 引言

心率变异性 (heart rate variability, HRV) 是指逐次心跳间期的波动, 常用来评估自主神经系统 (autonomic nervous system, ANS) 对心脏活动的调节作用, 是评价自主神经活动的重要无创指标, HRV 的分析能够了解 ANS 在心脏发病过程中的作用^[1-3].

传统的 HRV 分析方法集中于时域和频域分析^[4-6]. 时域分析法主要是利用相邻正常心跳间隔的标准差 (standard deviation of normal to normal, SDNN)、相邻正常心跳间隔差值的均方根 (root

mean square of the successive normal, RMSSD)、相邻正常心跳间隔差值超过 50 ms 的比例 (count divided by the total number of all NN intervals, pNN50)、相邻正常心跳间隔的总个数除以相邻正常心跳间隔直方图的高度 (HRV triangular index, HRVTi) 等指标对 HRV 进行评价. 频域分析是把 HRV 分解为不同的频率成分, 并将其相对强度定量为功率, 提供了各种频率成分的功率谱测定, 分为甚低频段 (very low frequency, VLF)、低频段 (low frequency, LF)、高频段 (high frequency, HF)、总功率谱 (total power, TP) 等指标. 然而, 时域指标不能表达出 HRV 信号的时变特性, 所以对自主神经系统的反映十分有限, 而频域分析只能

* 重大科技创新项目 (批准号: N161608001) 资助的课题.

† 通信作者. E-mail: shaoshiliang@sia.cn

给出全局的频率信息, 缺少局部和不同频率间的耦合信息. 时域和频域的分析方法都是对 HRV 信号做线性分析, 很难透过 HRV 信号的非线性本质^[7,8]. 因此, 通过非线性分析方法对 HRV 进行分析得到了广泛的研究, 包括 Poincaré 散点图^[9]、去趋势波动分析^[10]和近似熵^[11]、样本熵^[12]、排列熵^[13]、bubble 熵^[14]等熵分析法. 熵分析法是 HRV 分析中比较有代表性的一类方法, 因 HRV 的无序波动中, 包含了心脏活动中有序的内在动力学特性, 而熵测度能够度量心脏活动的这种有序程度, 所以在 HRV 信号的研究中, 熵分析法得到了广泛的应用. 但对 HRV 信号直接进行熵测度分析忽略了信号内部的波动细节. 为了增强对 HRV 信号内部细节的观察, 文献^[15]把经验模态分解 (empirical mode decomposition, EMD) 方法与熵分析方法相结合, 但该方法忽略了残差信号, 同时没有考虑不同本征模态函数 (intrinsic mode function, IMF) 之间的耦合关系, 造成了信息量的丢失, 而且 EMD 分解算法存在模态混叠和端点效应等不足.

目前, 对 HRV 信号的分析研究中, 并没有对不同时频尺度下的 HRV 信号之间的耦合关系进行分析. 本文根据非线性和非平稳的 HRV 信号在不同时刻具有不同频率成分的特点, 提出了一种基于改进的自适应噪声完备集合经验模态分解 (improved complete ensemble EMD with adaptive noise, ICEEMDAN) 和 bubble 熵 (bubble entropy) 的复杂网络 (complex network, CN) 映射的 HRV 度量方法——ICBN 方法, 该方法主要研究不同时频尺度空间下的 HRV 信号之间的耦合关系. 本研究先通过 ICEEMDAN 对 HRV 信号进行时频尺度化, 然后将得到的不同时频段间的 IMF 分别计算 bubble 熵值, 构建熵值向量, 根据有限穿越水平可视图法 (limited penetrable horizontal visibility graph, LPHVG)^[16,17]将熵值向量映射成复杂网络, 通过网络参数特征对不同时频尺度空间化下的 IMF 间的耦合关系进行度量, 从而实现 HRV 信号的度量.

2 研究对象与方法

本文的实验方法结构如图 1 所示. 首先, 对带有人工校准的心跳标注和时间戳的文件进行 HRV 提取, 并进行片段分割; 然后, 通过时域分

析、频域分析、ICBN 方法对 HRV 信号进行分析, 提取时域、频域指标和耦合特征指标; 最后, 通过统计分析和交叉校验对各特征的分类性能进行对比分析.

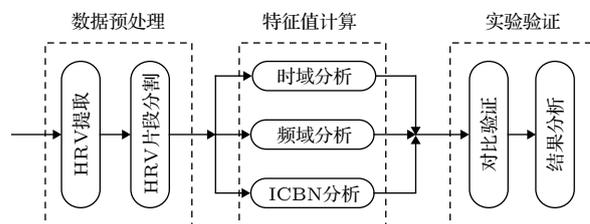


图 1 HRV 分析框架图

Fig. 1. Framework of the HRV analysis.

2.1 研究对象

实验数据取自 PhysioNet 提供的数据集^[18]. 在这里共使用了 4 个数据集. 第一个数据集是 chf2, 包含 29 个患有充血性心力衰竭 (congestive heart failure, CHF) 病人的长时心电信号 (electrocardiogram, ECG), 患者年龄从 34 到 79 岁. 第二个数据集是 nsr2, 包含 54 个正常窦性心律 (normal sinus rhythm, NSR) 对象的长时 ECG 信号, 其中男性 30 名, 年龄从 28.5 到 76 岁, 女性 24 名, 年龄从 58 到 73 岁. 第三个数据集是 nsr, 包含 18 个正常窦性心律的长时 ECG 信号, 包括男性 5 名, 年龄从 26 到 45 岁, 女性 13 名, 年龄从 20 到 50 岁. 第四个数据集是 ltaf, 包含 84 个房颤心律失常 (atrial fibrillation, AF) 患者的长时 ECG 信号. 原始 ECG 信号的采样频率是 128 Hz, 每个信号都带有人工校准的心跳标注, 从而可以获得用于数据分析的 RR 间期序列, 即 HRV 信号 (图 2). 为了排除昼夜节律对信号分析的影响, 文献^[19]采用上午清醒时间段的信号进行分析, 本文采用同样的方法进行实验.

2.2 时域、频域分析方法

时域分析的统计特征如表 1 所示, 包括 SDNN, RMSSD, pNN50, HRVTi 这 4 个时域特征指标.

本文采用 Lomb-Scamble 周期图法计算功率谱密度, 相对基于 FFT 的方法具有更高的估计精度^[20]. 本文计算的频域特征包括 TP (≤ 0.4 Hz), VLF (0.003—0.040 Hz), LF (0.04—0.15 Hz) 和

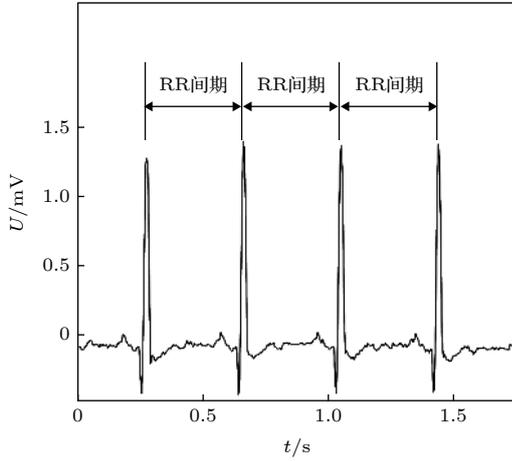


图 2 HRV 信号获得示意图
Fig. 2. Schematic of obtaining HRV signal.

HF(0.15—0.40 Hz) 范围的功率谱, LF 和 HF 的比值 LF/HF, 5 个频域特征指标. 具体的描述与定义如表 2 所示.

2.3 ICBN 分析方法

本文提出的 ICBN 分析方法的实现过程如图 3 所示. 首先, 读取带有人工校准标注的数据文件并提取 HRV 信号, 根据标注文件剔除异常点; 然后, 通过 ICEEMDAN 对提取的 HRV 信号在不同时频尺度下进行分解, 得到不同频尺度空间下的

IMF; 再通过计算每个 IMF 的 bubble 熵值, 构建 bubble 熵向量, 对熵向量进行网络的映射; 最后, 通过对网络的特征进行计算, 完成对 HRV 信号在不同时频尺度下的耦合特征分析.

2.3.1 RRs 提取

获取带有人工标注的 ECG 信号文件和人工标注的注释文件, 提取每个对象上午清醒时间段 1 h 长的 HRV 信号, 定义为 $x(i), 1 \leq i \leq N, i \in Z$, 其中 N 表示信号长度.

2.3.2 ICEEMDAN 分解

ICEEMDAN 基于 EMD 方法提出, 是针对非线性和非稳态数据的自适应分析方法, 它改善了 EMD 方法的模态混叠效应, 减少了 IMF 中的噪声成分, 同时丰富了 IMF 的物理意义 [21]. 对于输入 HRV 信号 x , ICEEMDAN 对其分解的具体实现过程如下.

1) 对于 $j = 1, 2, \dots, J$, 通过 EMD 分解 $x^{(j)} = x + \beta_0 E_1(w^{(j)})$, 得到第一个残差:

$$r_1 = \left\langle M \left(x^{(j)} \right) \right\rangle. \quad (1)$$

2) 在第一阶段 $k = 1$, 计算第一个模态分量:

$$\text{IMF}_1 = x - r_1. \quad (2)$$

表 1 时域分析统计特征

Table 1. Statistical features in time domain.

指标	单位	描述与定义
SDNN	ms	相邻正常心跳间隔的标准差 $\text{SDNN} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\text{RR}_{s_i} - \frac{1}{N} \sum_{i=1}^N \text{RR}_{s_i} \right)^2}$
RMSSD	ms	相邻正常心跳间隔差值的平方和均值的均方根 $\text{RMSSD} = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (\text{RR}_{s_{i+1}} - \text{RR}_{s_i})^2}$
pNN50	%	相邻正常心跳间隔差值超过 50 毫秒的比例 $\text{pNN50} = \frac{\text{num}[(\text{RR}_{s_{i+1}} - \text{RR}_{s_i}) > 50\text{ms}]}{N-1}$
HRVTi	—	相邻正常心跳间隔的总个数除以相邻正常心跳间隔直方图的高度

表 2 频域分析统计特征

Table 2. Statistical features in frequency domain.

指标	单位	描述与定义	频率范围
Total power	ms^2	所有频率范围的功率谱总和	$\leq 0.4 \text{ Hz}$
VLF	ms^2	甚低频范围内的功率谱	0.003—0.040 Hz
LF	ms^2	低频范围内的功率谱	0.04—0.15 Hz
HF	ms^2	高频范围内的功率谱	0.15—0.40 Hz
LF/HF	%	LF [ms^2] 与 HF [ms^2] 的比值	—

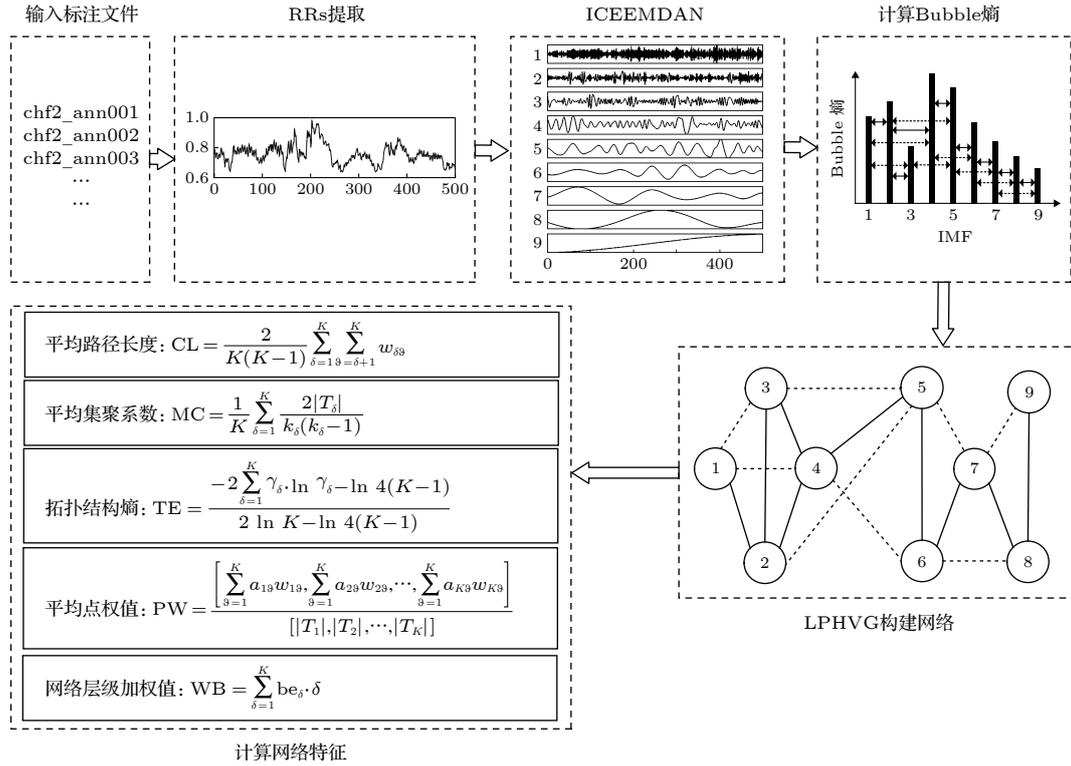


图 3 ICBN 分析方法实现过程框图

Fig. 3. Implementation process of ICBN analysis method.

3) 对于 $j = 1, 2, \dots, J$, 通过 EMD 分解 $r_1 + \beta_0 E_2(w^{(j)})$, 得到第二个模态分量为

$$IMF_2 = r_1 - r_2 = r_1 - \left\langle M \left(r_1 + \beta_1 E_2 \left(w^{(j)} \right) \right) \right\rangle. \quad (3)$$

4) 对于 $k = 3, \dots, K$, 计算第 k 个残差:

$$r_k = \left\langle M \left(r_{k-1} + \beta_{k-1} E_k \left(w^{(j)} \right) \right) \right\rangle. \quad (4)$$

5) 计算第 k 个模态分量:

$$IMF_k = r_{k-1} - r_k. \quad (5)$$

6) 对下一个 k 回到步骤 4).

重复 4) 到 6), 直到获取的残差不能继续被 EMD 分解, 则输入信号被分解为

$$x = \sum_{k=1}^K IMF_k. \quad (6)$$

以上公式中 $E_k(\cdot)$ 为产生第 k 个模态分量的算子; $M(\cdot)$ 是局部均值算子; $w^{(i)}$ 为零均值单位方差白噪声; 系数 $\beta_k = \varepsilon_k \text{std}(r_k)$ 允许在每一次迭代中选择信噪比, 其中 $\text{std}(\cdot)$ 为标准偏差算子. 研究表明^[21], 噪声幅值 $\varepsilon_0 = 0.2$ 时, ICEEMDAN 具有最好的分解效果, 分解次数 J 在取值 50 和 200 时具有相似的分解结果, 所以本文设置 $\varepsilon_0 = 0.2$, $J = 50$.

2.3.3 计算 IMF 的 bubble 熵

Bubble 熵是一种更加稳定和精确的度量方法, 不需要设置容限值且度量结果不依赖于嵌入维数, 是基于条件排列熵和 Renyi 排列熵而提出的. 相对于样本熵和近似熵, bubble 熵具有更好的区分能力^[14]. 对于输入的 HRV 信号 $x: \{x(i): 1 \leq i \leq N\}$, 通过 ICEEMDAN 在不同时频尺度上分解出不同的模态分量 IMF 的, 定义为 $IMF_s = [IMF_1, IMF_2, \dots, IMF_K]$, 其中每个模态分量定义为 $IMF_k: \{\text{imf}_k(i): 1 \leq i \leq N, 1 \leq k \leq K\}$, 对 IMF_k 进行计算 bubble 熵的过程如下.

将 IMF_k 嵌入一个 m 维空间, 对于每一个 $\text{imf}_k(i)$, 进行相空间重构, 得到

$$IMF_k(i) = [\text{imf}_k(i), \text{imf}_k(i+L), \dots, \text{imf}_k(i+(m-1)L)], \quad (7)$$

其中 L 和 m 分别为延迟因子和嵌入维数. 将 $IMF_k(i)$ 的 m 个重构分量 $[\text{imf}_k(i), \text{imf}_k(i+L), \dots, \text{imf}_k(i+(m-1)L)]$ 使用冒泡排序法, 按照升序进行重新排列, 统计每一个重构分量的必要交换次数 $n_j (j = 1, 2, \dots, m)$, 在 bubble 熵的计算中, $L = 1$, 所以 m 维矢量的个数为 $N - m + 1$, 计算其对应次

数出现的概率 $p_j = \frac{n_j}{N - m + 1}$. 嵌入维数 m 根据文献 [14] 设置为 15.

Renyi 排列熵可根据如下公式计算:

$$H_2 = -\log \left(\sum_{i=1}^n p_i^2 \right). \quad (8)$$

条件排列熵可根据如下公式计算:

$$\text{cpe} = \text{PE}(m+1) - \text{PE}(m), \quad (9)$$

其中, $\text{PE}(m)$ 代表 m 维空间排列熵, $\text{PE}(m+1)$ 代表 $m+1$ 维空间排列熵.

条件 Renyi 排列熵为

$$\text{crpe} = (H_2^{m+1} - H_2^m) / \log(m+1). \quad (10)$$

根据公式 (8), (9) 和 (10) 得 bubble 熵的计算公式为

$$\text{be} = (H_{\text{swaps}}^{m+1} - H_{\text{swaps}}^m) / \log(m+1/m-1), \quad (11)$$

其中 $1/\log(m+1/m-1)$ 是归一化因子.

对于模态分量 $\text{IMFs} = [\text{IMF}_1, \text{IMF}_2, \dots, \text{IMF}_K]$, 得到 bubble 熵值向量 $\text{BE} = [\text{be}_1, \text{be}_2, \dots, \text{be}_K]$.

2.3.4 Bubble 熵网络的映射

LPHVG 具有相对更强的连接性, 进而在较小的时间尺度上可以更多地反应信号的内在信息和特征, 同时不影响对序列长程波动趋势的影响 [16,17], 因此本文选择 LPHVG 方法构建 bubble 熵网络.

对于时间序列 $x(i), 1 \leq i \leq N, i \in Z$, 通过 ICEEMDAN 在不同时频尺度上分解出 IMFs , $\text{IMFs} = [\text{imf}_1, \text{imf}_2, \dots, \text{imf}_K]$, 对每一个 IMF 进行非线性分析计算出 bubble 熵值, 得到向量 $\text{BE} = [\text{be}_1, \text{be}_2, \dots, \text{be}_K]$, 根据 LPHVG, 将 BE 向量映射成网络 $G = (V, \xi)$. 通过对网络 $G = (V, \xi)$ 的特征参数进行计算, 完成对 IMFs 之间的耦合关系分析, 其中节点集合为 $V = \{v_1, v_2, \dots, v_K\}$, $\xi \subseteq \{(v_\delta, v_\vartheta) : v_\delta, v_\vartheta \in V, v_\delta \neq v_\vartheta\}$ 是边所构成的集合, 且 $(v_\delta, v_\vartheta) \in \xi \Leftrightarrow (v_\vartheta, v_\delta) \in \xi$, $|V|$ 表示图 G 的阶. 定义 $W = [w_{\delta\vartheta}]$ 为图 G 的加权邻接矩阵, 其中 $w_{\delta\vartheta} \neq 0 \Leftrightarrow (v_\delta, v_\vartheta) \in \xi$, 2 个节点 v_δ 和 v_ϑ 的权值分别为 be_δ 和 be_ϑ , 定义节点 v_δ 和 v_ϑ 之间边的权值为

$$w_{\delta\vartheta} = \begin{cases} |(\text{be}_\delta - \text{be}_\vartheta)|, & \text{节点 } v_\delta \text{ 和 } v_\vartheta \text{ 相连,} \\ 0, & \text{节点 } v_\delta \text{ 和 } v_\vartheta \text{ 不相连.} \end{cases} \quad (12)$$

节点 v_δ 的邻居集合定义为 $T_\delta = \{v_\vartheta \in V : w_{\delta\vartheta} \neq 0\} = \{v_\vartheta \in V : (v_\delta, v_\vartheta) \in \xi\}$, 节点 v_δ 的度定义为 d_δ , 则 $d_\delta = |T_\delta|$, 图 G 的度矩阵定义为

$D_G = [d_1, d_2, \dots, d_K] = [|T_1|, |T_2|, \dots, |T_K|]$, 根据节点之间的边权值, 节点 v_δ 的点权值 S_δ 定义为与它关联的边权值之和, 即 $s_\delta = \sum_{\vartheta=1}^K a_{\delta\vartheta} w_{\delta\vartheta}$, 图 G 的点权矩阵定义为 $S_G = [s_1, s_2, \dots, s_K]$.

2.3.5 计算网络特征指标

在将 bubble 熵值向量映射为加权网络后, 对 5 个复杂网络参数进行考察, 分别为平均集聚系数 MC , 特征路径长度 CL , 网络拓扑熵 TE , 网络层级加权值 WB , 平均点权值 PW .

平均集聚系数 MC : 平均集聚系数是指在网络中与同一个节点连接的 2 个节点之间相互连接的平均概率, 该系数用来刻画网络的局域结构性性质 [22].

$$\text{MC} = \frac{1}{K} \sum_{\delta=1}^K \frac{2|T_\delta|}{\kappa_\delta(\kappa_\delta - 1)}, \quad (13)$$

其中, 与节点 v_δ 直接相连接的节点数为 $|T_\delta|$, κ_δ 为所有与节点 v_δ 相连接的节点之间直接相连接的边数.

特征路径长度 CL : 特征路径长度表示所有节点之间距离的平均值, 它描述了网络中节点间的平均分离程度, 即网络有多小 [22].

$$\text{CL} = \frac{2}{K(K-1)} \sum_{\delta=1}^K \sum_{\vartheta=\delta+1}^K w_{\delta\vartheta}. \quad (14)$$

网络标准拓扑熵 TE : 网络拓扑熵可以更简洁的度量网络的序状态, 对网络拓扑熵进行归一化得到网络标准拓扑熵, 其定义为 [23]

$$\text{TE} = \frac{-2 \sum_{\delta=1}^K \gamma_\delta \cdot \ln \gamma_\delta - \ln 4(K-1)}{2 \ln K - \ln 4(K-1)}, \quad (15)$$

其中 $\gamma_\delta = d_\delta / \sum_{\delta=1}^K d_\delta$ 为节点重要程度, 显然 $0 \leq \text{TE} \leq 1$.

针对 IMFs 的 bubble 熵网络的实际物理意义, 本文在构建的 bubble 熵网络的基础上提出 2 个网络特征, 分别是网络层级加权值 WB 和平均点权值 PW .

网络层级加权值 WB : 网络层级加权值以不同权值, 对不同层级地位的网络节点的权值总量进行计算, 图 G 中节点 v_δ 的 δ 表示 IMF 的层级位置, 每个节点 v_δ 的权值为 be_δ , 则网络层级加权值为

$$WB = \sum_{\delta=1}^K be_{\delta} \cdot \delta. \quad (16)$$

平均点权值 PW: 用来刻画网络中点权值的平均分布情况, 定义为图 G 的点权向量 $S_G = [s_1, s_2, \dots, s_K]$ 除以度向量 $D_G = [d_1, d_2, \dots, d_K]$.

$$PW = \frac{S_G}{D_G} = \frac{\left[\sum_{\vartheta=1}^K a_{1\vartheta} w_{1\vartheta}, \sum_{\vartheta=1}^K a_{2\vartheta} w_{2\vartheta}, \dots, \sum_{\vartheta=1}^K a_{K\vartheta} w_{K\vartheta} \right]}{[|T_1|, |T_2|, \dots, |T_K|]}. \quad (17)$$

3 实验分析

采用上述的时域、频域分析方法和本文提出的 ICBN 分析方法, 分别对不同人群的 HRV 信号进行分析, 然后通过 T 检验对各类特征分别进行差异分析, 并取 $p < 0.001$ 的特征作为最终的极显著差异特征进行分类, 最后通过 Fisher 判别模型对实验对象进行识别. 为了得到更加可靠、稳定的结果, 采用留一法交叉检验实验的平均值作为最后的识别结果.

3.1 应用于健康人和 CHF 患者的 HRV

首先对如下两组 HRV 信号进行分析, 即 CHF

组和 NSR1 组, 其中 CHF 组采用 chf2 数据集的 29 例 CHF 患者; NSR1 组采用 nsr2 数据集的前 29 例健康人.

3.1.1 NSR1 和 CHF 的 HRV 信号差异性分析

HRV 信号时域、频域特征和 ICBN 分析方法计算的 IMF 间耦合特征的均值和标准差如表 3 所示. 从 NSR1 和 CHF 这 2 类人群的对比中可以看出, WB, PW, CL, HRVTi, LF/HF 具有极显著统计学差异 ($p < 0.001$); TE, MC 指标具有显著统计学差异 ($p < 0.01$). 其中, 耦合特征中 WB, PW 和 CL 具有极显著的统计学差异 ($p < 0.001$); 时频域指标中 HRVTi 和 LF/HF 具有极显著的统计学差异 ($p < 0.001$).

图 4 是具有极显著差异的特征的均值和标准差. 从图 4 中可以看出, 在 NSR1 组中, PW, CL, HRVTi, LF/HF 的均值比 CHF 组的均值高, PW 的均值比 CHF 组的均值低. ICBN 方法中的指标 WB, PW 和 CL, 在 CHF 对象中表现出了更高的标准差, 而时域指标 HRVTi 和频域指标 LF/HF, 在 NSR1 对象中表现出了更高的标准差.

3.1.2 CHF 病人的识别

通过 Fisher 判别模型对 NSR1 和 CHF 这 2 组 HRV 信号进行分类, 实现对不同指标分类性

表 3 NSR1 和 CHF 患者不同分析方法下的结果

Table 3. Statistical analysis results of HRV index under different analysis methods.

指标	NSR1(mean ± SD)	CHF(mean ± SD)	标准误差差值的95%置信区间		p	
			下限	上限		
ICBN	WB	21.853 ± 1.479	27.835 ± 7.741	3.050	8.914	0***
	PW	0.563 ± 0.051	0.455 ± 0.103	-0.151	-0.066	0***
	TE	0.956 ± 0.019	0.937 ± 0.037	-0.034	-0.005	0.009**
	CL	1.135 ± 0.133	0.954 ± 0.194	-0.268	-0.094	0***
	MC	0.684 ± 0.035	0.705 ± 0.026	-0.038	-0.006	0.009**
时域	SDNN	81.507 ± 38.566	59.535 ± 44.76	-43.951	0.007	0.05
	pNN50	11.476 ± 14.676	10.772 ± 14.110	-8.277	6.870	0.853
	RMSSD	51.172 ± 54.895	60.307 ± 58.497	-20.707	38.976	0.542
	HRVTi	6.886 ± 2.452	4.093 ± 1.494	-3.861	-1.725	0***
频域	TP	1.809 ± 4.909	1.443 ± 4.052	-2.734	2.001	0.758
	VLF	0.0003 ± 0.448	1.387 ± 6.214	-1.265	3.370	0.367
	LF	0.212 ± 0.333	0.119 ± 0.316	-0.263	0.078	0.281
	HF	1.597 ± 4.608	1.322 ± 3.745	-2.483	1.934	0.804
	LF/HF	0.288 ± 0.184	0.108 ± 0.083	-0.255	-0.105	0***

注: *, **, ***分别代表 $p < 0.05$, $p < 0.01$, $p < 0.001$.

能的验证. 分类结果通过正确率 (accuracy, Acc)、灵敏度 (sensitivity, Sen)、特异度 (specificity, Spe)、ROC 曲线下的面积 (area under curve, AUC) 来进行评价. 实验结果如表 4 所列, 通过单独的进行分类时, WB, PW, CL, HRVTi 和 LF/HF 这 5 个特征之中, WB 表现出了更高的

Acc, Sen 和 AUC, 分别是 79.3%, 90.48% 和 81.72%, LF/HF 表现出了更高的 Spe, 为 80.95%.

本文通过穷举法, 将具有极显著差异的 5 个指标 WB, PW, CL, HRVTi 和 LF/HF 中的所有 2, 3, 4, 5 个指标的组合作为特征, 通过 Fisher 判别模型对 NSR1 和 CHF 病人进行分类, 将分类正

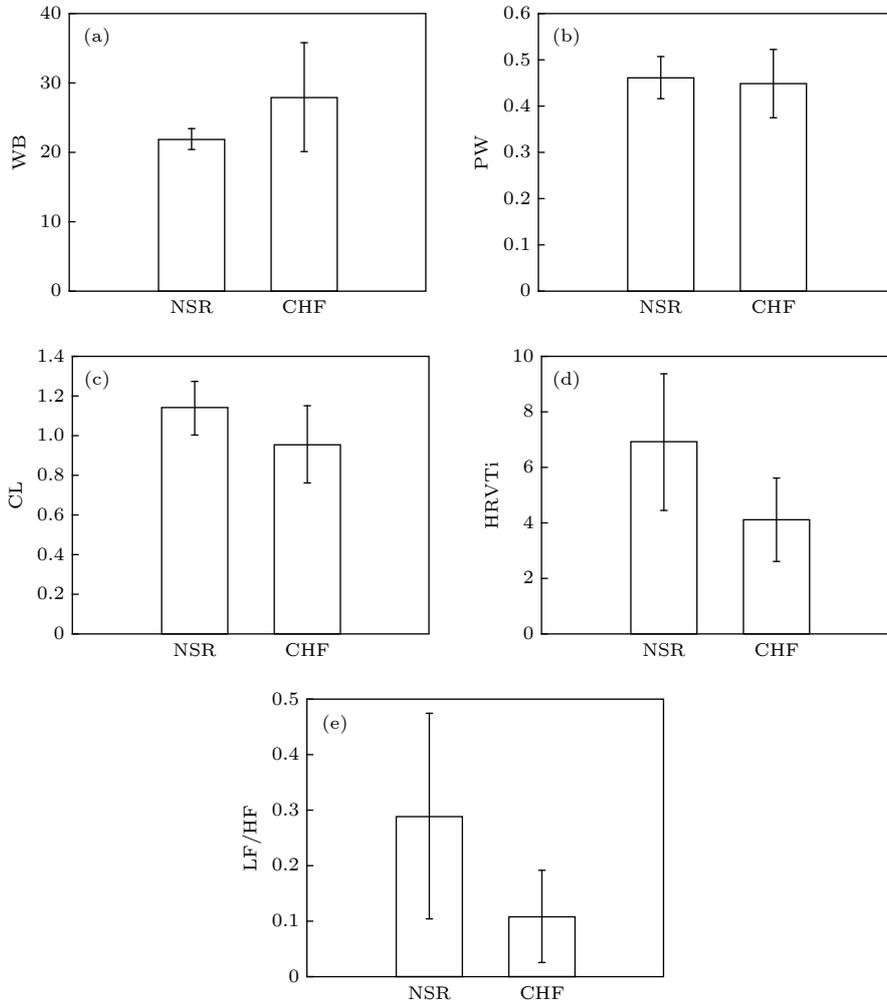


图 4 NSR1 和 CHF 这 2 组对象具有极显著差异的指标的均值与标准差

Fig. 4. Mean and variance of the indicators with very significant differences between the two groups of NSR1 and CHF.

表 4 不同特征的 CHF 识别性能对比

Table 4. Performance comparisons of different indices for CHF recognition.

指标	TP	TN	FP	FN	Acc	Sen	Spe	AUC
WB	19	27	10	2	79.31	90.48	72.97	81.72
PW	19	24	10	5	74.14	79.17	70.59	75.53
CL	20	23	9	6	74.14	76.92	71.88	74.40
HRVTi	23	19	6	10	72.41	69.70	76.00	72.85
LF/HF	25	17	4	12	72.41	75.68	80.95	78.32

注: TP, 被判定为CHF病人的数量; TN, 被判定为NSR1对象的数量; FP, NSR1对象被判定为CHF病人的数量; FN, CHF病人被判定为NSR1对象的数量; 正确率 $Acc = \frac{TP + TN}{TP + FP + TN + FN} \times 100\%$; 灵敏度 $Sen = \frac{TP}{TP + FN} \times 100\%$; 特异度 $Spe = \frac{TN}{FP + TN} \times 100\%$; $AUC = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \times 100\%$.

表 5 不同特征组合的 CHF 识别性能对比
Table 5. Performance comparisons of different indices for CHF recognition.

指标	TP	TN	FP	FN	Acc	Sen	Spe	AUC
WB&CL&LF/HF	25	27	4	2	89.66	92.59	87.1	89.85
WB&PW&CL&HRVTi&LF/HF	24	27	5	2	87.93	92.31	84.38	88.35
WB&PW&CL&LF/HF	24	27	5	2	87.93	92.31	84.38	88.35
WB&PW	22	29	7	0	87.93	100	80.56	90.28
WB&CL&HRVTi&LF/HF	25	25	4	4	86.20	86.21	86.21	86.21
WB&PW&HRVTi&LF/HF	24	26	5	3	86.20	88.89	83.87	86.38
WB&CL&HRVTi	25	25	4	4	86.20	86.21	86.21	86.21
WB&PW&HRVTi	24	26	5	3	86.20	88.89	83.87	86.38

准确率最高的 5 种组合列出 (具体见表 5). 其中, WB&CL&LF/HF 表现出了最高的 Acc 和 Spe, 分别是 89.66% 和 92.59%, WB&PW 表现出了最高的 Sen 和 AUC, 分别是 100% 和 90.28%.

3.2 应用于健康人和 AF 患者的 HRV

对如下 2 组 HRV 信号进行分析: AF 组采用 Itaf 数据集的前 43 例患者, 为了和 AF 组形成公平对比, 并和上一组实验进行区分, NSR2 组采用 nsr 数据集的 18 例健康人和 nsr2 数据集的后 25 例健康人, 共 43 个实验对象.

3.2.1 NSR2 和 AF 的 HRV 信号差异性分析

NSR2 组和 AF 组的 HRV 信号时域、频域和

ICBN 指标如表 6 所列. 从 NSR2 和 AF 这 2 类人群的对比可知, WB, PW, SDNN, pNN50, RMSSD 和 LF/HF 具有极显著统计学差异 ($p < 0.001$); CL, HRVTi, TP, LF 和 HF 指标具有显著统计学差异 ($p < 0.01$); TE 和 MC 指标具有统计学差异 ($p < 0.05$). 其中, 耦合特征中 WB 和 PW 具有极显著的统计学差异 ($p < 0.001$); 时频域指标中 SDNN, pNN50, RMSSD 和 LF/HF 具有极显著的统计学差异 ($p < 0.001$).

图 5 是具有极显著差异特征的均值和标准差. 从图 5 中可以看出, 具有极显著差异的指标中, 在 NSR2 组中 PW 和 LF/HF 的均值比 AF 组的均值高, WB, SDNN, pNN50 和 RMSSD 的均值比 AF

表 6 NSR2 和 AF 患者在不同分析方法下的结果
Table 6. Statistical analysis results of HRV index under different analysis methods.

指标	NSR2(mean ± SD)	AF(mean ± SD)	标准误差差值的 95% 置信区间		<i>p</i>	
			下限	上限		
ICBN	WB	21.483 ± 1.367	24.243 ± 3.105	1.731	3.789	0***
	PW	0.567 ± 0.074	0.454 ± 0.090	-0.148	-0.077	0***
	TE	0.941 ± 0.050	0.960 ± 0.010	0.004	0.035	0.013*
	CL	1.113 ± 0.146	0.999 ± 0.170	-0.183	-0.047	0.001**
	MC	0.687 ± 0.043	0.664 ± 0.032	-0.024	-0.008	0.04*
时域	SDNN	74.698 ± 26.193	139.016 ± 62.480	10.331	43.773	0***
	pNN50	10.123 ± 9.610	45.495 ± 30.687	4.904	25.620	0***
	RMSSD	36.402 ± 19.003	170.926 ± 97.980	15.220	104.256	0***
	HRVTi	7.735 ± 3.210	6.049 ± 2.488	-2.918	-0.455	0.008**
频域	TP	0.615 ± 0.612	13.493 ± 19.369	7.000	18.754	0.001**
	VLF	0.0002 ± 0.0003	0.017 ± 0.063	-2.256	36.147	0.083
	LF	0.157 ± 0.154	1.204 ± 1.620	0.553	1.540	0.002**
	HF	0.458 ± 0.515	12.272 ± 17.908	6.381	17.247	0.001**
	LF/HF	0.515 ± 0.419	0.126 ± 0.059	-0.519	-0.259	0***

注: *, **, *** 分别代表 $p < 0.05$, $p < 0.01$, $p < 0.001$.

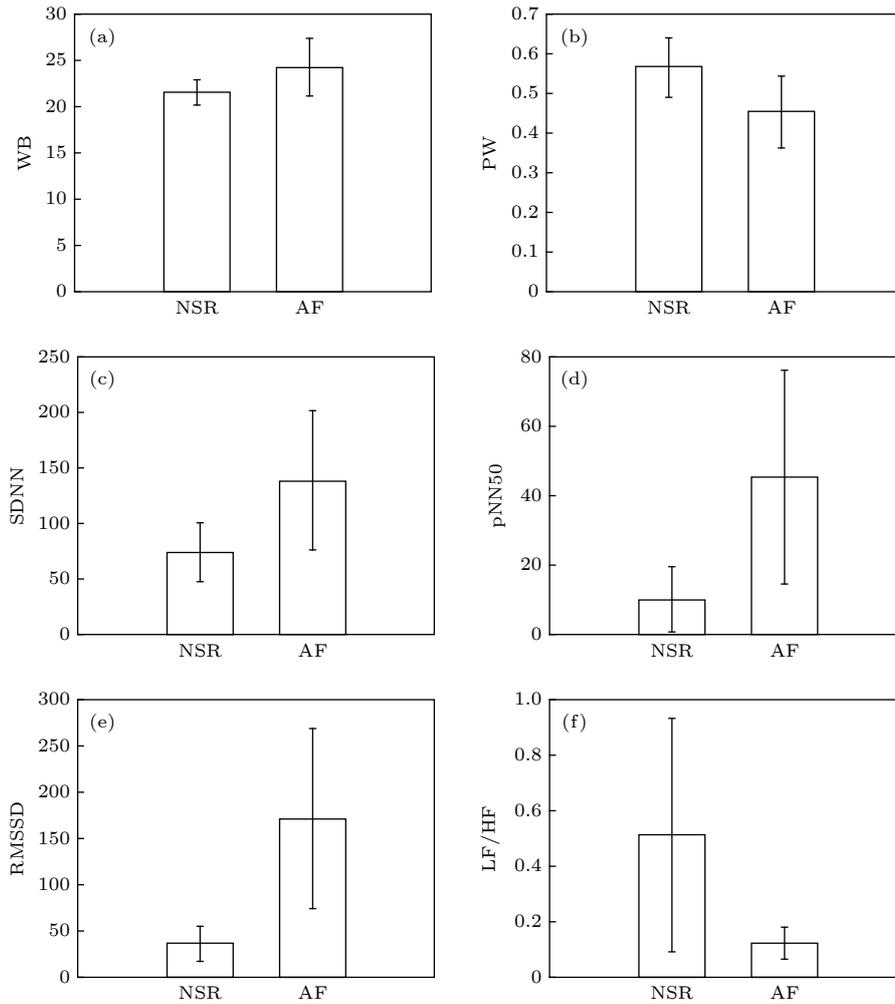


图 5 NSR2 和 AF 这 2 组对象具有极显著差异的指标的均值与标准差

Fig. 5. Mean and variance of the indicators with very significant differences between the two groups of NSR2 and AF.

组的均值低. ICBN 方法中的指标 WB 和 PW, 时域指标 SDNN, pNN50 和 RMSSD 在 AF 对象中表现出了更高的标准差, 频域指标 LF/HF 在 NSR2 对象中表现出了更高的标准差.

3.2.2 AF 患者的识别

通过 Fisher 判别模型对 NSR2 和 AF 这 2 组

HRV 信号进行分类, 实现对不同指标分类性能的验证. 实验结果如表 7 所示, 通过单独的进行分类时, WB, PW, SDNN, pNN50, RMSSD 和 LF/HF 这 6 个特征之中, PW 表现出了最高的 Acc, Sen 和 AUC, 分别是 83.72%, 96.77% 和 86.57%, LF/HF 表现出了最高的 Spe, 是 96.00%.

表 7 不同特征的 AF 识别性能对比

Table 7. Performance comparisons of different indices for AF recognition.

指标	TP	TN	FP	FN	Acc	Sen	Spe	AUC
WB	30	37	13	6	77.91	83.33	74.00	78.67
PW	30	42	13	1	83.72	96.77	76.36	86.57
SDNN	31	34	12	9	75.58	77.50	73.91	75.71
pNN50	28	39	15	4	77.91	87.50	72.22	79.86
RMSSD	29	33	14	10	72.09	74.36	70.21	72.29
LFHF	42	24	1	19	76.74	68.85	96.00	82.43

表 8 不同特征的 AF 识别性能对比
Table 8. Performance comparisons of different indices for AF recognition.

指标	TP	TN	FP	FN	Acc	Sen	Spe	AUC
WB&PW&pNN50&RMSSD&LFHF	38	41	5	2	91.86	95.00	89.13	92.07
WB&PW&SDNN&LFHF	38	40	5	3	90.70	92.68	88.89	90.79
WB&PW&RMSSD&LFHF	38	40	5	3	90.70	92.68	88.89	90.79
WB&PW&SDNN&RMSSD	37	41	6	2	90.70	94.87	87.23	91.05
WB&PW&SDNN&pNN50&RMSSD	36	42	7	1	90.70	97.30	85.71	91.51

本文通过穷举法, 将具有极显著差异的 6 个指标的所有 2, 3, 4, 5, 6 个指标的 57 种组合作为特征, 通过 Fisher 判别模型对 NSR2 和 AF 病人进行分类, 将分类正确率最高的 5 种组合列出 (表 8). 其中, WB&PW&pNN50&RMSSD&LFHF 表现出了最高的 Acc, Spe 和 AUC, 分别是 91.86%, 89.13% 和 92.07%, WB&PW&SDNN&pNN50&RMSSD 表现出了最高的 Sen, 为 97.3%.

4 讨论

本文首先研究比较了 NSR1 组对象和 CHF 患者 HRV 信号时域、频域指标和 ICBN 指标之间的差异, 然后又对另一 NSR2 组对象和 AF 患者进行了同样的分析.

从表 3 可知, 对于 CHF 和 NSR1 这 2 组实验对象, 所有的时域和频域指标中, HRVTi 和 LF/HF 表现出了极显著的统计学差异 ($p < 0.001$). CHF 与 NSR1 相比, 时域指标 HRVTi 显著减小, 表明充血性心力衰竭病人心脏活动发生变化, 交感神经活动增强, 副交感神经活动下降, 频域指标 LF/HF 的下降反应了交感神经和副交感神经系统活动的均衡状态发生变化, 这与文献 [4,6] 的研究结论相一致, 因此本文选择 HRVTi 和 LF/HF 作为时域和频域的识别指标.

从图 4 可知, ICBN 分析方法中, CHF 与 NSR1 相比, WB 指标均值增大, PW 指标和 CL 指标均值减小. WB 指标反映的是不同层级模态分量的波动特性的加权值, CHF 患者的 HRV 信号波动特性相对 NSR1 组的健康人更强, 信号频率成分更复杂, 所以 CHF 患者的 WB 均值更大. PW 指标反映的是模态分量的波动特性在整个网络中的分布情况, 而 NSR1 组对象的 HRV 信号频率成分更简单, 根据 LPHVG 构建的网络节点的度值较小, CHF 患者的 HRV 信号频率成分复杂, 构

建的网络边数更多, 节点的度值更大, 所以 CHF 患者具有更小的 PW 值. 而 CL 值反映的是构建的网络的所有节点之间最短路径长度的平均值, 是网络的全局特征, 因为 CHF 患者的网络具有更多的边, 所有节点之间有更多的路径和更短的路径, 所以 CHF 组具有更小的 CL 值. ICBN 方法是对 HRV 在不同时频尺度空间下的非线性特征之间的关系进行分析, 反映了充血性心力衰竭病人交感神经和副交感神经之间复杂的耦合关系. ICBN 方法中 CHF 对象的 WB 指标、PW 指标和 CL 指标标准差均大于 NSR1 组, 因标准差是对数据离散程度的度量, 而 ICBN 方法是通过度量每个 IMF 的复杂性来实现对 HRV 信号的度量, WB 指标、PW 指标和 CL 指标标准差越大表示 CHF 组病人的 HRV 信号之间差异大, 自主神经系统的调控越活跃, 而 NSR1 组实验对象之间的差异则较小, 实验对象的自主神经系统活动更有规律. 本文的研究初步表明, ICBN 方法能够对 CHF 病人和健康人的 HRV 信号进行度量并进行区分, 但其背后的生理学机制有待深入研究.

从表 4 和表 5 可知, 在 ICBN 方法中, WB, PW 和 CL 相对于时域指标 HRVTi 和频域指标 LF/HF 具有更高的识别正确率, WB, CL 和 LF/HF 这 3 个指标组合的情况下具有最高的分类正确率. 实验结果表明, ICBN 方法提高了分类的正确率, WB, PW 和 CL 指标, 对于 CHF 病人的筛选具有相对于时域 HRVTi 指标和频域 LF/HF 指标更好的分类效果, 通过表 5 还可以看出不是指标越多分类效果越好. 因为指标之间并不相互独立, 过多的指标会导致分类器出现过拟合现象, 使模型不稳定, 分类性能下降. 分类正确率最高的组合中均包含本文提出的 ICBN 方法中的指标, 表明了本文提出的 ICBN 方法对 HRV 信号的度量具有一定的应用价值.

从表 6 可知, 对于 AF 和 NSR2 这 2 组实验对

象,所有的时域和频域指标中,SDNN, pNN50, RMSSD 和 LF/HF 表现出了极显著的统计学差异 ($p < 0.001$),这与文献 [24] 的研究结论相一致,所以本文选择 SDNN, pNN50, RMSSD 和 LF/HF 作为时域和频域指标.

从图 5 可知,ICBN 方法中,AF 与 NSR2 相比,WB 指标均值增大,PW 指标均值减小,与 CHF 患者和 NSR1 的情况相同.WB 指标反映的是不同层级模态分量的波动特性的加权值,因疾病原因,AF 患者的 HRV 信号波动特性更强,信号频率成分更复杂,所以 AF 患者的 WB 均值更大.PW 指标是网络单位度值下的点权值,而 NSR2 组的 HRV 信号频率成分相对 AF 组简单,根据 LPHVG 构建的网络节点的度值小,AF 患者的 HRV 信号频率成分复杂,构建的网络边数更多,网络中度值更大,所以 AF 患者具有更小的 PW 值.AF 组的 WB 和 PW 指标的标准差均大于 NSR2 组,因标准差是对数据离散程度的度量,而 ICBN 方法是通过度量每个 IMF 的复杂性来实现对 HRV 信号的度量的,WB 和 PW 指标标准差越大表示 AF 组病人的 HRV 信号之间差异越大,而 NSR2 组实验对象之间的差异则较小,HRV 信号更有规律.

从表 7 和表 8 可知,在 ICBN 方法中,WB 和 PW 指标相对于时域指标 SDNN, pNN50 和 RMSSD,频域指标 LF/HF 具有更高的识别正确率.对于 AF 病人的筛选,在组合所有极显著差异指标后,WB, PW, pNN50, RMSSD 和 LFHF 组合表现出了最高的分类正确率,且分类正确率最高的组合中均包含本文提出的 ICBN 方法中的指标.实验结果表明,ICBN 方法提高了 AF 病人分类的正确率,对 HRV 信号的度量具有一定的应用价值.还可以看出,因为指标之间并非完全独立,过多的指标组合会导致分类器出现过拟合现象,反而会降低分类正确率.

ICBN 分析方法首先通过 ICEEMDAN 方法对 HRV 信号进行分解,因为健康人和病人 (CHF 与 AF 患者) 的 HRV 信号在频率成分上存在一定的差异,ICEEMDAN 将分解出不同数量和波动特性的 IMFs,因 HRV 信号内在的生理信息不能单纯地通过信号分解进行分离,因此在不同 IMFs 之间存在着耦合的生理信息,所以通过 bubble 熵对 IMFs 的无序特性进行度量,然后将得到的

bubble 熵值通过 LPHVG 方法构建成网络,通过对网络特征的分析实现不同 IMF 之间耦合生理信息的分析.因为健康人和病人将构建出具有不同网络特征的网络,通过网络特征 WB, PW, TP, CL 和 MC 对网络进行度量,实现对 HRV 信号的度量.ICBN 方法中包含了 5 个指标,即 WB, PW, CL, MC 和 TE. WB 指标反映的是不同层级 IMF 的波动特性的加权值,CHF 和 AF 患者的 HRV 信号频率成分相对于健康人更复杂,因此 AF 和 CHF 患者的 WB 值更大. PW 指标反映的是网络的单位度值下的点权值,健康人的 HRV 信号规律性强,频率成分简单,得到的 IMF 数量少,因此 LPHVG 构建的网络、节点和边的数量少,节点的度值小.相反,CHF 和 AF 患者的 HRV 信号频率成分复杂,构建的网络具有更大的度值,因此具有更小的 PW 值. CL 值反映的是构建的网络的所有节点之间路径长度的平均值,是网络的全局特征,如果构建的网络的节点之间有更多的路径和更短的路径,则具有更小的 CL 值. MC 指标反应的是网络的平均聚集程度,在节点数相差不大的情况下,如果构建的网络具有更多的边,则聚集程度更高. TE 反映的是网络的序特征,网络的结构越规则,TE 值越小. WB 和 PW 这 2 个网络特征度量指标的计算过程是对 HRV 信号不同时频尺度下 IMFs 的 bubble 熵值直接进行应用,而 CL, MC 和 TE 更多的是对网络结构特征的度量,对模态分量的 bubble 熵值是一种间接的应用,所以 WB 和 PW 相对于 CL, MC 和 TE 具有更好的分类效果.

5 结 论

本文首先将提出的 ICBN 方法和传统的时域、频域分析方法分别应用于 NSR1 组和 CHF 组实验对象,结果表明,ICBN 方法相对于时域和频域指标具有更高的识别正确率,并且本文提出的 WB 和 CL 指标与频域指标 LF/HF 作为特征向量,通过 Fisher 判别方法对 CHF 病人识别正确率达 89.66%. 然后将 ICBN 方法、时域和频域分析方法应用于 NSR2 组和 AF 组实验对象,结果表明 ICBN 方法中的指标相对于时域和频域指标具有更高的识别正确率. 将时域指标 pNN50, RMSSD, 频域指标 LF/HF, WB 和 PW 指标作为特征向量, Fisher 判别方法对 AF 患者的识别正确率达到

91.86%. 综合以上实验结果可知, 本文提出的 ICBN 方法具有一定的心率变异性度量能力. ICBN 分析方法在不同时频尺度空间下对非线性和非平稳的 HRV 的复杂波动特性进行分析, 是评价交感神经和副交感神经系统调节的潜在指标. ICBN 分析方法的提出, 为心脏自主调节的复杂波动分析和 HRV 信号的度量分析提供了新的思路.

参考文献

- [1] Narin A, Isler Y, Ozer M, Perc M 2018 *Phys. A: Stat. Mech. Appl.* **509** 56
- [2] Si J F, Huang X L, Zhou L L, Liu H X 2014 *Acta Phys. Sin.* **54** 40504 (in Chinese) [司峻峰, 黄晓林, 周玲玲, 刘红星 2014 物理学报 **54** 40504]
- [3] Wendt H, Abry P, Kiyono K, Hayano J, Watanabe E, Yamamoto Y 2019 *IEEE Trans. Biomed. Eng.* **66** 80
- [4] Wang Y, Wei S S, Zhang S, Zhang Y T, Zhao L N, Liu C Y, Murray A 2018 *Biomed. Signal Process. Control* **42** 30
- [5] Pernice R, Javorka M, Krohova J, Czipelova B 2019 *Med. Biol. Eng. Comput.* **57** 1247
- [6] Deus L A, Sousa C V, Rosa T S, Souto J M 2019 *Physiol. Behav.* **205** 39
- [7] Li Y F, Pan W F, Li K Y, Jiang Q, Liu G Z 2019 *IEEE J. Biomedical Health Informat.* **23** 175
- [8] Liu D Z, Wang J, Li J, Li Y, Xu W M, Zhao X 2014 *Acta Phys. Sin.* **19** 198703 (in Chinese) [刘大钊, 王俊, 李锦, 李瑜, 徐文敏, 赵筱 2014 物理学报 **19** 198703]
- [9] Asha N D, Joseph K P 2013 *J. Mech. Med. Biol.* **13** 1350061
- [10] Xia J N, Shang P J, Wang J 2013 *Nonlinear Dyn.* **74** 1183
- [11] Singh V, Gupta A, Sohal J S, Singh A 2019 *Med. Biol. Eng. Comput.* **57** 741
- [12] Alvarez D, Sanchez-Fernandez A, Andres-Blanco A M, Gutierrez-Tobal G C, Vaquerizo-Villar F, Barroso-Garcia V, Hornero R 2019 *Entropy* **21** 381
- [13] Li T B, Yao W P, Wu M, Shi Z R, Wang J, Ning X B 2017 *Phys. A: Stat. Mech. Appl.* **471** 492
- [14] Manis G, Aktaruzzaman M, Sassi R 2017 *IEEE Trans. Biomed. Eng.* **64** 2711
- [15] Acharya U R, Fujita H, Sudarshan V K, Oh S L, Muhammad A, Koh J E W, Tan J H, Chua C K, Chua K P, Tan R S 2016 *Neural Comput. Appl.* **28** 3073
- [16] Gao Z, Cai Q, Yang Y, Dang W, Zhang S 2016 *Sci. Rep.* **6** 35622
- [17] Huo C Y, Ma X F, Ning X B 2017 *Acta Phys. Sin.* **66** 160502 (in Chinese) [霍铖宇, 马小飞, 宁新宝 2017 物理学报 **66** 160502]
- [18] Goldberger A L, Amaral L A N, Glass L, Hausdorff J M, Ivanov P C, Mark R G, Mietus J E, Moody G B, Peng C K, Stanley H E 2000 *Circulation* **101** e215
- [19] Lin Y C, Lin Y H, Lo M T, Peng C K, Huang N E, Yang C C H, Kuo T B J 2016 *Chaos* **26** 023109
- [20] Clifford G D, Tarassenko L 2005 *IEEE Trans. Biomed. Eng.* **52** 630
- [21] Colominas M A, Schlotthauer G, Torres M E 2014 *Biomed. Signal Process. Control* **14** 19
- [22] Watts D J, Strogatz S H 1998 *Nature* **393** 440
- [23] Liu X, Zhao H, Zhang J, Wang J F 2016 *Journal of Northeastern University (Natural Science)* **37** 486 (in Chinese) [刘晓, 赵海, 张君, 王进法 2016 东北大学学报(自然科学版) **37** 486]
- [24] Narin A, Isler Y, Ozer M, Perc M 2018 *Physica A* **509** 65

A novel method of heart rate variability measurement*

Shao Shi-Liang^{1)2)3)†} Wang Ting²⁾³⁾ Song Chun-He²⁾³⁾Cui E-Nuo¹⁾ Zhao Hai¹⁾ Yao Chen²⁾³⁾1) (*School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China*)2) (*State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China*)3) (*Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China*)

(Received 15 March 2019; revised manuscript received 13 June 2019)

Abstract

The complex fluctuation of heart rate variability reflects the autonomous regulation function of the heart. In this paper, a novel method of measuring the heart rate variability is proposed. Firstly, the heart rate variability signal is decomposed by the improved complete ensemble empirical mode decomposition with adaptive noise method, and the multiple intrinsic mode functions are obtained, and the bubble entropy of each intrinsic mode function is calculated to obtain an entropy value vector. Then, the vector is mapped to a network based on a limited penetrable horizontal visibility graph method. By calculating various characteristic parameters of the network, the coupling relationship between the nonlinear features of heart rate variability in different time-frequency scale states are studied. The characteristic parameters include mean value of aggregation coefficient (MC), the characteristic path length (CL), the topological entropy of network (TE), the network level weighted bubble value (WB), and the pseudo mean value of node weight (PW). Firstly, the heart rate variabilities of 29 patients with congestive heart failure and 29 normal sinus heart rhythm subjects are analyzed by time domain, frequency domain and ICBN analysis method, the T test is used for statistical analysis, and Fisher discriminant method is used for classification. The results show that the time domain triangular index HRVTI, frequency domain index LF/HF, WB, PW and CL in ICBN have statistical differences. The accuracy rate of recognition model based on WB, CL, frequency domain index LF/HF and Fisher discriminant method is 89.66%. Secondly, the heart rate variabilities of 43 patients with atrial fibrillation arrhythmia and another 43 normal sinus heart rhythm subjects are analyzed by the same methods, including the time domain analyzed method, frequency domain analyzed method, and ICBN analyzed method. Then, the T test is also used for statistical analysis, and Fisher discriminant method is used for classification. The results show that using the time domain index pNN5 and RMSSD, frequency index LF/HF, ICBN index WB and PW as the feature vectors, and the Fisher discriminant mode as the classifier, the accuracy rate of recognition for atrial fibrillation arrhythmia is 91.86%. From these results it is concluded that the ICBN method provides a new idea for the heart rate variability measurement.

Keywords: heart rate variability, improved complete ensemble empirical mode decomposition with adaptive noise, bubble entropy, complex network

PACS: 87.80.-y, 05.45.-a

DOI: 10.7498/aps.68.20190372

* Project supported by the Major Scientific and Technological Innovation Projects, China (Grant No. N161608001).

† Corresponding author. E-mail: shaoshiliang@sia.cn