

DOI: 10.19650/j.cnki.cjsi.J2107960

基于 ICEEMDAN-MSE 的左室舒张功能 障碍心音信号的识别研究*

杨 洋^{1,2}, 郭兴明^{1,2}, 郑伊能³, 王 慧^{1,2}

(1. 重庆大学生物工程学院 重庆 400044; 2. 重庆市医疗电子工程技术研究中心 重庆 400044;
3. 重庆医科大学附属第一医院 放射科 重庆 400044)

摘 要:左室舒张功能障碍(LVDD)加重会导致左室重构、室壁僵硬、顺应性降低,从而走向不可逆阶段并进展为射血分数保留型心力衰竭。为早期诊断 LVDD,本文提出一种基于改进的自适应噪声完全集合经验模式分解(ICEEMDAN)多尺度样本熵(MSE)的心音特征结合逻辑回归模型的无创检测方法。首先,采用改进的小波去噪方法对心音信号进行预处理。其次,通过 ICEEMDAN 方法将非平稳的心音信号分解为多个反映心音本体特征的平稳的固有模态函数(IMF),再利用互相关系数准则筛选 IMF,并提取所筛选 IMF 的 MSE,以构成特征向量作为分类器的输入。最后,通过与其他 3 种分类模型的性能比较,将逻辑回归应用于 LVDD 识别。结果表明,该方法能有效提取心音特征,其准确率为 89.85%,灵敏度为 92.17%,特异度为 87.63%,证明了采用心音信号对 LVDD 进行早期诊断的有效性。

关键词:左室舒张功能障碍;改进的自适应噪声完全集合经验模式分解;多尺度样本熵;逻辑回归;识别

中图分类号: TP391.4 TH77 **文献标识码:** A **国家标准学科分类代码:** 520.60

Study on left ventricular diastolic dysfunction heart sound signals identification based on ICEEMDAN-MSE

Yang Yang^{1,2}, Guo Xingming^{1,2}, Zheng Yineng³, Wang Hui^{1,2}

(1. College of Bioengineering, Chongqing University, Chongqing 400044, China; 2. Chongqing Engineering Research Center for Medical Electronics Technology, Chongqing 400044, China; 3. Department of Radiology, The First Affiliated Hospital of Chongqing Medical University, Chongqing 400044, China)

Abstract: The aggravation of left ventricular diastolic dysfunction (LVDD) could lead to left ventricular remodeling, wall stiffness, and the reduced compliance, which make progression to heart failure with preserved ejection fraction (HFpEF). To achieve early diagnosis of LVDD, a non-invasive method is proposed, which utilizes the improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) multi-scale sample entropy (MSE) characteristics and the logistic regression model. Firstly, the improved wavelet denoising method is used for heart sound signals preprocessing. Then, the non-stationary heart sound signals are decomposed into several intrinsic mode functions (IMF) which reflect the characteristics of heart sound itself by the ICEEMDAN method. The mutual correlation coefficient criterion is used to select IMF. The MSE values of the selected IMFs are extracted to form the eigenvectors, which are used as the input into the classifier for identification. Finally, the logistic regression is applied for LVDD identification by the comparison of performances with other three models. Results show that the proposed method could effectively extract the features of heart sound with 89.85% accuracy, 92.17% sensitivity and 87.63% specificity, which demonstrate the effectiveness of heart sound signals for LVDD diagnosis.

Keywords: left ventricular diastolic dysfunction; ICEEMDAN; MSE; logistic regression; identification

收稿日期: 2021-05-20 Received Date: 2021-05-20

* 基金项目: 国家自然科学基金(31870980, 31800823, 31570003)项目资助

0 引言

左室舒张功能障碍(left ventricular diastolic dysfunction, LVDD)是一种由于左室舒张期主动松弛能力受损和心肌顺应性降低,导致左室舒张末压增高,从而改变心功能,甚至引起心肌重塑的临床综合征^[1]。目前,受不同地区、研究中心以及纳入和排除标准的影响,总体而言,LVDD在人群中的发生率约为30%^[2-5],与全因死亡率呈正相关。LVDD是左室射血分数保留型心力衰竭(heart failure with preserved ejection fraction, HFpEF)的独立影响因子^[6-7]。当LVDD人群中逐渐出现呼吸困难、水肿、疲劳等心力衰竭(heart failure, HF)表现时,其将走向不可逆阶段并进展为HFpEF。而HFpEF患者约占HF住院患者的50%^[8]。因此,早期诊断LVDD对预防心功能恶化、及时治疗具有重要意义。

有创测量,如左室压力下降率、僵硬指数等指标可用于评估舒张功能,但对人体有害。目前,超声心动图是临床实践中最常用的无创检查^[9],但其不能将未发生器质性病变的早期LVDD有效检出。心音信号是心脏机械活动的直接反映,能为早期诊断心脏异常提供有效信息^[10]。因此,本文采用心音信号对LVDD进行识别。

心音信号具有非线性和非平稳特性^[11]。目前,常用的心音信号分析和特征提取方法主要集中在时域^[12-14]、频域^[15-17]与非线性域^[18-20]。心音信号的非线性特征相比于时频域特征分量具有更好的特异性,有利于心音识别^[21]。而在非线性域中,复杂性对心脏机械运动系统的状态变化敏感,有利于特征的提取^[20]。其中,熵是表征复杂性的良好物理量。Pincus等^[22]提出近似熵,但其存在偏差、结果不稳定的缺点。Richman等^[23]对近似熵算法进行改进得到了样本熵。近似熵和样本熵在心音信号分析中已广泛应用^[18,24],但这些算法都只是仅仅从单一尺度上量化了心音信号时间序列,将检查生理波动的解释范围仅限于该水平,而不能完全捕捉整个心脏机械运动系统的动态变化,往往会产生误导性的结果。多尺度样本熵(multi-scale sample entropy, MSE)是在不同尺度因子下,对时间序列的复杂性和不规则性的度量。现其已被应用于生理信号序列的分析,例如脑电^[25]、心电信号^[26],这表明MSE不仅可以从整体上衡量信号的复杂性,而且还可从不同尺度挖掘更深层次的细节特性,并有效地从定性和定量的角度识别不同类型的信号。

经验模式分解(empirical mode decomposition, EMD)^[27]是分析非线性和非平稳信号的有效方法,为解决分解的固有模式函数(intrinsic mode function, IMF)的模式混叠现象,有研究提出集合经验模式分解(ensemble empirical mode decomposition, EEMD)^[28],其本质是叠加

高斯白噪声的多次EMD,通过加入高斯白噪声来改变信号的极值点分布,之后对多次EMD得到的相应IMF进行总体平均来抵消加入的白噪声。然而,添加噪声的信号会产生不同数量的固有模式函数(intrinsic mode function, IMF),且重构后的信号中含有分解后的残余噪声。完全集合经验模式分解(complete ensemble empirical mode decomposition, CEEMD)^[29]在信号中加入N对正负噪声对,之后进行EMD分解,该方法提高了原始噪声辅助方法的效率,并且可以完全消除重构信号中的残余噪声,但其分解完备性较差,若参数选择不正确,则会产生较多的虚假分量。基于上述问题,Torres等^[30]提出了另一种噪声辅助方法,即自适应噪声完全集合经验模式分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN),该方法将自适应的白噪声添加到EEMD算法分解的每个阶段。通过求平均值的方法,使得分解过程具有良好的完备性,从而提高了原始信号的重构精度,且其迭代次数不到EEMD迭代次数的一半。然而,CEEMDAN仍然存在需要改进的问题,例如,在信号分解的早期阶段显示出一些虚假模式。随后,Colominas等^[31]提出改进的CEEMDAN,即ICEEMDAN,其不仅解决了模式混叠的问题,还降低IMF中的残余噪声,并通过避免虚假模式,可更好实现信号的分解和重构。ICEEMDAN比EMD及其改进方法能更好地表示心音信号的本质特性^[32]。

因此,基于上述ICEEMDAN与MSE的优点,本文将二者结合,构建了基于改进的自适应噪声完全集合经验模式分解(the improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)多尺度样本熵(multi-scale sample entropy, MSE)的方法,以此量化心音非线性动力学特征,并将其应用于LVDD心音信号的特征提取,此外,结合逻辑回归模型实现LVDD的分类识别。为选取最佳的分类模型,还与其他3种分类模型的性能进行对比,实验结果表明,本文提出的方法能有效用于LVDD心音的分类识别。

1 心音数据及预处理

1.1 心音数据

于重庆医科大学附属第一医院共采集92例心音信号,采集装置为成都仪器厂生产的多通道生理信号采集系统RM-6240BD和心音换能器XJ102,采样频率为8000 Hz,带通滤波范围1~1000 Hz以滤除心音频率外的低频和高频噪声,陷波频率50 Hz以滤除工频干扰,采集时长约5 min。同时采集心率、血压、左室容积和室壁厚度等相关的多普勒参数指标。所有研究对象病情均已由心内科专科医生完成评估,且在参与本研究前均签署

知情同意书。选取心尖四腔心切面,采用双平面辛普森法测量所有受试者的左室射血分数(left ventricular ejection fraction, LVEF)。根据美国超声心动图学会(American Society of Echocardiography, ASE)和欧洲心血管影像协会(European Association of Cardiovascular Imaging, EACVI)提出的关于超声心动图评估左室舒张功能的指南^[33],将受试者分为:1) LVDD组,30例;2) 控制组,41例。其余21名未达到临界值而被排除。

1.2 心音预处理

由于心音信号的频率通常不超过800 Hz^[34],因此,为提高信号处理效率并且不损失心音主要成分,根据奈奎斯特采样定理,首先将信号降采样到2 000 Hz。为避免多余噪声对识别结果产生影响,再采用Liu等^[19]提出的一种改进的小波去噪方法来对采集的心音信号去噪。最后,对去噪后的信号进行幅值归一化。

心脏周期包含4种状态,即第一心音、收缩期、第二心音和舒张期。由于第一心音是心动周期的开始,其开端被认为是分段的开始。因此本文以第一心音起点为起始位置,固定心音片段长度为16 s(约20个心动周期)进行分段,表1描述了实验的心音样本信息。

表1 本实验的心音样本信息

Table 1 The information of heart sound samples in this experiment

组别	类型	受试者人数	年龄 (均值±标准差)	心音 样本数	样本 长度/s
LVDD组	有LVDD	30	24~89 (66.87±16.21)	524	16
控制组	无LVDD	41	19~81 (58.71±13.19)	662	16

2 研究方法

2.1 基于ICEEMDAN-MSE的特征提取

该算法是对预处理后的心音样本进行ICEEMDAN分解,筛选有效的IMF分量,提取其多尺度样本熵,构建ICEEMDAN-MSE特征向量,以此量化心音非线性动力学特征。

令 $x = \{x_1, x_2, \dots, x_n\}$ 为预处理后的心音序列(长度为 n),基于ICEEMDAN-MSE的特征提取方法主要包括以下4个步骤:

1) 对心音序列进行ICEEMDAN分解。

CEEMDAN方法在分解过程中添加高斯白噪声,而ICEEMDAN方法添加的是一种特殊的白噪声 $E_k(w^{(i)})$,这是高斯白噪声经过EMD分解后的第 k 个IMF分量。针对每个模式分量计算信号加噪声的局部均值,并将经

EMD分解后得到的IMF定义为残差分量与局部均值之差。ICEEMDAN分解方法极大地减少了IMF分量中的残余噪声,并改进了传统方法在分解重构的早期阶段容易产生的虚假分量和模式混叠的缺点。

定义操作符 $E_k(\cdot)$ 表示EMD分解后的第 k 个模式分量, $M(\cdot)$ 表示信号的局部均值。则 $E_1(x) = x - M(x)$ 。操作符 $\langle \cdot \rangle$ 表示取均值,具体的分解过程如下:

(1) 构造 $x^{(i)} = x + \alpha_0 E_1(w^{(i)})$,其中, $w^{(i)}$ 表示被添加的第 i 个白噪声,计算 $x^{(i)}$ 的局部均值 $M(x^{(i)})$,取均值得到第1个残差分量 $r_1 = \langle M(x) \rangle$ 。

(2) 当 $k=1$ 时,计算第1个模式分量IMF₁的值 d_1 :
 $d_1 = x - r_1$;

(3) 计算第2个模式分量IMF₂的值 d_2 : $d_2 = r_1 - r_2$,其中第2个残差分量 $r_2 = \langle M(r_1 + \alpha_1 E_2(w^{(i)})) \rangle$;

(4) 同理,计算第 k 个残差分量 r_k 和第 k 个模式分量IMF _{k} 的值 d_k :

$$r_k = \langle M(r_{k-1} + \alpha_{k-1} E_k(w^{(i)})) \rangle \quad (1)$$

$$d_k = r_{k-1} - r_k, k = 3, \dots, N \quad (2)$$

其中,常数 α_{k-1} 被用来调整残差分量和添加噪声之间的信噪比(signal noise ratio, SNR),对于 $k=1$, $\alpha_0 = \varepsilon_0 \text{std}(x) / \text{std}(E_1(w^{(i)}))$,此处 $\text{std}(\cdot)$ 为噪声标准差, ε_0 为输入心音序列与第1个添加噪声之间所需SNR的倒数。对于 $k \geq 2$, $\alpha_k = \varepsilon_0 \text{std}(r_k)$ 。本文,ICEEMDAN算法的参数选择如下:噪声标准差为0.2,EMD实现次数为500,允许的最大筛选迭代次数为5 000,SNR取1表示信噪比随着EMD实现而递增。

(5) 重复步骤(4),直至获得所有的模式分量。

2) IMF有效分量提取。

各个IMF包含了不同的时间特征尺度,且随信号自身的变化而变化。此外,由于各IMF分量包含的与原始信号有关的信息是不同的,因此需要利用互相关系数准则进行筛选。

3) 对有效IMF分量进行多尺度化处理。

多尺度样本熵是一种基于样本熵的计算方法,首先进行多尺度化处理,然后计算各个尺度因子下的样本熵,使原始数据的特征信息能够更准确地表征。具体步骤如下:

(1) 对有效IMF分量进行多尺度化处理,有:

$$y_i^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} \text{imf}_i \quad (3)$$

式中: $1 \leq j \leq N/\tau$;构造粗粒化的时间序列 $\{y^{(\tau)}\}$,其中 τ 为尺度因子,序列长度为 $M = \text{int}(n/\tau)$ 。对于尺度1来说, $\{y^{(\tau)}\}$ 就是原始时间序列。每个粗粒化的时间序列长度等于原始时间序列的长度除以 τ 。在此,将长度为32 000个点的时间序列并且粗粒化其最高到尺度20,因此最短的时间有1 600个点。

(2) 构造一组 m 维向量:

$$\mathbf{X}_m(\mathbf{i}) = \{y_{i+k} : 0 \leq k \leq m-1\} \quad (4)$$

(3) 计算 $\mathbf{X}_m(\mathbf{i})$ 和其余向量 $\mathbf{X}_m(\mathbf{j})$ 间的距离:

$$d[\mathbf{X}_m(\mathbf{i}), \mathbf{X}_m(\mathbf{j})] = \max |y_{(i+k)} - y_{(j+k)}| \quad (5)$$

式中: $0 \leq k \leq m-1; i, j = 1 \sim M-m-1; i \neq j$ 。

(4) 设定匹配过程公差阈值 $r (r > 0)$, 对每个 i 统计 $d[\mathbf{X}_m(\mathbf{i}), \mathbf{X}_m(\mathbf{j})] < r$ 数目 $B^m(i)$ (即模板匹配数), 并计算与距离总数的比值, 记作:

$$C_r^m(r) = \frac{B^m(i)}{M-m} \quad (6)$$

(5) 计算 $C_r^m(r)$ 的平均值 $C^m(r)$:

$$C^m(r) = (M-m+1)^{-1} \cdot \sum_{i=1}^{M-m+1} C_r^m(r) \quad (7)$$

(6) 增加维数至 $m+1$, 重复上述步骤, 计算 $C_r^{m+1}(r)$ 及 $C^{m+1}(r)$, 序列长度为 M 时, 有效 IMF 分量的样本熵的估计值可记作:

$$S_{imf_k}(m, r, M) = -\ln \left[\frac{C^{m+1}(r)}{C^m(r)} \right] \quad (8)$$

由式(8)可知, 该值与维数 m 、阈值 r 和数据长度 M 有关。一般情况下, m 取 2; r 为时间序列的标准差的 0.15 倍^[25]。

(7) 在某一尺度因子 τ 下, 某样本熵值即构成心音序列在该尺度下的 ICEEMDAN-MSE 特征向量。

$$\mathbf{e} = \{S_{imf_1}, S_{imf_2}, \dots, S_{imf_k}\}^T \quad (9)$$

4) 重复以上操作, 计算 N 段心音序列的 ICEEMDAN-MSE 特征向量, 并形成特征向量组, 有:

$$\mathbf{E} = \{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_N\} \quad (10)$$

2.2 基于逻辑回归的分类识别

逻辑回归 (logistic regression, LR) 是一种用于解决二分类问题的机器学习方法, 其训练速度快, 有较好的分类效果。

解决分类问题时, 逻辑回归通常遵循以下步骤:

1) 寻找预测函数: 预测函数是输入自变量用于预测因变量结果概率的函数。逻辑回归模型是线性回归模型和逻辑函数的组合, 逻辑函数的形式可表示为:

$$g(z) = \frac{1}{1 + e^{-z}} \quad (11)$$

因此, 可构造逻辑回归的预测函数为:

$$h_\theta(x) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}} \quad (12)$$

其中, θ 是回归参数, x 是输入的自变量, 即输入上述提到的特征向量, $h_\theta(x)$ 则对应样本输入最终得到的预测概率值, 在 $0 \sim 1$ 之间, 是样本预测成为不同类别的概率值。

2) 构造损失函数

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m [y_i \log_{\theta}(x_i) + (1 - y_i) \log(1 - h_{\theta}(x_i))] \quad (13)$$

其中, m 是样本的数量, y 是真实值, 损失函数代表输入多个训练样本后预测值和真实值之间的平均差。损失函数也称为目标函数, 目的是通过优化方法来使 $J(\theta)$ 尽可能小。上式虽然能很好地拟合训练集, 但是针对于未知数据, 测试集将会被错误地分类, 从而出现过拟合现象。解决过拟合的方法主要有减少特征数量和正则化。特征越多, 模型性能就会越好。正则化可以在不减少特征的情况下解决过拟合, 因此本文采用在损失函数后面添加惩罚项 $\lambda/2m \sum_{j=1}^n \theta_j^2$ 的改进方法, 其中, λ 为惩罚项系数。为让 θ 拟合出最佳参数, 采用梯度下降法最小化损失函数, 以找到函数最小值。

3 实验结果分析

信号预处理、特征提取和分类识别等算法均在 MATLAB (版本: R2018a) 编程上实现。实验环境如下, 处理器: Inter Core i5-9500K@3.70 GHz; 内存: 64 GB; 显卡: GTX1660Ti。

3.1 特征提取结果

对经预处理后的心音序列采用 ICEEMDAN 方法分解得到 n 重 IMF 分量。由于 ICEEMDAN 是一种自适应分解算法, 从不同心音周期获得的模式数目可能不同。为了便于比较, 此处仅显示经 ICEEMDAN 分解获得的最少数量的 IMF。为清晰显示, 图 1 所示为一段 4 s 的 LVDD 心音序列的 ICEEMDAN 分解图。从上至下依次为: 原始信号到 IMF 分量再到残余分量。

由图 1 可以看出, ICEEMDAN 将非平稳的 LVDD 心音信号分解为 14 个 IMF 分量和 1 个残余分量, 不同的 IMF 分量包含不同的时间尺度信息。利用互相关系数准则计算每个 IMF 分量与原始信号之间的互相关系数, 对多次平均后的计算结果进行分析, 其相关系数大于 0.35, 表明 IMF4~IMF7 分量与原始信号具有较大的相关性, 结果如表 2 所示。

计算筛选出的有效 IMF4~IMF7 分量的多尺度样本熵值, 其变化趋势如图 2 所示。以此构成特征向量作为分类器的输入。

可以看出, 两组心音序列对应的有效 IMF 分量的多尺度样本熵不同且各具特点, 从而揭示了各自的本质特征与其不同的非线性产生机制。随着尺度的增大, 控制组心音序列的多尺度样本熵值要高于 LVDD 组, 说明 LVDD 患者的复杂性明显低于无 LVDD 患者。




图1 一段4 s的LVDD心音序列的ICEEMDAN分解图

Fig. 1 ICEEMDAN decomposition diagram of a 4 s LVDD heart sound sequence

表2 各IMF间的互相关系数

Table 2 The mutual correlation coefficient among the IMF

组别	LVDD组	控制组
IMF1	0.045 6	0.033 7
IMF2	0.190 7	0.200 6
IMF3	0.322 8	0.324 7
IMF4	0.531 2	0.496 4
IMF5	0.618 2	0.593 4
组别	LVDD组	控制组
IMF6	0.536 3	0.553 9
IMF7	0.360 9	0.357 1
IMF8	0.194 8	0.175 9
IMF9	0.103 4	0.080 4
≥ IMF10	<0.01	<0.01

相对于IMF4、5、6分量而言,IMF7分量的多尺度样本熵值要大,表明在IMF7分量上的信号更复杂,其非线性非平稳性更强。IMF6分量从尺度9开始,其熵值基本保持不变,说明尺度变化信号的复杂度基本没有改变;而IMF4、5、7分量的多尺度样本熵值的变化趋势波动较大,说明具有较强的长程相关性。对各有效IMF分量进行多尺度分析,在尺度变大时,这两组心音序列的样本熵值能很好地区分开来,此外,两组心音序列在相同时间尺度下




图2 IMF4分量的多尺度样本熵变化趋势

Fig. 2 The trend of MSE of IMF4




图3 IMF5分量的多尺度样本熵变化趋势

Fig. 3 The trend of MSE of IMF5




图4 IMF6分量的多尺度样本熵变化趋势

Fig. 4 The trend of MSE of IMF6




图5 IMF7分量的多尺度样本熵变化趋势

Fig. 5 The trend of MSE of IMF7

会表现出不同的复杂性,可根据该特点对其进行分类识别。

3.2 识别性能对比

为保证本文方法的可重复性,采用10折交叉验证法。将所有心音样本按照6:2:2的比例划分为训练集、

测试集和验证集,且保证其中无人员重叠。此外,为验证本文方法的有效性,将 ICEEMDAN-MSE 特征输入 K-最近邻(K-nearest neighbor, KNN)、支持向量机(support vector machine, SVM)、极限学习机(extreme learning machine, ELM)和 LR 模型,基于准确性、灵敏度和特异度指标对分类性能进行评估,结果如表 3 所示。

由表 3 可知,当采用相同分类器时,基于 ICEEMDAN-MSE 特征的识别性能均优于单一 MSE 特征的识别性能;当采用相同输入特征向量时,LR 模型在准确率、灵敏度和特异度这 3 个评价指标上的表现均优于其他 3 种分类模型,表明本文提出的基于心音信号的 ICEEMDAN-MSE 特征,结合逻辑回归模型分类识别方法能够有效地对 LVDD 进行早期诊断。

表 3 不同分类模型的性能对比结果

Table 3 Performance comparison results of different models %

分类器	所用特征	%		
		准确率	灵敏度	特异度
		均值± 标准差	均值± 标准差	均值± 标准差
KNN ^[35]	MSE	79.85±3.14	83.40±2.81	76.55±2.95
	ICEEMDAN-MSE	84.36±2.35	86.07±2.58	82.77±2.46
SVM ^[36]	MSE	84.73±2.11	88.17±2.46	81.53±2.38
	ICEEMDAN-MSE	87.21±1.98	90.08±2.15	84.55±2.27
ELM ^[19]	MSE	85.37±1.74	88.74±1.89	82.24±1.76
	ICEEMDAN-MSE	88.68±1.45	91.79±1.63	85.79±1.53
LR	MSE	87.54±1.26	90.05±1.42	86.34±1.24
	ICEEMDAN-MSE	89.85±1.02	92.17±0.95	87.63±1.09

注:其中,所用特征均经统计分析完成独立样本 t 检验,其 p 值均小于 0.05,具有显著性差异。

4 结 论

早期诊断 LVDD 可为 HFpEF 的发展和严重程度提供重要的参考,并可及时预防与治疗。心音信号是一种非线性且非平稳的信号,本文提出了一种基于 ICEEMDAN-MSE 特征结合逻辑回归模型的 LVDD 心音信号分类识别方法。通过对临床采集的心音数据的分析,结果表明 ICEEMDAN 能自适应地分解心音信号,且 IMF 能较好地反映心音信号的局部特征与本质特性。通过提取 ICEEMDAN 分解后各有效 IMF 分量的多尺度样本熵,反映不同尺度下心音信号的复杂性及其变化的不规则性,从而为 LVDD 心音分类识别提供依据。此外,还进行了对比实验,结果表明,LR 模型分类识别性能优于 KNN、SVM、ELM 模型,其准确率:89.85%,灵敏度:

92.17%,特异度:87.63%,表明本文提出的方法能有效对 LVDD 进行早期诊断,但本文用于模型训练的样本量还不够充足,下一步研究可通过数据增强的方法来增加样本,改善样本不平衡、稀疏的问题。未来可将本文方法应用到更多心血管疾病的分类识别中,如右室舒张功能障碍等,从而得出规律性认识来为临床提供重要的辅助诊断。

参考文献

- [1] WAN S H, VOGEL M W, CHEN H H, et al. Pre-clinical diastolic dysfunction[J]. Journal of the American College of Cardiology, 2014, 63(5): 407-416.
- [2] REDFIELD M M, JACOBSEN S J, BURNETT J C, et al. Burden of systolic and diastolic ventricular dysfunction in the community-appreciating the scope of the heart failure epidemic[J]. JAMA-Journal of the American Medical Association, 2003, 289(2): 194-202.
- [3] ABHAYARATNA W P, MARWICK T H, SMITH W T, et al. Characteristics of left ventricular diastolic dysfunction in the community: An echocardiographic survey[J]. Heart, 2006, 92(9): 1259-1264.
- [4] LAM C S P, LYASS A, KRAIGHER-KRAINER E, et al. Cardiac dysfunction and noncardiac dysfunction as precursors of heart failure with reduced and preserved ejection fraction in the community[J]. Circulation, 2011, 124(1): 24-30.
- [5] MUREDDU G F, AGABITI N, RIZZELLO V, et al. Prevalence of preclinical and clinical heart failure in the elderly. A population-based study in central Italy[J]. European Journal of Heart Failure, 2012, 14(7): 718-729.
- [6] PRASAD S B, GUPPY-COLES K B, HOLLAND D, et al. Echocardiographic predictors of all-cause mortality in patients with left ventricular ejection fraction >35%: Value of guideline based assessment of diastolic dysfunction[J]. IJC Heart & Vasculature, 2019, 24: 1-6.
- [7] ASHCHEULOVA T V, DEMYDENKO H V, HERASYMCHUK N M, et al. Diastolic dysfunction: From the discovery to the latest updates[J]. Zaporozhye Medical Journal, 2019, 21(4): 538-545.
- [8] JEONG E M, DUDLEY S C. Diastolic dysfunction-potential new diagnostics and therapies[J]. Circulation Journal, 2015, 79(3): 470-477.
- [9] KOSSAIFY A, NASR M. Diastolic dysfunction and the new recommendations for echocardiographic assessment of

- left ventricular diastolic function: Summary of guidelines and novelties in diagnosis and grading [J]. *Journal of Diagnostic Medical Sonography*, 2019, 35(4): 317-325.
- [10] WU C F, HERMAN B A, RETTA S M, et al. On the closing sounds of a mechanical heart valve[J]. *Annals of Biomedical Engineering*, 2005, 33(6): 743-750.
- [11] YOGANATHAN A P, GUPTA R, CORCORAN W H, et al. Use of the fast Fourier transform in the frequency analysis of the second heart sound in normal man [J]. *Medical & Biological Engineering*, 1976, 14(4): 455-460.
- [12] FAHAD H M, KHAN M U G, SABA T, et al. Microscopic abnormality classification of cardiac murmurs using ANFIS and HMM [J]. *Microscopy Research and Technique*, 2018, 81(5): 449-457.
- [13] ABDOLLAHPUR M, GHAFARI A, GHIASI S, et al. Detection of pathological heart sounds [J]. *Physiological Measurement*, 2017, 38(8): 1616-1630.
- [14] WHITAKER B M, SURESHA P B, LIU C Y, et al. Combining sparse coding and time-domain features for heart sound classification [J]. *Physiological Measurement*, 2017, 38(8): 1701-1713.
- [15] UGUZ H. A biomedical system based on artificial neural network and principal component analysis for diagnosis of the heart valve diseases [J]. *Journal of Medical Systems*, 2012, 36(1): 61-72.
- [16] SAFARA F, DORAISAMY S, AZMAN A, et al. Multi-level basis selection of wavelet packet decomposition tree for heart sound classification [J]. *Computers in Biology and Medicine*, 2013, 43(10): 1407-1414.
- [17] 张小兰, 房玉, 刘栋博, 等. 肥心病心音时频杂波特征提取识别算法研究 [J]. *电子测量与仪器学报*, 2020, 34(4): 20-26.
- ZHANG X L, FANG Y, LIU D B, et al. Research on extraction algorithm of heart murmur features in time-frequency domain for HCM recognition [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(4): 20-26.
- [18] ZHENG Y N, GUO X M, DING X R. A novel hybrid energy fraction and entropy-based approach for systolic heart murmurs identification [J]. *Expert Systems with Applications*, 2015, 42(5): 2710-2721.
- [19] LIU Y M, GUO X M, ZHENG Y N. An automatic approach using ELM classifier for HFpEF identification based on heart sound characteristics [J]. *Journal of Medical Systems*, 2019, 43(9): 285.
- [20] 郭兴明, 黄林洲. IMF 复杂度特征在心音信号分类识别中的应用 [J]. *计算机工程与应用*, 2013, 49(21): 212-215.
- GUO X M, HUANG L ZH. Study on classification and recognition of heart sound using IMF complexity feature [J]. *Computer Engineering and Applications*, 2013, 49(21): 212-215.
- [21] KUMAR D, CARVALHO R, ANTUNES M, et al. Discrimination of heart sounds using chaos analysis in various subbands [C]. *2nd International Conference on Bio-Inspired Systems and Signal Processing*, 2009: 369-375.
- [22] PINCUS S M. Assessing serial irregularity and its implications for health [C]. *Conference on Demography and Epidemiology: Frontiers in Population Health and Aging*, 2001: 245-267.
- [23] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy [J]. *American Journal of Physiology-Heart and Circulatory Physiology*, 2000, 278(6): H2039-H2049.
- [24] 黄林洲, 郭兴明, 丁晓蓉. EMD 近似熵结合支持向量机的心音信号识别研究 [J]. *振动与冲击*, 2012, 31(19): 21-25.
- HUANG L ZH, GUO X M, DING X R. Heart sound recognition based on EMD approximate entropy and SVM [J]. *Journal of Vibration and Shock*, 2012, 31(19): 21-25.
- [25] 葛家怡, 周鹏, 赵欣, 等. 脑电信号的多尺度熵分析 [J]. *计算机工程与应用*, 2009, 45(10): 13-15.
- GE J Y, ZHOU P, ZHAO X, et al. Multi-scale entropy analysis of EEG signal [J]. *Computer Engineering and Applications*, 2009, 45(10): 13-15.
- [26] 王俊, 宁新宝, 马千里. 基于多尺度熵的心电图分析 [J]. *中国生物医学工程学报*, 2008, 27(3): 331-334.
- WANG J, NING X B, MA Q L. Multi-scale entropy based electrocardiogram analysis [J]. *Chinese Journal of Biomedical Engineering*, 2008, 27(3): 331-334.
- [27] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proceedings of Royal Society A-Mathematical Physical and Engineering Science*, 1998, 454(1971): 903-995.
- [28] WU Z H, HUANG N E. Ensemble empirical mode

- decomposition: A noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1-41.
- [29] YE H J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method [J]. *Advances in Adaptive Data Analysis*, 2010, 2(2): 135-156.
- [30] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2011: 4144-4147.
- [31] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: A suitable tool for biomedical signal processing [J]. *Biomedical Signal Processing and Control*, 2014, 14(1): 19-29.
- [32] ALTUVE M, SUAREZ L, ARDILA J. Fundamental heart sounds analysis using improved complete ensemble EMD with adaptive noise [J]. *Biocybernetics and Biomedical Engineering*, 2020, 40(1): 426-439.
- [33] NAGUEH S F, SMISETH O A, APPLETON C P, et al. Recommendations for the evaluation of left ventricular diastolic function by echocardiography: An update from the American society of echocardiography and the European association of cardiovascular imaging [J]. *Journal of the American Society of Echocardiography*, 2016, 29(4): 277-314.
- [34] DEBBAL S M, BEREKSI-REGUIG F. Time-frequency analysis of the first and the second heartbeat sounds[J]. *Applied Mathematics and Computation*, 2007, 184(2): 1041-1052.
- [35] RUJOIE A, FALLAH A, RASHIDI S, et al. Classification and evaluation of the severity of tricuspid regurgitation using phonocardiogram [J]. *Biomedical Signal Processing and Control*, 2020, 57: 1-9.
- [36] SENGUR A. Support vector machine ensembles for intelligent diagnosis of valvular heart disease[J]. *Journal of Medical Systems*, 2012, 36(4): 2649-2655.

作者简介



杨洋, 2019年于贵州医科大学获得学士学位, 现为重庆大学硕士研究生。主要研究方向为生物医学信号检测及处理。

E-mail: yangyang99@cqu.edu.cn

Yang Yang received her B. Sc. degree from Guizhou Medical University in 2019. She is currently a master student at Chongqing University. Her main research direction is biomedical signal detection and processing.



郭兴明(通信作者), 分别在1984年、1991年和1994年于重庆大学获得学士、硕士和博士学位, 现为重庆大学教授、博士生导师, 主要研究方向为生物医学信号检测及仪器、远程医疗及医学图像处理。

E-mail: guoxm@cqu.edu.cn

Guo Xingming (Corresponding author) received his B. Sc., M. Sc., and Ph. D. degrees all from Chongqing University in 1984, 1991, and 1994, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His research interests include biomedical signal detection and instrument, telemedicine and medical image processing.