

一种基于频谱包络特征提取的心音信号分类方法

易民升^{1,2}, 冷虹霞², 刘星², 房玉²

1. 邵阳职业技术学院, 湖南 邵阳 422000; 2. 西华大学电气与电子信息学院, 四川 成都 610039

【摘要】针对心血管疾病易诱发心脏结构、功能异常,造成心肌收缩与血液泵血能力衰减、严重危及患者身心健康的问题,提出一种基于频率平衡功率谱强度特征的心音分析方法,可实现正常心音与病理性心音信号的有效区分。首先采用自适应小波阈值收缩降噪算法对心音信号进行预处理,提取其频率平衡功率谱强度(FBPSI)包络。再提取FBPSI包络的多维特征,融合功率谱密度、能量谱密度提取的特征,通过MRMR算法对特征进行重要性分数排序。最后应用机器学习模型对心音信号进行分类识别。实验采用Yaseen以及2016心音挑战赛(PhysioNet/CinC Challenge 2016)两个公开数据集进行验证。十折交叉验证结果表明,本研究提出的有效特征向量与K近邻分类器相结合在Yaseen数据集上5分类准确率为97.40%,在PhysioNet/CinC Challenge 2016数据集中正常/异常分类准确率为89.11%,可为心血管疾病的预防和诊断提供有效参考。

【关键词】心音分类;功率谱强度;特征提取;心脏瓣膜疾病;频域包络

【中图分类号】R318;TP391.4

【文献标志码】A

【文章编号】1005-202X(2026)07-0958-07

Heart sound signal classification method based on spectral envelope feature extraction

YI Minsheng^{1,2}, LENG Hongxia², LIU Xing², FANG Yu²

1. Shaoyang Polytechnic, Shaoyang 422000, China; 2. School of Electrical and Electronic Information, Xihua University, Chengdu 610039, China

Abstract: Cardiovascular diseases can predispose the heart to structural and functional abnormalities, leading to weakened myocardial contractility and reduced blood-pumping capacity, which severely jeopardizes patients' physical and psychological health. Therefore, this study proposes a heart sound analysis method based on frequency-balanced power spectrum intensity (FBPSI) features to enable effective differentiation of normal and pathological heart sound signals. An adaptive wavelet threshold shrinkage denoising algorithm is first employed to preprocess heart sound signals and extract FBPSI envelopes. Subsequently, multi-dimensional features are extracted from the FBPSI envelopes, which are then fused with features derived from power spectral density and energy spectral density. The importance of these features is ranked using the minimum redundancy maximum relevance algorithm. Finally, machine learning models are applied for the classification and identification of heart sound signals. Experimental validation is conducted using the Yaseen and the PhysioNet/CinC Challenge 2016 public datasets. Ten-fold cross-validation results demonstrate that the proposed effective feature vectors combined with the K-nearest neighbor classifier achieves a five-class classification accuracy of 97.40% on the Yaseen dataset and a binary classification accuracy of 89.11% on the PhysioNet/CinC Challenge 2016 dataset, providing valuable references for the prevention and diagnosis of cardiovascular diseases.

Keywords: heart sound classification; power spectrum intensity; feature extraction; heart valve disease; frequency domain envelope

前言

随着社会发展和生活节奏的变化,慢性疾病的防治工作成为全民健康的关注热点^[1]。心血管疾病(Cardiovascular Disease, CVD)是常见的慢性疾病之一,如心脏瓣膜疾病严重影响着心脏的结构和功能,随着人口老龄化,其患病率也将进一步增加^[2]。因此,能在早期诊断出心脏疾病是非常必要的。临床上,常见的CVD检测方法主要包括动态心电图、超声

【收稿日期】2026-01-08

【基金项目】国家自然科学基金青年基金(61901393);湖南省教育厅科学研究项目(24C1214)

【作者简介】易民升,硕士,副教授,研究方向:信号处理、电气工程,
E-mail: yms_xhu@126.com

【通信作者】房玉,博士,副教授,研究方向:智能信息处理、生物医学信息工程, E-mail: Yfang_123@163.com

心动图、心音听诊^[3]等。考虑到成本及预防的需求,数字化心音听诊这一使用数字信号处理技术定量分析心音信号进行听诊辅助的心脏病筛查手段得到研究者的广泛关注。

国内外已有众多针对心音信号检测和分析的研究,其中提出有效心音特征是研究的重点之一。Nizam等^[4]对预处理后的信号提取希尔伯特(Hilbert)包络特征以及由第一心音、收缩期、第二心音、舒张期构成的心动周期特征和ResNet特征,使用随机森林对Yaseen数据集分类,获得94.78%的平均准确率。Oh等^[5]提出WaveNet模型对不同心音信号分类。Avanzato等^[6]利用基本卷积神经网络(CNN)进行心音分类,准确率达94.80%。房玉等^[7]利用小波包分析提取分布特征,在Yaseen数据集上获得93.6%的准确率。罗刚等^[8]提出一种增强型功率谱密度(PSD)特征提取方法,实现对情绪的分析与差异显著性判断。杨利英等^[9]对脑电时域信号提取平衡功率谱强度(BPSI)特征,在DEAP脑电数据集中情绪识别准确率达88%。许春冬等^[10]在不进行心音分割的基础上,利用PSD时频特征和CNN实现心音分类,在2016心音挑战赛(PhysioNet/CinC Challenge 2016)数据集上获得84.72%的准确率。Riccio等^[11]使用分区迭代函数系统(PIFS)对一维心音信号进行图像编码,生成二维彩色图像,在PhysioNet/CinC Challenge 2016上的分类准确率达到85%。李伟等^[12]使用CNN和循环神经网络(RNN)分别提取心音信号的时频域特征,在PhysioNet/CinC Challenge 2016数据集获得85.7%的准确率。Li等^[13]在时域、振幅域、能量域、高阶统计域、倒谱域、频域中共提取497个特征,结合CNN分类,基于PhysioNet/CinC Challenge 2016数据集在五折交叉验证中获得86.8%的平均准确率。

尽管已有大量研究致力于心音信号的分类,但现有方法在实际应用中仍存在诸多挑战,例如模型训练过程中参数调优繁琐,特征对不同数据集的泛化能力有限。此外,不同病理心音之间存在较高的相似性,进一步加大分类的难度。为了克服以上方法的局限性,本研究提出一种基于频率平衡功率谱强度(Frequency-Balanced Power Spectrum Intensity, FBPSI)包络的特征提取新方法,然后融合PSD特征与能量谱密度(ESD)特征对正常与不同病理性心音信号进行分类识别。

1 资料与方法

本研究对原始信号进行降采样与去噪,提取信号的FBPSI、PSD和ESD特征包络及其13个有效特征构成特征向量,输入到机器学习分类识别模型中,对正常心音和不同病理性心音进行分类。

1.1 数据集

Yassen数据集包括正常(Normal, N)、主动脉狭窄(AS)、二尖瓣狭窄(MS)、二尖瓣反流(MR)、二尖瓣脱垂(MVP)心音信号各200个样本^[14]。信号时长2.5~3.0 s,采样频率为8 kHz,文件均使用.wav格式存储。

PhysioNet/CinC Challenge 2016数据集中2 575个正常记录来自健康受试者,665个异常记录来自确诊为心脏病的患者,主要为二尖瓣反流、主动脉瓣狭窄和瓣膜手术等心脏瓣膜缺陷和冠状动脉疾病病人^[15]。录音的持续时间为5~120 s。整个数据集由6个数据库(a~f)组成,共计3 240个心音记录,采样频率为2 kHz,文件均为.wav格式。

1.2 数据预处理

为了消除设备或环境噪声,利用小波阈值降噪函数对原始心音信号进行去噪^[16]。正常心音信号的频率成分主要在50~300 Hz。因此,通过设定一个判断条件来选择不同的阈值函数 a ,再使用小波阈值对信号进行去噪。首先通过原始信号的频谱图,计算50~300 Hz与300 Hz以上的频谱能量占比是否属于正常心音信号所在的0.013~0.030范围内,若是,则选择阈值 $a=[1,1,1,1,1,1,1]$;否则,选择阈值 $a=[1,0,0,1,1.3,1.3,1.3]$ 。 a 向量内的7个值对应的是小波分解得到的不同频段范围。 a 值的大小对应去噪的强弱,由于代表高频的后3段中包含的心脏杂音较少,所以设置较大的去噪强度。最后,利用最大最小法对降噪后的信号进行归一化处理,获得去噪后的预处理信号 $x(n)$ 。

图1和图2分别展示正常信号和异常信号在去噪前后的时域、频域对比图。去噪后的信号在保留心音信号有效成分的同时,滤除大部分背景噪声和干扰成分,为后续的特征提取和分类分析奠定良好的基础。

1.3 PSD和ESD包络提取

频域分析是一种较好的标准化分析工具,在许多临床和生理现象中都得到应用。正常心音与异常心音在频谱的分布上存在一定的差异,PSD能够联合时频域特征,较好地描述心音信号的时频分布特征^[17]。对于有限长度的信号,可以使用快速傅里叶变换(FFT)计算^[18]:

$$\text{PSD}(f) = \frac{|X(f)|^2}{N \cdot fs} \quad (1)$$

其中, $X(f)$ 是信号的FFT变换; N 为信号的长度; fs 为采样频率。

ESD描述能量信号在频率域中的能量分布。ESD通过信号的FFT变换求得,表征信号能量在各个




图1 正常心音信号去噪前后的时频域对比

Figure 1 Temporal-frequency domain comparison of normal signals before and after denoising




图2 异常心音信号去噪前后的时频域对比图

Figure 2 Temporal-frequency domain comparison of abnormal signals before and after denoising

频率成分上的分布情况^[19]。对于离散信号 $x(n)$,其ESD计算公式如下所示:

$$\text{ESD}(f) = \frac{|x(f)|^2}{N} \quad (2)$$

1.4 心音FBPSI包络特征提取

对去噪后得到的心音信号 $x(n)$ 提取频率平衡功率谱强度包络 Q_{FBPSI} ,步骤参考文献[20]。对比同一个心音信号的FBPSI、PSD与ESD包络,如图3所示,

可以看出FBPSI包络减少高低频段的能量差异,达到能量平衡的效果在特征表达上优于PSD与ESD包络。




图3 心音信号的FBPSI、PSD、ESD包络

Figure 3 FBPSI, PSD, and ESD envelopes of heart sound signals

为了描述数据的集中趋势,衡量不同病理心音信号数据的离散程度,基于FBPSI包络提取4个常用统计特征:均值($\bar{Q}$)、标准差(Q_{std})、一阶差绝对值平均值($Q_{\delta 1}$)、二阶差绝对值平均值($Q_{\delta 2}$)。均值用于衡量心音包络的基线,标准差表示包络变化程度,一阶差绝对平均值反映信号振幅的平稳程度,二阶差绝对平均值评估信号变化速度和波动性的有效特征,特征表达式如式(3)~(4)所示:

$$Q_{\delta 1} = \frac{1}{M-1} \sum_{i=1}^{M-1} |Q_{i+1} - Q_i| \quad (3)$$

$$Q_{\delta 2} = \frac{1}{M-2} \sum_{i=1}^{M-2} |Q_{i+2} - Q_i| \quad (4)$$

其中, $Q=Q_{\text{FBPSI}}$ 表示频率平衡功率谱强度; M 表示窗口总个数。

由图4中正常、异常心音信号的FBPSI包络对比可知,两类信号包络特征区分度较高。正常心音包络存在明显的谐波峰值,这与信号频谱频率构成直接关联,为了分辨包络的频率成分,针对性地提取9个特征:重心频率(F_g)、均方频率(MSF)、频率分布系数(MF)、峰值幅值(Q_{peak})、峰值频率(F_{peak})、峰值频率与重心频率之差(F_{sub})、峰值幅值与重心幅值之差(Q_{sub})、峰值点与重心的距离(D)、重心之前的能量与总能量之比(E)。




图4 FBPSI包络的重心与峰值点

Figure 4 Gravity and peak point of the FBPSI envelopes

重心频率表明FBPSI包络的能量集中的频段范围,表征心音FBPSI包络在频率域上的重心,正常信号的重心频率相对于异常心杂音信号更低,病理性心音信号往往包含更多高频成分,例如由血流紊乱引起的杂音,导致重心频率向高频偏移^[21]。重心频率计算公式如下所示:

$$F_g = \frac{\sum_{k=1}^M f_k \cdot Q}{\sum_{k=1}^M Q} \quad (5)$$

其中, f_k 表示第 k 个窗口对应的频率值。

均方频率表征包络能量分布的扩张程度,较高的均方频率说明信号能量越分散且高频分量增加,这与心脏病变息息相关。为进一步分析正常与异常信号之间的频率分布差异,提出频率分布系数特征^[22]。均方频率与频率分布系数计算公式如下所示:

$$MSF = \frac{\sum_{k=1}^M f_k^2 \cdot Q}{\sum_{k=1}^M Q} \quad (6)$$

$$MF = \frac{MSF}{F_g} \quad (7)$$

峰值点为包络信号能量最大的频率点,峰值频率是包络信号取最大幅值时对应的频率。峰值幅值与频率计算公式如下所示:

$$Q_{peak} = \max |Q_i|, i = 1, 2, \dots, M \quad (8)$$

$$F_{peak} = \frac{f_{max k}}{N} \cdot f_s \quad (9)$$

峰值频率与重心频率之差即峰值点与重心在包络信号上的横向距离,重心与峰值点的幅值差即峰值点与重心在包络信号上的纵向距离,峰值点与重心的距离即两者间的欧氏距离,均描述主要能量分布中心和最大能量点之间的偏移程度。

如图4所示,正常信号的重心相较于异常信号距离峰值点更远。以上3个距离的计算公式如下所示:

$$F_{sub} = F_{peak} - F_g \quad (10)$$

$$Q_{sub} = \bar{Q} - Q_{peak} \quad (11)$$

$$D = \sqrt{F_{sub}^2 - Q_{sub}^2} \quad (12)$$

低于重心频率段的信号能量与总能量比是衡量信号频谱低频能量集中性的一个指标,反映信号的频谱分布特性,计算公式如下所示:

$$E = \frac{\sum_{k=0}^{(N \cdot F_g / f)} Q}{\sum_{k=0}^{N-1} Q} \quad (13)$$

同时提取PSD和ESD包络的各13维特征,与FBPSI特征组成39维特征向量。

1.5 特征筛选

为提高分类模型的性能,加快模型速度,运用最小冗余最大相关性(MRMR)算法^[23]对39个特征按照输出变量相关性最大且冗余性最小原则进行筛选。MRMR特征筛选算法如式(14)所示:

$$MRMR = \operatorname{argmax}_{f_i \in F} \left[I(f_i; c) - \frac{1}{|S|} \sum_{X_i \in S} I(f_i; X_i) \right] \quad (14)$$

其中, f 表示候选特征集; f_i 为 f 里的第 i 个候选特征; $I(*)$ 为互信息函数; $I(f_i; c)$ 表示候选特征 f_i 与类标签 c 之间的互信息函数值; $I(f_i; X_i)$ 表示候选特征 f_i 与选定特征 X_i 之间的互信息函数; S 表示已选特征集; $|S|$ 为已选特征的个数。

互信息函数 $I(X; Y)$ 定义为:

$$I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (15)$$

其中, $p(x, y)$ 为联合概率分布函数; $p(x)$ 与 $p(y)$ 为边缘概率分布函数。

1.6 评价指标

为了验证所提方法的性能,本研究采用5个常用指标进行评价分析,即准确率(Accuracy)、特异性(Specificity)、精确率(Precision)、召回率(Recall)和F1分数(F1 score)^[24]。5个指标的计算方法如式(16)~式(20)所示:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100\% \quad (16)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{FP} + \text{TN}} \times 100\% \quad (17)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (18)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (19)$$

$$\text{F1 - score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \times 100\% \quad (20)$$

其中,TP为真阳性结果的数目,表示被正确地分类为目标标签的样本数;TN为真阴性结果的数目,表示被正确地分类为非目标标签的样本数;FP为假阳性结果的数目,表示检测到非目标标签为目标标签的样本数;FN为假阴性结果的数目,表示检测到目标标签为非目标标签的样本数。

2 实验结果与讨论

对每个心音样本提取FBPSI包络,计算13维有效特征向量,并结合PSD与ESD特征构成特征向量

集,并将筛选的特征送入机器学习分类模型,包括精细树(FT)、支持向量机(SVM)、K-近邻算法(KNN)以及前馈神经网络(FFNN)。实验结果均采用十折交叉验证所得。

2.1 Yaseen数据集实验结果与讨论

图5展示经MRMR算法后的每个特征在Yaseen心音数据集的重要性分数,其中对比属于PSD、ESD、FBPSI特征的累计重要性分数,可以发现FBPSI的累计分数是最高的,为9.0476分。最终分类结果如表1所示。其中,使用KNN分类器能获得最优的分类准确率为97.4%。图6为Yaseen心音数据集5分类混淆矩阵。AS通常在心脏收缩期存在高频喷射性杂音,MR在收缩期会存在高频吹风样杂音,而MVP存在中期喀音和晚期收缩期杂音,所以导致三者之间存在误判,同时由于某些复杂的病情会导致心音重叠或不典型表现,从而使病理性心杂音之间难以区分^[25]。表2为本文方法与其他文献在Yaseen数据集上的性能对比,本文算法相较其他对比文献在特征维度和识别效果上均有优势。




图5 MRMR筛选的特征在Yaseen心音数据集上的重要性分数
Figure 5 Importance scores of features selected by MRMR on the Yaseen heart sound dataset

表1 Yaseen数据集在不同分类器上的分类结果(%)
Table 1 Classification results of different classifiers on the Yaseen dataset (%)

分类器	准确率	特异性	精确率	召回率	F1分数
FT	92.70	98.12	92.71	92.70	92.69
FFNN	94.40	98.60	94.42	94.40	94.40
SVM	96.10	99.02	96.11	96.10	96.10
KNN	97.40	99.35	97.41	97.40	97.40

2.2 PhysioNet/CinC Challenge 2016数据集实验结果与讨论

图7为经MRMR算法后的每个特征在PhysioNet/CinC Challenge 2016心音数据集的重要性分数,其中对比不同包络特征的累计重要性分数,可以发现FBPSI的累计分数仍是最高,为1.1093分。分类结果如表3所示。其中,使用KNN分类器能获




图6 Yaseen数据集的分类混淆矩阵
Figure 6 Confusion matrix for the Yaseen dataset

得最优的分类准确率为89.11%。图8为本文方法在PhysioNet/CinC Challenge 2016数据集上获得的分类

表 2 不同文献在 Yassen 数据集上的性能对比(%)

Table 2 Performance comparison of different methods on the Yassen dataset (%)

方法	特征集	分类器	准确率	特异性	精确率	召回率	F1 分数
文献[8]	小波包能量分布特征	决策树	93.60	98.40	93.60	93.60	93.60
文献[6]	原心音信号	WaveNet 模型	94.00	98.10	-	92.50	-
文献[4]	Hibert 包络、声学信号、Resnet 特征	随机森林	94.78	96.87	96.87	87.48	87.47
文献[7]	原始心音信号	CNN	94.80	94.80	-	95.40	94.95
本文算法	PSD、ESD、FBPSI	KNN	97.40	99.35	97.41	97.40	97.40

混淆矩阵,2 575 条正常信号中 95.96%的信号分类正确,但异常心音信号的分类准确率较差,正确率仅有 63.41%,这是因为该数据集的正常与异常信号数量不平衡,为了维持一个较高的数据集分类准确性,分类结果会偏向数量大的一类,从而导致数量较小的一类分类误差大。




图 7 MRMR 筛选的特征在 PhysioNet/CinC Challenge 2016 数据集上的重要性分数

Figure 7 Importance scores of features selected by MRMR on the PhysioNet/CinC Challenge 2016 dataset

表 3 PhysioNet/CinC Challenge 2016 数据集在不同分类器上的分类结果(%)

Table 3 Classification results of different classifiers on the PhysioNet/CinC Challenge 2016 dataset (%)

分类器	准确率	特异性	精确率	召回率	F1 分数
FT	87.04	78.18	80.66	78.18	79.31
FFNN	87.65	79.85	81.43	79.85	80.60
SVM	88.33	80.61	82.64	80.61	81.56
KNN	89.11	79.26	85.42	79.26	81.77

表 4 是本文方法与其他文献方法在 PhysioNet/CinC Challenge 2016 数据集上的对比结果,FBPSI 特征集结合 KNN 分类器的方法能获得更高的性能指标,相较于文献[11-14]分类准确率分别提升 4.39%、4.11%、3.41% 和 2.31%,结果表明,本文算法能够获得用于分类正常与异常心音信号的有效特征。

3 结论

本研究基于 FBPSI 包络提取心音信号有效特征,结合 KNN 分类器在 Yassen 数据集上多分类准确率、特异




图 8 PhysioNet/CinC Challenge 2016 数据集的分类混淆矩阵

Figure 8 Confusion matrix for the PhysioNet/CinC Challenge 2016 dataset

性、精确率、召回率和 F1 分数分别达到 97.40%、99.35%、97.41%、97.40% 和 97.40%;在 PhysioNet/CinC Challenge 2016 数据集上分类准确率、特异性、精确率、召回率和 F1 分数分别达到 89.11%、79.26%、85.42%、79.26% 和 81.77%。初步证实本研究算法的可行性,特别是在区

表4 不同文献在 PhysioNet/CinC Challenge 2016数据集上的性能对比(%)
Table 4 Performance comparison of different methods on the PhysioNet/CinC Challenge 2016 dataset (%)

方法	特征集	分类器	准确率	特异性	精确率	召回率	F1 分数
文献[11]	PSD-CNN	CNN	84.72	-	-	77.63	-
文献[12]	PIFS-ResNet18	ResNet18	85.00	-	-	-	86.00
文献[13]	声谱图、振动波形	CNN+RNN	85.70	-	-	-	-
文献[14]	时域、振幅域、能量域、高阶统计域、倒谱域、频域	CNN	86.80	86.60	-	87.00	-
本文方法	PSD、ESD、FBPSI	KNN	89.11	79.26	85.42	79.26	81.77

分不同病理性心音信号上,本文算法具有一定的应用价值。未来,还可以从扩大临床样本规模方面对本研究进行改善,涵盖多类的心音病理信号,以增强分类模型的泛化能力和可靠性。同时,考虑引入多模态数据,如心电图、心脏图像等,与心音信号进行融合分析,从多个角度全面评估心脏的健康状况。

【参考文献】

[1] 陈喆, 蒋薇薇, 朱佳敏, 等. 全球重大慢性病专利演进态势及我国发展对策研究[J]. 中国发明与专利, 2025, 22(3): 65-73.
Chen Z, Jiang WW, Zhu JM, et al. Analysis of patent development trend of major chronic diseases and development strategies in China[J]. China Invention & Patent, 2025, 22(3): 65-73.

[2] Jneid H, Chikwe J, Arnold SV, et al. 2024 ACC/AHA clinical performance and quality measures for adults with valvular and structural heart disease: a report of the American Heart Association/American College of Cardiology Joint Committee on Performance Measures [J]. Circ Cardiovasc Qual Outcomes, 2024, 17(4): e000129.

[3] 王志, 张菲菲, 陈始圆, 等. 心音智能听诊技术的研究现状与应用展望[J]. 软件导刊, 2023, 22(7): 212-219.
Wang Z, Zhang FF, Chen SY, et al. Research status and application prospect of intelligent auscultation technology of heart sound[J]. Software Guide, 2023, 22(7): 212-219.

[4] Nizam NB, Nuhash SI, Hasan T. Hilbert-envelope features for cardiac disease classification from noisy phonocardiograms [J]. Biomed Signal Process Control, 2022, 78: 103864.

[5] Oh SL, Jahmunah V, Ooi CP, et al. Classification of heart sound signals using a novel deep WaveNet model[J]. Comput Methods Programs Biomed, 2020, 196: 105604.

[6] Avanzato R, Beritelli F. Heart sound multiclass analysis based on raw data and convolutional neural network [J]. IEEE Sens Lett, 2020, 4(12): 1-4.

[7] 房玉, 昌业勤, 郭子健, 等. 基于小波包重构信号能量分布特征的心音分类识别[J]. 中国医学物理学杂志, 2024, 41(2): 205-211.
Fang Y, Chang YQ, Guo ZJ, et al. Heart sound classification using energy distribution features extracted with wavelet packet decomposition [J]. Chinese Journal of Medical Physics, 2024, 41(2): 205-211.

[8] 罗刚, 王铭勋, 黎明, 等. 面向情绪脑电分析的增强型功率谱密度特征提取方法[J]. 中国医学物理学杂志, 2022, 39(3): 349-356.
Luo G, Wang MX, Li M, et al. Feature extraction method based on enhanced power spectral density for emotion analysis using EEG [J]. Chinese Journal of Medical Physics, 2022, 39(3): 349-356.

[9] 杨利英, 孟天昊, 张清杨, 等. 特征融合实现脑电信号情感分析[J]. 西安电子科技大学学报, 2022, 49(6): 95-102.
Yang LY, Meng TH, Zhang QY, et al. Implementation of EEG emotion analysis via feature fusion [J]. Journal of Xidian University, 2022, 49(6): 95-102.

[10] 许春冬, 辛鹏丽, 周静, 等. 基于功率谱密度与卷积神经网络的心音分类[J]. 计算机工程与应用, 2021, 57(10): 125-132.
Xu CD, Xin PL, Zhou J, et al. Classification of heart sounds using

power spectral density and convolutional neural networks [J]. Computer Engineering and Applications, 2021, 57(10): 125-132.

[11] Riccio D, Brancati N, Sannino G, et al. CNN-based classification of phonocardiograms using fractal techniques [J]. Biomed Signal Process Control, 2023, 86(Part B): 105186.

[12] 李伟, 杨向东, 陈恩. 基于CNN和RNN联合网络的心音自动分类[J]. 计算机工程与设计, 2020, 41(1): 46-51.
Li W, Yang XD, Chen K. Heart sound classification based on CNN and RNN [J]. Computer Engineering and Design, 2020, 41(1): 46-51.

[13] Li F, Tang H, Shang S, et al. Classification of heart sounds using convolutional neural network[J]. Appl Sci, 2020, 10(11): 3956.

[14] Yaseen, Son GY, Kwon S. Classification of heart sound signal using multiple features[J]. Appl Sci, 2018, 8(12): 2344.

[15] Liu CY, Springer D, Li Q, et al. An open access database for the evaluation of heart sound algorithms [J]. Physiol Meas, 2016, 37(12): 2181-2213.

[16] 王燕, 王海滨, 刘立汉. 基于小波变换的心音信号降噪方法[J]. 信息与电子工程, 2010, 8(3): 303-307.
Wang Y, Wang HB, Liu LH. Noise reduction for heart sound based on wavelet transform [J]. Information and Electronic Engineering, 2010, 8(3): 303-307.

[17] 汪琴, 杨宏波, 潘家华, 等. 基于时频组合特征与自适应模糊神经网络的心音分类算法[J]. 生物医学工程学杂志, 2023, 40(6): 1152-1159.
Wang Q, Yang HB, Pan JH, et al. Heart sound classification algorithm based on time-frequency combination feature and adaptive fuzzy neural network [J]. Journal of Biomedical Engineering, 2023, 40(6): 1152-1159.

[18] Sanjeet S, Sahoo BD, Parhi KK. Low-energy real FFT architectures and their applications to seizure prediction from EEG [J]. Analog Integr Circuits Signal Process, 2023, 114(3): 287-298.

[19] Jing H, Jie R, Siqi L, et al. A cardiac audio classification method based on image expression of multidimensional features [J]. Sci Rep, 2024, 14(1): 23196.

[20] Fang Y, Leng HX, Wang WB, et al. Multi-level feature encoding algorithm based on FBPSI for heart sound classification [J]. Sci Rep, 2024, 14(1): 29132.

[21] Orozco-Reyes L, Alonso-Arévalo MA, García-Canseco E, et al. A deep-learning approach to heart sound classification based on combined time-frequency representations [J]. Technologies, 2025, 13(4): 147.

[22] Boz C, Kocyigit Y. Segmented vs. non-segmented heart sound classification: impact of feature extraction and machine learning models[J]. Appl Sci, 2025, 15(20): 11047.

[23] Ravikiran HK, Deepak R, Deepak HA, et al. A robust framework for Alzheimer's disease detection and staging: incorporating multi-feature integration, MRMR feature selection, and Random Forest classification [J]. Multimed Tools Appl, 2025, 84(22): 24903-24931.

[24] Wang JL, Zang JB, Yao S, et al. Multiclassification for heart sound signals under multiple networks and multi-view feature [J]. Measurement, 2024, 225: 114022.

[25] Zhang XF, Liu XH, Liu GZ. A heart sound signal classification method based on the mixed characteristics of Mel cepstrum coefficient and second-order spectrum [J]. Circuits Syst Signal Process, 2024, 43(6): 3533-3552.

(编辑:陈丽霞)