

DOI:10.3969/j.issn.1005-202X.2024.02.013

医学信号处理与医学仪器

基于小波包重构信号能量分布特征的心音分类识别

房玉, 昌业勤, 郭子健, 王维博, 刘栋博
西华大学电气与电子信息学院, 四川 成都 610039

【摘要】目的:为了有效识别心脏疾病心音的病理特征信息进行心脏疾病早期筛查,提出一种基于小波包系数重构信号能量序列的分布特征提取算法。**方法:**应用小波包分解算法对原始心音信号进行10层成分分解,获得各层小波包系数后对每一个系数进行重构,计算重构信号的能量并按原序排列构成能量序列。分析各层重构信号的能量序列的分布特征,并把分布特征作为分类特征。应用支持向量机、K近邻和决策树对正常心音和各类心脏疾病心音信号进行分类识别。**结果:**应用重构信号能量序列的分布特征结合决策树分类器,对公开数据集的5种心音分类识别准确率可达93.6%;对临床采集的正常心音和肥厚性心肌病心音数据分类准确率最高达95.6%。**结论:**本文算法能提取异常心音信号的有效病理信息,为临床心脏病听诊提供参考。

【关键词】心肌病;心音;小波包分解;峰度;偏度

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2024)02-0205-07

Heart sound classification using energy distribution features extracted with wavelet packet decomposition

FANG Yu, CHANG Yeqin, GUO Zijian, WANG Weibo, LIU Dongbo

School of Electrical and Electronic Information, Xihua University, Chengdu 610039, China

Abstract: Objective To propose a distribution feature extraction algorithm based on wavelet packet coefficients to reconstruct the signal energy sequence for effectively identifying the pathological features of heart sounds, thereby realizing the early screening of heart diseases. **Methods** The original heart sound signal was decomposed into 10 layers using wavelet packet decomposition algorithm. After obtaining the wavelet packet coefficients of each layer, each coefficient was reconstructed, and the energy of the reconstructed signal was calculated and arranged in the original order to form the energy sequence. The distribution characteristics of the energy sequence of the reconstructed signals at each layer were analyzed, and distribution features were taken as classification features. Support vector machine, K-nearest neighbor, and decision tree were used to classify and recognize normal heart sounds and the heart sound signals of various diseases. **Results** The combination of the distribution features of the reconstructed signal energy sequence and decision tree classifier had an accuracy of 93.6% for classifying 5 types of heart sounds on the public dataset, and the accuracy was 95.6% for identifying normal heart sounds and hypertrophic cardiomyopathy heart sounds. **Conclusion** The proposed algorithm can extract the effective pathological information of abnormal heart sounds, providing a reference for clinical cardiac auscultation.

Keywords: hypertrophic cardiomyopathy; heart sound; wavelet packet decomposition; kurtosis; skewness

前言

心血管疾病是威胁人类生命健康的主要疾病之一。心音信号由心脏的机械震动产生,可以反映心脏活动和血液流动的情况。非传染性疾病严重威胁

着人类的健康,其中,心脑血管疾病是非传染性疾病死亡的主要原因^[1]。目前,心血管疾病主要通过心音听诊、心电图和超声心动图等技术进行诊断。心音作为门诊评估心脏功能状态的最基本方法,操作简单方便,但其准确性依赖于医生的临床经验。当心瓣膜发生病变后,瓣膜会出现异常的机械波动,产生异常的心音,称为心杂音。临床上可根据心杂音产生的时期和性质,诊断某些心血管疾病^[2]。随着信息处理技术的快速发展,心音信号的量化分析成为心血管疾病早期诊断的重要辅助参考,其中,特征提取

【收稿日期】2023-10-26

【基金项目】国家自然科学基金(61901393, 61571371)

【作者简介】房玉,博士,研究方向:生物医学信号与处理, E-mail: Yfang_123@163.com

是对心音进行量化分析的关键。

时域中,Narvaez等^[3]基于小波变换,根据归一化香农能量特征包络,提取能量特征,最高准确率达99.26%;Sun等^[4]根据心音特征包络提取第一心音(S1)与第二心音(S2)、S1与S1之间的时间间隔用于诊断心室隔膜缺陷,准确率达98.4%;Sawant等^[5]提取心音信号过零率、能量、能量熵等特征,分类准确率为90.25%。频域上,Saeidi等^[6]基于自回归功率谱估计提取心音高频成分以及峰值信息,分类准确率为89.8%;孙树平等^[7]提出基于功率谱的特征提取算法,对正常第三心音和异常第三心音的特征参数范围进行统计学分析;Arora等^[8]使用灰度共生矩阵在心音信号频谱图上提取心音信号的纹理特征作为分类特征,最高准确率达100%;Al-Naami等^[9]基于离散傅里叶变换第三统计量,提取熵和对数熵等作为特征,最高分类准确率达89%。另外,Chen等^[10]对心音信号的香农包络进行S变换以提取信号的时频域能量特征,最高分类准确度达94.12%。Das等^[11]使用伽玛通滤波器提取心音信号特征,S1分类准确率最高达97.7%。Baydoun等^[12]直接以小波变换后的系数作为特征进行分类识别,分类准确率为86.6%。Upreti等^[13]提取一种能有效表示心音信号复杂动态的时变频谱特征用于对心血管疾病的分类。Yadav等^[14]通过对正常心音和异常心音进行倒谱分析,再从中提取出特征进行分类,准确率达到95%。See等^[15]将心音分割为3个频段,并提取每个频段的香农熵和谱熵作为特征,取得82.5%的分类准确率。Deng等^[16]提出一种改进的梅尔频率倒谱特征提取算法,分类准确率达98%。

此前,将峰度和偏度等分布特征作为特征的研究多限于时域上。王子超等^[17]将心音分割后,分别计算S1、S2、收缩期和舒张期的时间间隔、平均振幅、偏度、峰度等特征,并将心脏跳动周期的平均值和标准差作为特征。Shen^[18]提取峰度、偏度、波峰因子、方差和最大峰值作为特征,对心音进行分类。韩威等^[19]将心音分割后,提取各心动周期、S1、收缩期、S2、舒张期幅度值的偏度和偏度的均值以及标准差等时域特征,频域特征以及梅尔频率倒谱系数(Mel Frequency Cepstral Coefficients, MFCC)特征,采用卷积神经网络(Convolutional Neural Network, CNN)作为分类器对心音信号进行分类。余强等^[20]提取S1、S2、S3和S4的峰度和偏度并计算其各自的平均值和标准差等时域特征、频域特征以及小波特征,并采用Light Gradient Boosting Machine(LightGBM)作为分类器。

上述文献均只针对心音信号的时域分布提取峰

度和偏度等分布特征参数;然而,代表心脏疾病的杂音信号在频域上与正常心音信号区分度更明显。因此,本研究提出一种将分布特征与小波包分解重构相结合的特征提取算法。首先对心音进行预处理,再根据实验选取最优小波包基函数dmey,应用小波包分解得到各层小波包系数然后进行重构,计算获得的重构信号的能量序列。然后针对能量序列提取分布特征作为分类特征并进行组合。最后采用多种机器学习方法对心音数据进行分类识别,验证所提取特征的有效性。

1 方法

1.1 数据来源

本研究所使用的心音数据包括公开数据集和临床数据集。公开数据集由Yaseen等^[21]提供,数据集中的文件都以.wav格式保存,采集频率为8 kHz。数据集包含正常心音(Normal Signal, N)以及4种常见心血管疾病心音,分别是二尖瓣狭窄(Mitral Stenosis, MS)、主动脉瓣狭窄(Aortic Stenosis, AS)、二尖瓣返流(Mitral Regurgitation, MR)和二尖瓣脱垂(Mitral Valve Prolapse, MVP),各200例,合计1 000例。

临床数据集包括正常心音114例和肥厚型心肌病(Hypertrophic Cardiomyopathy, HCM)心音160例,合计274例。正常心音来自体检合格的健康受试者,年龄20~24岁;HCM心音数据来源于合作医院的HCM诊治与遗传咨询中心已确诊的HCM患者,年龄14~70岁。采集频率包括44.1 kHz和8.0 kHz,为保持采样频率的一致性以便后续分析,对原始信号统一降采样到8.0 kHz。

1.2 特征提取

小波分析是把时域信号分解成低频信息和高频信息两部分。小波包分解则不然,它不仅对低频部分进行分解,而且还对高频部分进行分解,是一种相比小波分解更精细的分解方法,应用更广泛^[22]。本研究提出一种基于小波包分解算法的心音特征提取算法,流程如图1所示。

1.2.1 小波包分解算法 在小波多分辨分析理论的基础上,小波包可由两组正交小波基滤波器系数生成^[23]。如果 $\{h_k\}_{k \in \mathbb{Z}}$ 和 $\{g_k\}_{k \in \mathbb{Z}}$ 是一组共轭镜像滤波器,满足:

$$\sum_{n \in \mathbb{Z}} h_{n-2k} h_{n-2l} = \delta_{kl}, \sum_{n \in \mathbb{Z}} h_n = \sqrt{2} \quad (1)$$

$$g_k = (-1)^k h_{1-k}, l, k \in \mathbb{Z} \quad (2)$$

其中, g_k 表示高通滤波器, h_k 表示低通滤波器, \mathbb{Z} 为整数集。 k 与 l 是整数序列的指标,代表滤波器的偏移量。

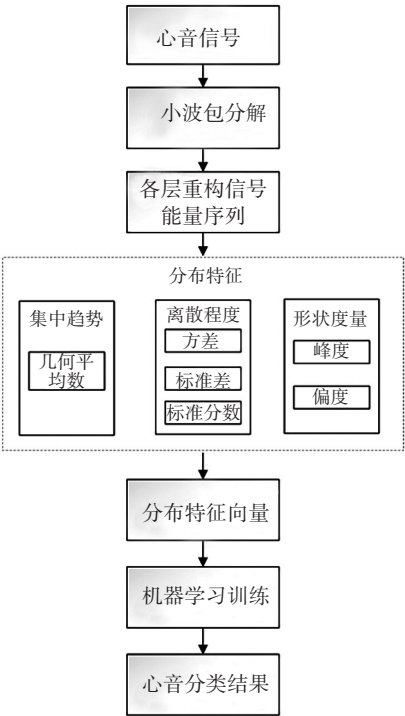


图1 特征提取流程图

Figure 1 Feature extraction flowchart

定义一系列小波基函数 $\{u_n(t)\}$ ($n=0, 1, 2, \dots$)满足如下二尺度方程:

$$u_{2n}(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} h_k u_n(2t - k) \tag{3}$$

$$u_{2n+1}(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} g_k u_n(2t - k) \tag{4}$$

小波包分解的空间划分如图2所示。




图2 小波包分解示意图

Figure 2 Wavelet packet decomposition

第一行表示预处理后的心音信号,第二行之后表示小波包对应层数的分解情况,列数表示频率和位置参数。经过一级分解把信号频带一分为二,得到第二层两个频率成分的子带,A表示低频,D表示高频,下标的序号表示小波包分解的层数(即尺度数)。3层分解的具体关系表示为:

$$S_3 = AAA_3 + DAA_3 + ADA_3 + DDA_3 + AAD_3 + DAD_3 + ADD_3 + DDD_3 \tag{5}$$

进而可以得到4层分解的具体关系为:

$$S_4 = AAAA_4 + AAAD_4 + DAAA_4 + DAAD_4 + ADAA_4 + ADAD_4 + DDAA_4 + DDAD_4 + AADA_4 + AADD_4 + DADA_4 + DADD_4 + ADDA_4 + ADDD_4 + DDDA_4 + DDDD_4 \tag{6}$$

其中, S 表示每一层的小波包分解后获得的小波包系数,更高层分解的具体关系可由此继续往下推出。

小波包分解算法为:

$$d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j+1,n}, k \in \mathbb{Z}, n \in \mathbb{Z}_+ \tag{7}$$

$$d_l^{j,2n+1} = \sum_k g_{k-2l} d_k^{j+1,n}, k \in \mathbb{Z}, n \in \mathbb{Z}_+ \tag{8}$$

其中, d 是每一层的频率子带, j 是尺度参数, k 是平移参数, n 是频率参数。由式(7)和式(8)可知,小波包分解的过程实质上就是通过一组高、低通组合的共轭正交滤波器 h, g 将信号分解到不同的频带上^[24]。

1.2.2 计算重构信号能量序列 对心音信号进行10层小波包分解,对2~10层的每一个小波包系数进行重构得到重构信号 $X_{a,b}$, $a \in (2, 10)$, $b \in (1, 2^a)$,其中,下标 a 表示用来重构的小波包系数所在的分解层数, b 表示用来重构的小波包系数在 a 层系数里的排序位置。

得到重构信号 $X_{a,b}$ 后,计算能量 $E_{a,b}$:

$$E_{a,b} = \sum_{i=1}^n [X_{a,b}(i)]^2 \tag{9}$$

其中, n 表示序列长度。

将能量按原顺序排列,获得对应的9层重构信号的能量序列 Y_a 。如第3层能量序列为:

$$Y_3 = (E_{3,1}, E_{3,2}, E_{3,3}, E_{3,4}, E_{3,5}, E_{3,6}, E_{3,7}, E_{3,8}) \tag{10}$$

图3展示的是各类心音第十层前百个重构信号能量序列的波形,可以明显看出不同种类的心音的重构信号能量的分布具有显著差异。同时,从纵坐标的幅值来观察,在固定频带区间中,各类心音的能量大小也有区分。

1.2.3 提取分布特征 对9层重构信号能量序列提取描述数据分布的集中趋势、离散程度和形状度量的分布特征。

几何平均数 $G(Y)$ 能衡量重构信号能量分布的集中程度,计算公式如下所示:

$$G(Y) = \sqrt[n]{\prod_{i=1}^n Y(i)} \tag{11}$$

方差通常都是计算样本方差 $s^2(Y)$,用以衡量重构信号能量的分布与均值的偏离程度,序列计算公式如下所示:

$$s^2(Y) = \frac{\sum_{i=1}^n (Y(i) - \bar{Y})^2}{n - 1} \tag{12}$$

样本方差开方后获得标准差 $s(Y)$,标准差能反映重构信号能量分布的离散程度,计算公式如下:

$$s(Y) = \sqrt{\frac{\sum_{i=1}^n (Y - \bar{Y})^2}{n - 1}} \tag{13}$$

每个能量序列的最大值的标准分数 $Z(Y)$ 可以用




图3 重构信号能量分布示意图

Figure 3 Energy distribution of the reconstructed signal

来检测最大值在能量序列中的相对位置,计算公式如下:

$$Z(Y) = \frac{(Y)_{\max} - \bar{Y}}{s} \quad (14)$$

峰度也称为峰态系数,是表征重构信号能量分布曲线在平均值处峰值高低的特征数,第十层重构能量序列的峰度 Kurt(Y)计算公式如下:

$$\text{Kurt}(Y) = E \left[\left(\frac{Y - \bar{Y}}{s} \right)^4 \right] = \frac{E(Y - \bar{Y})^4}{E^2[(Y - \bar{Y})^2]} \quad (15)$$

其中, E 代表期望值,获得的峰度分布箱型图如图4所示。




图4 峰度分布箱型图

Figure 4 Box diagram of kurtosis distribution

偏度是统计重构信号能量分布偏斜方向和程度的度量,是统计数据分布非对称程度的数值特征,定义为样本的三阶标准化矩。第十层重构能量序列的偏度 Skew(Y)计算公式如下:

$$\text{Skew}(Y) = E \left[\left(\frac{Y - \bar{Y}}{s} \right)^3 \right] \quad (16)$$

获得的偏度分布箱型图如图5所示。




图5 偏度分布箱型图

Figure 5 Box diagram of skewness distribution

1.3 评价指标

采用召回率(Recall)、精确率(Precision)、F1分数(F1-score)和准确率(Accuracy)对分类结果进行评估:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (17)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (18)$$

$$\text{F1-score} = (1 + l^2) \frac{\text{Precision} \times \text{Recall}}{l^2 \times \text{Precision} + \text{Recall}} \quad (19)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (20)$$

其中, TP 和 TN 分别表示 A 类心音被正确识别为 A 类心音的个数和非 A 类心音被正确识别为非 A 类心音的个数, FN 和 FP 分别表示 A 类心音被错误识别为非 A 类心音的个数和非 A 类心音被错误识别为 A 类心音的个数。

对公开数据库和临床数据进行小波包分解重构后提取重构信号能量序列的分布特征向量。实验使用 K 近邻 (K-Nearest Neighbor, KNN)、支持向量机 (Support Vector Machine, SVM) 和决策树分类器依据所提的特征向量进行心音分类识别。采用十折交叉验证法,每一类样本数据的 10% 用于测试, 90% 用于训练。

2 实验结果

单独以峰度或偏度结合 3 种机器学习方法平均分类准确率超过 92%, 其他 4 种特征的平均分类准确率均不超过 90%, 而峰度+偏度串行组成的混合特征

集结合决策树分类器分类准确率最高,可达93.6%(表1)。

表1 分布特征结合不同分类器在公开数据集上的分类结果
Table 1 Classification results of distribution features combined with different classifiers on the public dataset

特征	特征维数	分类器	准确率/%
几何平均数	9	决策树	82.7
		SVM	71.2
		KNN	83.1
方差	9	决策树	85.4
		SVM	78.3
		KNN	90.5
标准差	9	决策树	87.2
		SVM	80.1
		KNN	91.1
标准分数	9	决策树	88.5
		SVM	85.1
		KNN	78.2
峰度	9	决策树	92.9
		SVM	92.1
		KNN	92.5
偏度	9	决策树	92.8
		SVM	91.6
		KNN	92.3
峰度+偏度	18	决策树	93.6
		SVM	92.9
		KNN	92.5

图6为分类效果最佳时的混淆矩阵,即采用峰度+偏度特征向量结合决策树的方法。真实值表示真实类别,预测值表示分类器预测的类别。MS心音信号识别准确率最高,有6例被误判为MR和MVP心音;同时异常心音分类中,AS和MS心音都未被误判为正常心音,由此也验证了重构信号能量序列的形状度量分布特征对心音分类识别的有效性;但同时可以观察到,MR和MVP心音都有被误判为正常心音的现象存在。在临床上,正常心音包括S1和S2。AS心音表现为S1后会出现钻石型杂音^[2],MS心音的杂音则出现在舒张期,与正常心音的区分较为明显^[25]。MR心音的心杂音为收缩期杂音,且可能出现第三心音^[2],而MVP心音的心杂音则存在于收缩中晚期,非常贴近S2^[26]。因此MR和MVP中的个别数据与正常心音的区别度较AS和MS小,在临床上会出现将其误判为正常心音的情况。

真实值	主动脉瓣狭窄	192	4	2	2	
	二尖瓣反流	3	182	8	5	2
	二尖瓣狭窄		5	194	1	
	二尖瓣脱垂	5	8	8	176	3
	正常心音	1	5	1	1	192
		主动脉瓣狭窄	二尖瓣反流	二尖瓣狭窄	二尖瓣脱垂	正常心音
	预测值					

图6 公开数据集分类混淆矩阵
Figure 6 Classification confusion matrix on the public dataset

表2展示了提取的分布特征向量结合最优分类器在公开数据集上的分类效果评估。峰度+偏度组成的混合特征集对心音信号进行分类时,评价指标最高,平均召回率达到93.6%,平均精确率达到93.6%,F1分数为0.936,表现最优。

表2 分布特征结合最优分类器在公开数据集上的分类结果
Table 2 Classification results of distribution features combined with the optimal classifier on the public dataset

特征	召回率/%	精确率/%	F1分数	准确率/%
几何平均数	83.2	82.8	0.829	83.1
方差	90.8	90.4	0.906	90.5
标准差	91.6	91.0	0.912	91.1
标准分数	88.8	88.4	0.886	88.5
峰度	93.2	93.2	0.932	92.9
偏度	93.0	93.2	0.931	92.8
峰度+偏度	93.6	93.6	0.936	93.6

表3展示了临床数据集的分类结果。单独以峰度或偏度结合3种机器学习方法平均分类准确率也超过94%,而在所有特征集中,峰度+偏度串行组成的混合特征集结合决策树分类器分类准确率最高,为95.6%。

表4展示了所提的特征向量结合最优分类器在临床数据上的分类效果评估。峰度+偏度组成的混合特征集在4个分类指标上表现最优,召回率达到94.7%,精确率达到94.7%,F1分数为0.947,准确率为95.6%。

表5列出了涉及分布特征的心音分类文献中所提取特征、使用分类器的相关信息。与列出的文献相比,本研究提出的基于小波包系数重构信号能量分布特征向量的特征维数为最少的18维,在使用决

表 3 分布特征结合不同分类器在临床数据集上的分类结果

Table 3 Classification results of distribution features combined with different classifiers on the clinical dataset

特征	特征维数	分类器	准确率/%
几何平均数	9	决策树	85.0
		SVM	81.0
		KNN	86.5
方差	9	决策树	87.6
		SVM	80.7
		KNN	91.2
标准差	9	决策树	87.2
		SVM	87.6
		KNN	88.3
标准分数	9	决策树	89.4
		SVM	86.5
		KNN	80.3
峰度	9	决策树	95.4
		SVM	93.8
		KNN	94.9
偏度	9	决策树	95.4
		SVM	95.1
		KNN	94.9
峰度+偏度	18	决策树	95.6
		SVM	95.1
		KNN	94.9

表 4 分布特征结合最优分类器在临床数据集上的分类结果

Table 4 Classification results of distribution features combined with the optimal classifier on the clinical dataset

特征	召回率/%	精确率/%	F1 值	准确率/%
几何平均数	87.0	86.0	0.865	86.5
方差	91.5	91.0	0.912	91.2
标准差	87.5	88.5	0.880	88.3
标准分数	88.5	89.5	0.890	89.4
峰度	94.7	93.8	0.942	95.4
偏度	94.7	93.8	0.942	95.4
峰度+偏度	94.7	94.7	0.947	95.6

策树分类器对实验室临床采集的心音信号分类时，准确率最高，达 95.6%。以上实验结果证明基于小波包分解的分布特征向量从时域、频域相结合的分析角度有效地量化了心脏疾病病理性杂音特征，具有一定的临床参考意义。

3 讨论

分布特征在心音研究中经常被用于作为时域特征，但病理性心杂音往往在频域中与正常心音存在较大差异性。因此，本研究提出一种将分布特征参数与小波包分解相结合的特征提取算法。对正常心音和异常心音进行 10 层小波包分解，取 2~10 层重构

表 5 与已有文献方法的分类效果对比

Table 5 Comparison of classification performance with the existing methods

方法	特征	分类器	特征维数	分类准确率/%
文献[17]	峰度、偏度等时域特征,频域特征,MFCC 特征和小波域特征	XGBoost	20	86.6
文献[18]	峰度、偏度等时域特征,频域特征,时频域特征和相空间特征	SVM	36	91.0
文献[19]	峰度、偏度等时域特征,频域特征和 MFCC 特征	CNN	124	91.1
文献[20]	峰度、偏度等时域特征,频域特征和小波域特征	LightGBM	165	91.8
本文方法	基于小波包重构信号能量序列的峰度和偏度特征	决策树	18	95.6

后,对其进行能量计算,获得对应的能量序列,并对所得能量序列提取分布特征参数。最后采用 KNN、SVM 和决策树基于提取的特征向量进行心音多分类识别。通过对所有特征集的心音分类效果进行对比,峰度+偏度串行组成的特征向量对心脏病理的表征能力最强,对公开数据集中心音信号分类取得了最高 93.6% 的准确率,在临床数据集中进行验证,准确率最高达 95.6%。

在临床上,本研究对正常和异常心音的分类取

得了良好的效果,但对于各类病症的分类准确率仍有待提高。针对不同类型的心杂音出现在心动周期的时间不同,后续考虑对心动周期进行分割,更有针对性地对心杂音进行分类。同时,只应用峰度和偏度两种特征对由不同原因而引起的同种疾病的分类效果有待提高。为进一步提高心音的分类准确性,后续研究将提取多元特征,尝试更多的特征融合方法,完善并扩展本研究内容,提高数字化听诊的有效性和精度要求。

【参考文献】

- [1] 马丽媛,王增武,樊静,等.《中国心血管健康与疾病报告2021》概要[J]. 中国介入心脏病学杂志, 2022, 30(7): 481-496.
Ma LY, Wang ZW, Fan J, et al. Summary of the China cardiovascular health and disease report 2021[J]. Journal of China Interventional Cardiology, 2022, 30(7): 481-496.
- [2] 马爱群,胡大一. 心血管病学[M]. 北京: 人民卫生出版社, 2005: 514-515.
Ma AQ, Hu DY. Cardiovascular disease[M]. Beijing: People's Medical Publishing House, 2005: 514-515.
- [3] Narvaez P, Gutierrez S, Percybrooks WS. Automatic segmentation and classification of heart sounds using modified empirical wavelet transform and power features[J]. Appl Sci, 2020, 10(14): 4791.
- [4] Sun S, Wang H, Jiang Z, et al. Segmentation-based heart sound feature extraction combined with classifier models for a VSD diagnosis system[J]. Expert Syst Appl, 2014, 41(4 pt. 2): 1769-1780.
- [5] Sawant NK, Patidar S, Nesaragi N, et al. Automated detection of abnormal heart sound signals using Fano-factor constrained tunable quality wavelet transform[J]. Biocybern Biomed Eng, 2020, 41(1): 111-126.
- [6] Saeidi A, Almasganj F. Cardiac valves disorder classification based on active valves appearance periodic sequences tree of murmurs[J]. Biomed Signal Process Control, 2020, 57: 1-11.
- [7] 孙树平,李辉,张弼强,等.基于功率谱第三心音特征提取研究[J]. 图像与信号处理, 2020, 9(2): 86-92.
Sun SP, Li H, Zhang BQ, et al. Research on feature extraction of third heart sound based on power spectrum[J]. Journal of Image and Signal Processing, 2020, 9(2): 86-92.
- [8] Arora V, Eddie Yin-kwee NG, Leekha RS, et al. Health of things model for classifying human heart sound signals using co-occurrence matrix and spectrogram[J]. J Mech Med Biol, 2020, 20(6): 1-21.
- [9] Al-Naami B, Fraihat H, Gharaibeh NY, et al. A framework classification of heart sound signals in physioNet challenge 2016 using high order statistics and adaptive neuro-fuzzy inference system[J]. IEEE Access, 2020, 8: 224852-224859.
- [10] Chen P, Zhang Q. Classification of heart sounds using discrete time-frequency energy feature based on S transform and the wavelet threshold denoising[J]. Biomed Signal Process Control, 2020, 57(1): 1-9.
- [11] Das S, Pal S, Mitra M. Supervised model for cochleagram feature based fundamental heart sound identification[J]. Biomed Signal Process Control, 2019, 52: 32-40.
- [12] Baydoun M, Safatly L, Ghaziri H, et al. Analysis of heart sound anomalies using ensemble learning[J]. Biomed Signal Process Control, 2020, 62: 1-15.
- [13] Upreti P, Yüksel ME. Accurate classification of heart sounds for disease diagnosis by using spectral analysis and deep learning methods[J]. Data Anal Biomed Eng Healthcare, 2021: 215-232.
- [14] Yadav A, Dutta MK, Travieso CM, et al. Automatic classification of normal and abnormal PCG recording heart sound recording using fourier transform[C]//2018 IEEE International Work Conference on Bioinspired Intelligence. 2018: 1-9.
- [15] See AR, Cabili IS, Chen YJ. Heart sound classification based on nonlinear time-frequency features[J]. Sens Mater, 2022, 34(1): 217-223.
- [16] Deng MQ, Meng TT, Cao JW, et al. Heart sound classification based on improved MFCC features and convolutional recurrent neural networks[J]. Neural Netw, 2020, 130: 22-32.
- [17] 王子超,金衍瑞,赵利群,等.基于极限梯度提升和深度神经网络共同决策的心音分类方法[J]. 生物医学工程学杂志, 2021, 38(1): 10-20.
Wang ZC, Jin YR, Zhao LQ, et al. Heart sound classification method based on limit gradient lifting and deep neural network[J]. Journal of Biomedical Engineering, 2021, 38(1): 10-20.
- [18] Shen CH. Feature extraction and classification of heart murmurs based on acoustic qualities[J]. IRBM, 2021, 43(5): 470-478.
- [19] 韩威,李昌,刘么元,等.基于CNN的心音特征融合分类方法[J]. 自动化与信息工程, 2019, 40(5): 13-16.
Han W, Li C, Liu SY, et al. Heart sound feature fusion classification method based on CNN[J]. Automation and Information Engineering, 2019, 40(5): 13-16.
- [20] 余强,黄晓林.基于LightGBM的心音信号分类研究[J]. 陕西师范大学学报(自然科学版), 2020, 48(6): 47-55.
Yu Q, Huang XL. Research on heart sound signal classification based on LightGBM[J]. Journal of Shaanxi Normal University (Natural Science Edition), 2020, 48(6): 47-55.
- [21] Yaseen, Son GY, Kwon S. Classification of heart sound signal using multiple features[J]. Appl Sci, 2018, 8(12): 2344.
- [22] Langley P. Wavelet entropy as a measure of ventricular beat suppression from the electrocardiogram in atrial fibrillation[J]. Entropy, 2015, 17(9): 6397-6411.
- [23] 宋知用. Matlab语音信号分析与合成[M]. 北京: 北京航空航天大学出版社, 2017: 44-45.
Song ZY. Matlab voice signal analysis and synthesis [M]. Beijing: Beihang University Press, 2017: 44-45.
- [24] 张国华,袁中凡,李彬彬.心音信号特征提取小波包算法研究[J]. 振动与冲击, 2008, 27(7): 47-49.
Zhang GH, Yuan ZF, Li BB. Research on wavelet packet algorithm for feature extraction of heart sound signal[J]. Journal of Vibration and Shock, 2008, 27(7): 47-49.
- [25] 黄震华.二尖瓣狭窄的病因和发病机制[J]. 新医学, 2007, 38(5): 290.
Huang ZH. The etiology and pathogenesis of mitral stenosis[J]. Journal of New Medicine, 2007, 38(5): 290.
- [26] 郭颖,黄晓红.二尖瓣脱垂的流行病学与病因学研究进展[J]. 中国循环杂志, 2016, 31(9): 934-936.
Guo Y, Huang XH. Advances in epidemiology and etiology of mitral valve prolapse [J]. Chinese Circulation Journal, 2016, 31(9): 934-936.

(编辑:谭斯允)