

## 基于时频融合特征的肺动脉高压心音分类模型

王彦麟, 孙静, 杨宏波, 郭涛, 潘家华, 王威廉

### 引用本文

王彦麟, 孙静, 杨宏波, 郭涛, 潘家华, 王威廉. [基于时频融合特征的肺动脉高压心音分类模型](#)[J]. 计算机科学, 2024, 51(6A): 230800091-7.

WANG Yanlin, SUN Jing, YANG Hongbo, GUO Tao, PAN Jiahua, WANG Weilian. [Classification Model of Heart Sounds in Pulmonary Hypertension Based on Time-Frequency Fusion Features](#) [J]. Computer Science, 2024, 51(6A): 230800091-7.

---

### 相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于心电信号的先天性心脏病肺动脉高压识别分类研究](#)

Study on Recognition and Classification of Congenital Heart Disease and Pulmonary Hypertension Based on ECG Signal

计算机科学, 2022, 49(11A): 210900144-8. <https://doi.org/10.11896/jsjcx.210900144>

#### [基于TK能量算子和包络融合的心音分割算法](#)

Heart Sound Segmentation Algorithm Based on TK Energy Operator and Envelope Fusion

计算机科学, 2022, 49(11A): 210900135-6. <https://doi.org/10.11896/jsjcx.210900135>

#### [多分支RA胶囊网络及在图像分类中的应用](#)

Multi-branch RA Capsule Network and Its Application in Image Classification

计算机科学, 2022, 49(6): 224-230. <https://doi.org/10.11896/jsjcx.210400087>

#### [结合物品相似性的社交信任推荐算法](#)

Social Trust Recommendation Algorithm Combining Item Similarity

计算机科学, 2022, 49(5): 144-151. <https://doi.org/10.11896/jsjcx.210300217>

#### [图像去雨算法在云物联网应用中的研究综述](#)

Survey of Intelligent Rain Removal Algorithms for Cloud-IoT Systems

计算机科学, 2021, 48(12): 231-242. <https://doi.org/10.11896/jsjcx.201000055>

# 基于时频融合特征的肺动脉高压心音分类模型

王彦麟<sup>1</sup> 孙静<sup>1</sup> 杨宏波<sup>2</sup> 郭涛<sup>2</sup> 潘家华<sup>2</sup> 王威廉<sup>1</sup>

1 云南大学信息学院 昆明 650500

2 昆明医科大学附属心血管病医院 昆明 650102

(1768653841@qq.com)

**摘要** 先心病相关肺动脉高压是一种严重的心血管疾病,致死率高,对其进行早期筛查与识别对于治愈尤为重要。目前临床是通过右心导管术确诊,此为有创检查,不便于在大规模筛查中采用,研究一种无创便捷的识别方法迫在眉睫。文中建立了一种时频融合的心音分类模型。首先对心音信号进行预处理,然后使用融合滤波器组对信号进行转换并求取动态时频特征,最后将得到的融合特征参数输入表格式先验数据拟合网络(TabPFN)中进行分类识别。实验结果表明,该算法在正常、CHD-PAH和CHD中的平均准确率、精确率、灵敏度、特异度和F1分别为92.21%,92.15%,92.15%,96.11%,92.14%。对于先心病相关肺动脉高压的早期筛查与识别具有重要意义。

**关键词:** 心音;先心病相关肺动脉高压;动态特征提取;时频特征融合;表格式先验数据拟合网络

**中图分类号** TN912

## Classification Model of Heart Sounds in Pulmonary Hypertension Based on Time-Frequency Fusion Features

WANG Yanlin<sup>1</sup>, SUN Jing<sup>1</sup>, YANG Hongbo<sup>2</sup>, GUO Tao<sup>2</sup>, PAN Jiahua<sup>2</sup> and WANG Weilian<sup>1</sup>

1 School of Information Science and Engineering, Yunnan University, Kunming 650500, China

2 Kunming Medical University Affiliated Cardiovascular Hospital, Kunming 650102, China

**Abstract** Pulmonary hypertension associated with congenital heart disease has a high mortality rate, and early screening and identification of it is particularly important for cure. At present, diagnosis is made by right heart catheterization, which is an invasive examination, it is not easy to use in screening, and has high risk and high cost. Therefore, it is urgent to study a non-invasive and convenient method for identification. In this paper, a time-frequency fusion heart sound classification model is established. First, the heart sound signal is preprocessed, then the signal is converted, and the dynamic time-frequency characteristics are obtained by using the fusion filter bank. Finally, the obtained fusion feature parameters are input into the TabPFN network for classification and recognition. Experimental results indicate that the algorithm has average accuracy, precision, sensitivity, specificity, and F1 scores of 92.21%, 92.15%, 92.15%, 96.11%, and 92.14% respectively in normal, CHD-PAH, and CHD. It is important for the early screening and identification of pulmonary hypertension associated with congenital heart disease.

**Keywords** Heart sound, Congenital heart disease-associated pulmonary arterial hypertension, Dynamic feature extraction, Time-Frequency feature fusion, Tabular prior-data fitted network(TabPFN)

## 1 引言

肺动脉高压(Pulmonary Artery Hypertension, PAH)是一种严重的心血管疾病,其原因是肺血管阻力逐渐增加,最终导致右心室衰竭<sup>[1-2]</sup>,并可能使大多数心血管疾病和呼吸系统疾病复杂化<sup>[3]</sup>。在2018年第六届世界肺动脉高压研讨会上,肺动脉高压被定义为静息时平均肺动脉压(Mean Pulmonary Artery Pressure, mPAP)大于20 mm Hg<sup>[4-6]</sup>。早诊断、早治疗是治愈肺动脉高压的关键。肺动脉高压的临床听诊特征包括第二心音亢进、与右心室相关的第三心音、全收缩期杂音(三尖瓣反流)和舒张期杂音(肺动脉瓣反流)等<sup>[7-8]</sup>。但是仅

通过听诊难以听到深层次的病理特征。当前先心病相关肺动脉高压的诊断方法主要包括心电图(Electrocardiogram, ECG)、超声心动图、胸部计算机断层扫描(Computed Tomography of the chest, CT)、心脏磁共振成像(Cardiac Magnetic Resonance Imaging, MRI)和右心导管术等<sup>[4,6,9]</sup>。但是以上方法存在设备不方便携带,诊断费用较高等问题,且右心导管术为有创检查,风险大,不便于在大规模筛查中使用。借助计算机对心音进行分析<sup>[10-12]</sup>,实现对肺动脉高压的辅助诊断变得十分重要。

心音信号分析流程主要包括预处理、特征提取和分类识别3个部分<sup>[13-14]</sup>。

基金项目:国家自然科学基金(81960067);云南省重大科技专项基金(2018ZF017)

This work was supported by the National Natural Science Foundation of China(81960067) and Major Science and Technology Projects of Yunnan Province in 2018(2018ZF017).

通信作者:王威廉(wlwang\_47@126.com)

预处理包括对心音信号进行去噪,提取包络以及分割等处理。文献[15]提出了一种基于子带包络和卷积神经网络的心音分类算法,相较于使用 STFT 等特征提取方法,准确率有所提升。文献[16]提出了一种时域希尔伯特包络特征(Hilbert Envelope Feature, HEF)提取方案,即使在高噪声记录中,该方法也能有效区分正常和异常心音。文献[17]提出了基于多质心舒张期持续时间分布的心音分割模型,该模型克服了当心率变化相对较大时可能过度拟合持续时间分布的单峰均值模型的局限性,其在 2016 年的公开数据集上进行实验, F1 平均得分为  $98.36 \pm 0.43$ 。

特征提取是 3 个步骤中很重要的一部分,目前常用的特征提取方法有 S 变换(S-transform), MFCC(Mel Frequency Cepstrum Coefficient, MFCC)[18]等。文献[19]使用 S 变换和小波阈值去噪的离散时频能量特征对心音进行分类,与传统的特征相比分类效果更好。文献[20]研究了从呼吸音信号中检测肺部异常,使用了 Bark 频率倒谱系数(BFCC)作为特征提取的一部分,其实验结果证实了该特征的有效性。文献[21]是基于对数梅尔频谱系数特征和卷积神经网络的心音分类,该方法对二分类的准确率为 93.89%,对多分类的准确率为 86.25%。

在心音的自动分类识别中,文献[22]提出了一种利用同态滤波和 K-means 聚类将心音分割成单心动周期的新方法。在第二分解级别使用 Daubechies 2 小波细节系数分割后形成特征向量,然后将这些特征向量用作神经网络的输入。但该研究所使用的样本量较少,其结果的说服力较弱。文献[23]提出了用熵测量来分析 PAH 的心音信号,分别计算信号的样本熵、模糊熵和模糊测度熵 3 个熵值,通过核密度估计构建两组中单个选定熵测度的概率密度函数,以及任意两个和多个选定熵测度的联合概率密度函数。最后使用朴素贝叶斯(Naive Bayes, NB)作为分类器,在 104 例信号中取得了 74%

的准确率。但该研究仍然存在着样本量较少和分类准确率较低等问题。

尽管国内外已经对先心病进行了大量的研究,但对于先心病相关肺动脉高压的研究相对较少且存在数据量不足、数据样本分布差异较大、分类准确率较低等问题。

针对上述研究存在的问题,本文建立了一种时频融合特征的先心病相关肺动脉高压(Congenital Heart Disease-associated Pulmonary Arterial Hypertension, CHD-PAH)心音分类模型。首先使用持续时间隐马尔可夫(Hidden Semi-Markov Model, HSMM)对原始心音信号进行分割[17],以扩充心音信号的数据量,从而解决肺动脉高压样本量少的问题;然后将分割后的心音信号使用 mel, bark 和 erb 3 个滤波器组提取融合时频特征参数;最后将得的时频特征参数输入 TabPFN 中进行分类,实现对肺动脉高压信号的高效识别,并与其他分类方法进行对比。本文所采用的信号均为原始心音信号,无须降噪,一定程度上简化了模型。此外,本文所提心音分类方法在准确率及各种评价指标上均优于其他分类方法。

## 2 算法框架及基本理论介绍

### 2.1 算法框架

本文的算法框架如图 1 所示。首先对心音进行分割,将一段较长的信号分割为多个的单个心动周期,在方便后续特征提取的同时也扩大了数据量;接着之后对分割后的信号进行预加重、分帧、加窗和快速傅里叶变换等一系列处理;之后使用 3 个不同的滤波器组对心音信号进行时频特征转换处理,并分别对转换后的信号计算各自的对数能量、离散余弦变换和动态特性;最后将 3 组动态特征进行特征融合,得到最终的特征参数,输入表格先验数据拟合网络(Tabular Prior-Data Fitted Network, TabPFN)中进行分类识别。算法框架流程图如图 1 所示。

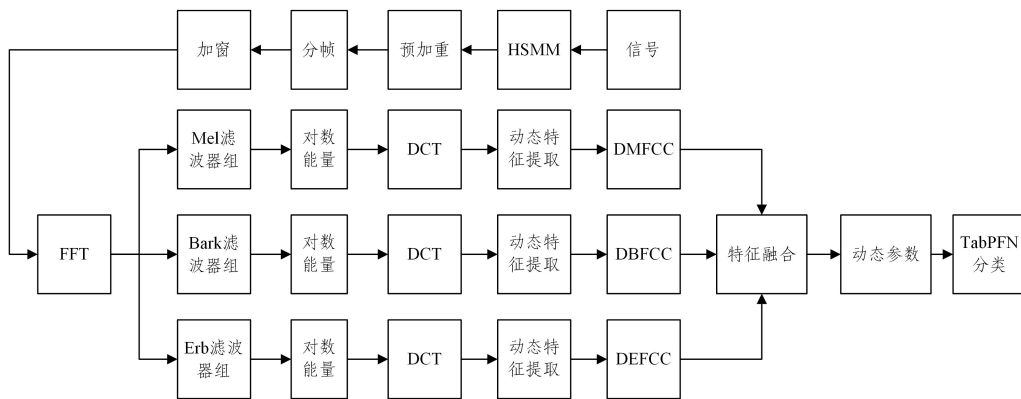


图 1 融合滤波器的的心音分类模型流程图

Fig. 1 Flowchart of classification model of heart sounds integrated with filters

### 2.2 基本理论介绍

先心病相关肺动脉高压是一种严重的心血管疾病,通常由医生通过听诊心音等方法来诊断,这种方法费时费力,而借助计算机进行辅助诊断可以极大提升诊断效率。

在计算机辅助诊断中,对心音信号进行特征提取和分类是诊断先心病相关肺动脉高压的关键步骤与研究重点。

由于先心病相关肺动脉高压数据量较少,对其进行分类实验时,模型往往会出现过拟合等泛化性不足的问题。为了提高模型的泛化能力,通常在预处理阶段采用 HSMM 对原

始心音信号进行分割以增加样本量[17]。HSMM 首先对心音样本进行位置标注;接着采用自相关估计法对心音的心动周期持续时间进行估计,通过高斯混合分布对样本的状态持续时间进行建模;然后通过训练集信号对隐马尔可夫模型进行优化;最后使用维特比算法对心音状态进行回溯得出 S1、收缩期、S2、舒张期。由于 HSMM 具有较高的鲁棒性与抗噪声性能,因此其更加符合临床环境的使用需求且有助于扩大先心病相关肺动脉高压的数据量。

Mel, Bark, ERB 这 3 种滤波器在语音信号方面均有较好

的应用,而心音信号与语音信号都属于声音信号,二者之间存在共性,因此本文采用将上述3种滤波器提取的时频特征进行融合的方法对先心病相关肺动脉高压进行特征提取。

Mel滤波器将心音信号转换为Mel频率表示,模拟人耳对音高的感知。其侧重于模拟人类对音高感知的特性,将频率划分为均匀分布的Mel频带,且它对低频和中频区域的细节也具有较高的分辨能力。

Bark滤波器将心音信号转换为Bark频率表示,模拟人耳对频率的感知。其将频率划分为均匀间隔的Bark频带。与Mel滤波器相比,Bark滤波器的中心频率分布相对均匀,能够更好地捕捉到整个频率范围内的细节信息。

在实际情况下,心音的采集由于受到操作人员的影响,通常会出现部分信号噪声较大的情况,导致信号信噪比急剧降低,在这种情况下,MFCC与BFCC这类方法的性能就会大幅下降。而ERB滤波器组可以突出原始心音信号的信息,降低噪声的影响<sup>[24]</sup>。ERB滤波器组在频域上对信号进行滤波,将信号分解成一系列不同频率的子带。它的非线性频率划分和滤波器响应特性能够抑制非心音信号的频率成分,减少噪声对心音信号的干扰。

先心病相关肺动脉高压在心音上的主要表现是第二心音分裂、第二心音的肺动脉瓣亢进和三尖瓣关闭不全的杂音。因此结合使用Mel滤波器、Bark滤波器和ERB滤波器对每个周期的心音进行动态时频特征提取以达到更全面的效果,这有助于全面分析心脏杂音信号的时频特征。这些滤波器提供了不同的频率划分方法,从而突出了不同频率范围内的特征。结合使用它们可以从更全面的视角来研究先心病相关肺动脉高压,从不同频率角度了解心音的特征和变化。将这三种时频特征进行融合,可以提高特征的鲁棒性和分类能力,从而提高心音信号的分类准确率。融合不同的特征可以弥补单一特征的不足,从而获得更全面、更准确的特征信息,使得分类器能够更好地区分不同的心音信号。

### 2.2.1 Mel滤波器组

梅尔倒谱系数(Mel-scale Frequency Cepstral Coefficients,MFCC)是在Mel刻度频率域提取出来的倒谱参数<sup>[25]</sup>,Mel刻度描述了人耳频率的非线性特性,它与频率的关系可用下式近似表示:

$$Mel(f) = 2595 * \lg\left(1 + \frac{f}{700}\right) \quad (1)$$

其中, $f$ 为语音信号的频率,单位为Hz。

如图2所示,Mel滤波器组是一组三角滤波器,其频率响应计算公式如下:

$$H_m(k) = \begin{cases} 0, & k < f(m-1) \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))}, & f(m-1) \leq k \leq f(m) \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m)-f(m-1))}, & f(m) \leq k \leq f(m+1) \\ 0, & k > f(m+1) \end{cases} \quad (2)$$

其中, $k$ 为每个三角滤波器的中心频率, $f(m-1)$ , $f(m)$ 和 $f(m+1)$ 分别对应第 $m$ 个滤波器的起始点、中间点和结束点。




图2 Mel滤波器组频率分布

Fig.2 Mel filter bank frequency distribution chart

### 2.2.2 Bark,ERB滤波器组

Bark刻度、ERB刻度是基于人的心理听觉特性提出的。信号频率高于500Hz时,Bark刻度约等于对数频率轴;低于500Hz时,Bark刻度的变化越来越线性,其频率轴如图3所示。Bark刻度与频率的转换关系如式(3)所示:

$$Bark(f) = 6 \sinh^{-1}\left(\frac{f}{600}\right) \quad (3)$$




图3 Bark滤波器组频率分布

Fig.3 Bark filter bank frequency distribution chart

ERB刻度给出了一个近似于人耳听觉的对带宽的过滤方法,可以将滤波器建模为矩形带通滤波器或带阻滤波器,其频率分布如图4所示。ERB刻度与频率的转换关系如式(4)所示:

$$ERB(f) = 11.17268 * \ln\left(1 + \frac{46.06538 * f}{f + 14678.49}\right) \quad (4)$$




图4 ERB滤波器组频率分布

Fig.4 ERB filter bank frequency distribution chart

### 2.2.3 动态参数提取

标准的倒谱参数MFCC只反映了语音参数的静态特性,而心音频谱的动态信息包含了丰富的信息,通过对MFCC求取差分谱可以得到心音信号的动态特征,将MFCC动态特征与标准MFCC参数相结合可以进一步提高分类精度。

动态MFCC参数提取的流程图如图5所示,其具体步骤如下:

#### 1)MFCC参数

心音信号首先经过一个高通滤波器,进行预加重,然后对心音信号进行分帧,帧长设置为256个采样点,在分帧之后选择汉明窗对信号进行加窗,以避免出现频谱泄露。之后将时域信号转换为频谱,并对心音信号的频谱取模平方得到心音

信号的功率谱。将信号通过 Mel 滤波器组,转换为 Mel 频谱。计算出每个滤波器输出的对数能量,之后对数能量进行离散余弦变换,即可求得心音信号的标准 MFCC 参数。

2)MFCC 动态差分参数提取

MFCC 参数只能反映心音信号的静态特征,通过对提取出的 MFCC 参数求一阶、二阶差分可以提取出其动态特征,将 MFCC 的差分参数与标准 MFCC 参数相结合,可以有效提高信号的识别率。MFCC 参数的一阶差分计算公式如下:

$$d_t = \begin{cases} C_t + 1 - C_t, & t < K \\ \frac{\sum_{k=1}^K k(C_{t+k} - C_{t-k})}{\sqrt{2 \sum_{k=1}^K k^2}}, & \text{others} \\ C_t - C_{t-1}, & t \geq Q - K \end{cases} \quad (5)$$



图 5 DMFCC 参数提取流程

Fig. 5 DMFCC parameter extraction process

二阶差分计算公式如下:

$$d_t^2 = \begin{cases} d_{t+1} - d_t, & t < K \\ \frac{\sum_{k=1}^K k(d_{t+k} - d_{t-k})}{\sqrt{2 \sum_{k=1}^K k^2}}, & \text{others} \\ d_t - d_{t-1}, & t \geq Q - K \end{cases} \quad (6)$$

其中,  $C_t$  为标准 MFCC 参数,  $K$  为差分阶数。

最后,求取标准 MFCC 参数、一阶差分参数和二阶差分参数三者的均值,得到具有一定动态特性的梅尔频谱倒谱参数 DMFCC (Dynamic Mel-scale Frequency Cepstral Coefficients)。

与 DMFCC 参数提取流程相似,将 DMFCC 参数提取流程中的第二步 Mel 刻度转换分别替换为 Bark 刻度转换和 ERB 刻度转换,即可求得动态 Bark 倒谱系数 (Dynamic Bark-scale Frequency Cepstral Coefficients, DBFCC) 和动态 ERB 倒谱系数 (Dynamic ERB-scale Frequency Cepstral Coefficients, DEFCC)。

2.3 特征融合

心音信号特征融合是来自于心音信号的不同特征融合在一起,以提取更全面、信息更加丰富的特征表示。此外,心音信号特征融合也可以减少特征噪声的影响,增强心音分类任务的泛化能力,以及提升任务的整体性能。

将提取到的 3 种时频特征参数 DMFCC, DBFCC 和 DEFCC 进行横向拼接,得到动态融合特征参数,每例信号有 36 个特征,示意图如图 6 所示。




图 6 特征融合流程

Fig. 6 Feature fusion process

2.4 分类模型

为了更好地实现 PAH 分类的准确性和可靠性,此次

实验的分类识别采用了表格式先验数据拟合网络 TabPFN 作为分类器。它是一种用于表格数据分类的深度学习模型<sup>[21]</sup>,是基于先验数据拟合网络 (PFN) 的框架,可以自适应地处理输入数据的特征数量和类型。

研究表明,Tabular Prior-Data Fitted Network (TabPFN) 在多个分类任务中表现出较高的准确度和鲁棒性,包括文字识别、图像分类、故障检测等领域<sup>[26]</sup>。此外,尽管肺动脉高压的样本量较少,但 TabPFN 在小样本数据上也能够保持较高的准确度和泛化能力,这为 PAH 分类任务提供了有力的支持。此外,TabPFN 具有处理缺失值、分类不平衡等常见数据问题的能力,在许多现有的数据集上都取得了较好的分类结果。综上所述,TabPFN 具有广泛的适用性和高效的性能,可以将其应用于先心病相关肺动脉高压的分类任务中。

TabPFN 通过混合先验模型生成新的数据集,并将其输入 Transformer 中进行训练,同时使用元学习器 (Meta Learning) 对 Transformer 的超参数进行更新,训练完毕后再对原始数据的测试集进行分类,得到分类结果。TabPFN 流程图如图 7 所示。

模型的工作流程如下:

第一步 将数据划分为训练集和测试集。

第二步 原始数据的训练集通过混合先验模型得到训练集的先验数据。

第三步 将原始数据的训练集输入元学习器中训练一定次数,得到训练完成的元学习器。

第四步 将先验数据与原始训练集混合,得到新训练集。

第五步 将新训练集输入 Transformer 中进行训练,并通过第三步中训练完成的元学习器更新 Transformer 的参数,直至 Transformer 收敛。

第六步 将测试集输入训练完成的 Transformer 中进行分类。

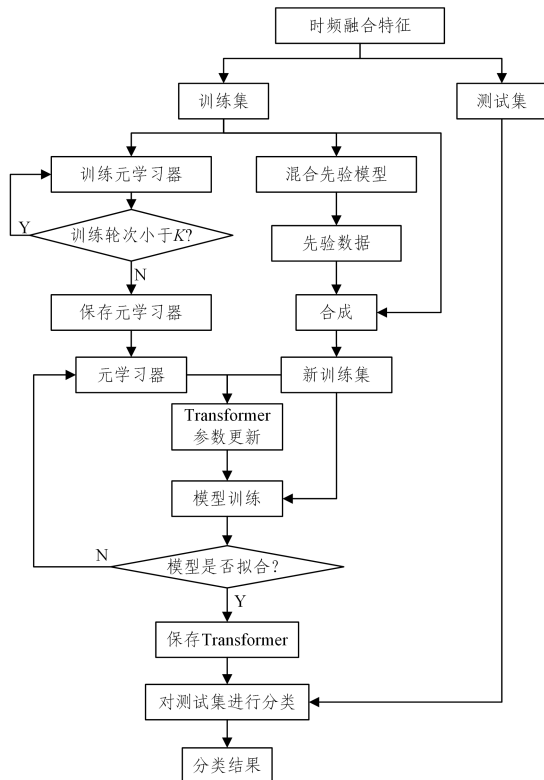


图 7 TabPFN 流程图

Fig. 7 TabPFN flowchart

### 3 实验结果

#### 3.1 数据来源

研究所用数据来源于课题组与云南省阜外心血管病医院临床采集的病例以及在云南省各地州进行先心病筛查中所常见的样本建立的数据库。所用的信号均经过了云南大学和云南省阜外心血管病医院的医学伦理委员会的审查批准;所采集数据的志愿者年龄阶段为6个月至18岁,所有志愿者均签署了知情同意书。该数据库中每例样本均含有临床常规5个听诊位置的信号,每个位置20s,采样频率为5000Hz。心音




图8 正常信号、异常信号以及肺动脉高压信号的时域波形图

Fig.8 Diagram of time domain waveform of normal signal,abnormal signal and pulmonary hypertension signal

#### 3.2 实验环境

本文所做实验硬件配置为:CPU为AMD Ryzen 7 5800H处理器,GPU为NVIDIA GeForce RTX 3060,内存为16GB,编程环境为MATLAB R2021b和Python 3.7。

#### 3.3 评价指标

本文使用以下5个指标来对文中所提出的算法进行评估:准确率(Accuracy, ACC)、精确度(Precision, PR)、灵敏度(Sensitivity, SE)、特异度(Specificity, SP)以及F1指数。其计算公式如下所示:

$$ACC = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (7)$$

$$PR = \frac{T_p}{T_p + F_p} \quad (8)$$

$$SE = \frac{T_p}{T_p + F_n} \quad (9)$$

$$SP = \frac{T_n}{T_n + F_p} \quad (10)$$

$$F1 = \frac{2T_p}{2T_p + F_n + F_p} \quad (11)$$

其中, $TP$ 为真阳性,表示实际类别为正常的样本,其预测类别也为正常; $TN$ 为真阴性,表示实际类别为非正常的样本,其预测类别也为非正常; $FP$ 为假阳性,表示实际类别为非正常的样本,其预测类别为正常; $FN$ 假阴性,表示实际类别为正常的样本,其预测类别为非正常。

#### 3.4 实验结果对比

首先,对模型准确性进行验证:使用TabPFN和其他分类器对BreastCancer数据集进行分类实验,其分类效果如表1所列。

表1 分类器准确性检验

Table 1 Tests of classifier accuracy

	SE	SP	PR	F1	ACC
ELM	0.9256	0.7910	0.8888	0.9068	0.8776
GBDT	0.9504	0.7910	0.8914	0.9200	0.8936
KNN	0.9504	0.8805	0.9349	0.9426	0.9255
TabPFN	0.9835	0.9851	0.9917	0.9876	0.9840

数据库的建立采用课题组自主研发的心音采集设备和The ONE ThinkLabs电子听诊器。实验数据取自健康志愿者、CHD患者、CHD-PAH患者各152名,共计456人5个听诊位置的2280例样本,其中正常、CHD、CHD-PAH样本各占760例。且异常信号中包含了常见的室间隔缺损、房间隔缺损和动脉导管未闭先心病。

经过心音分割之后得到的心动周期数分别为:正常17502个,异常17465个,肺动脉高压17486个并按照8:2的比例划分训练集和测试集。正常信号、异常信号以及肺动脉高压信号时域波形如图8所示。

从表1中可以看出,TabPFN在其他数据集上的分类结果较好,这也验证了本文所使用的分类模型的准确性。

将本文所提方法应用至先心病心音数据库中,在数据集相同的情况下,使用不同的特征提取方法做对比,其结果如表2所列。

表2 不同特征识别方法对比

Table 2 Comparison of different feature recognition methods

		SE	SP	PR	F1	ACC
MFCC <sup>[16]</sup>	正常	0.9962	0.9969	0.9940	0.9951	
	CHD-PAH	0.8455	0.9342	0.8653	0.8553	0.9018
	CHD	0.8630	0.9214	0.8455	0.8542	
DMFCC	正常	0.9979	0.9981	0.9962	0.9971	
	CHD-PAH	0.8475	0.9374	0.8732	0.8602	0.9053
	CHD	0.8726	0.9219	0.8489	0.8606	
DEFCC	正常	0.9951	0.9974	0.9948	0.9950	
	CHD-PAH	0.8715	0.9339	0.8685	0.8700	0.9101
	CHD	0.8630	0.9338	0.8663	0.8647	
DBFCC <sup>[18]</sup>	正常	0.9982	0.9956	0.9910	0.9946	
	CHD-PAH	0.8386	0.9264	0.8482	0.8434	0.8942
	CHD	0.8477	0.9187	0.8446	0.8461	
本文方法	正常	0.9966	0.9978	0.9958	0.9962	
	CHD-PAH	0.8822	0.9455	0.8891	0.8856	0.9221
	CHD	0.8857	0.9401	0.8796	0.8826	

通过上述实验对比可知,单独使用Mel滤波器、BARK滤波器和ERB滤波器得到的实验效果均没有特征融合后得到的效果好。这主要是由于上述3种滤波器对于心音的特征提取是针对不同的频段的,因此单独使用时容易造成提取的信息不够完全,导致部分病理信息被忽略。而本文使用3个滤波器结合求心音的动态时频特征能够更细致地提取心音的特征信息,得到0.9221的准确率。由评价指标可知,本文方法各方面的性能都优于常见的特征提取方法。

在数据量相同的情况下,使用不同的分类算法进行比较,结果如表3所列。

表 3 不同分类算法对比

Table 3 Comparison of different classification algorithms

		SE	SP	PR	F1	ACC
ELM (极限 学习机)	正常	0.9588	0.9471	0.9034	0.9303	
	CHD-PAH	0.7089	0.7957	0.6283	0.6662	0.7235
	CHD	0.4964	0.8438	0.6124	0.5483	
GBDT (梯度提升 决策树)	正常	0.9971	0.9896	0.9798	0.9884	
	CHD-PAH	0.7552	0.8735	0.753	0.7541	0.8262
	CHD	0.7253	0.8761	0.7408	0.733	
KNN (K-近邻)	正常	0.9997	0.9882	0.9765	0.9879	
	CHD-PAH	0.8461	0.8917	0.8002	0.8225	0.8690
	CHD	0.7629	0.9229	0.8312	0.7956	
LIGHTGBM (轻量级 梯度提升)	正常	0.9962	0.9938	0.9876	0.9919	
	CHD-PAH	0.7830	0.8874	0.7775	0.7802	0.8474
	CHD	0.7652	0.8892	0.7774	0.7712	
LR (逻辑回归)	正常	0.9772	0.9674	0.9371	0.9568	
	CHD-PAH	0.7062	0.8407	0.6884	0.6972	0.7698
	CHD	0.6278	0.8462	0.6735	0.6498	
RF (随机森林)	正常	0.9988	0.9917	0.9834	0.9911	
	CHD-PAH	0.8007	0.8986	0.8007	0.8007	0.8602
	CHD	0.7831	0.8993	0.7954	0.7892	
SVM (支持 向量机)	正常	0.9988	0.9946	0.9895	0.9941	
	CHD-PAH	0.7393	0.8432	0.7000	0.7191	0.8053
	CHD	0.6768	0.8702	0.7238	0.6996	
XGBOOST (极致梯度 提升)	正常	0.9920	0.9932	0.9866	0.9893	
	CHD-PAH	0.7568	0.8796	0.7573	0.7570	0.8322
	CHD	0.7477	0.8755	0.7513	0.7495	
TabPFN (本文方法)	正常	0.9966	0.9978	0.9958	0.9962	
	CHD-PAH	0.8822	0.9455	0.8891	0.8856	0.9221
	CHD	0.8857	0.9401	0.8796	0.8826	

通过对不同的分类算法与本文所使用的 TabPFN 分类器做比较,可以得出结论:在数据相同的情况下,TabPFN 在正常、CHD-PAH 和 CHD 3 个类别上都展现出了很好的性能指标,这进一步为 TabPFN 作为一种有效的分类器用于肺动脉高压的识别提供了支持。

通过消融实验可以看出,本文所提分类方法在分类准确率及各评价指标上均展现出较大的优势,使用本文所提方法对先心病相关肺动脉高压心音信号进行分类,能取得很高的准确率。

**结束语** 本文对分割之后的信号进行分帧加窗等一系列预处理,将处理过后的信号经过 mel,erb 和 bark 滤波器组进行转换,之后分别提取信号的动态时频特征,将得到的特征进行特征融合得到最终的参数信息,最后将参数输入 TabPFN 中进行分类识别,并与 SVM,XGBOOST,LIGHTGBM 等分类方法进行对比,证实了使用本文所提出的算法结合 TabPFN 分类器得到的三分类效果最好,有望用于先心病相关肺动脉高压的筛查中。此外,本文所提方法仅针对正常、异常和肺动脉高压心音信号进行三分类,并未考虑对其他心脏疾病进行识别。下一步的研究重点是考虑对其他心脏疾病进行识别与分类。

## 参考文献

- [1] KEARNEY K, KOTLYAR E, LAU E M T. Pulmonary vascular disease as a systemic and multisystem disease[J]. Clinics in Chest Medicine, 2021, 42(1):167-177.
- [2] NAEJIE R, RICHTER M J, RUBIN L J. The physiological basis of pulmonary arterial hypertension[J]. European Respiratory Journal, 2022, 59(6):2334-2354.
- [3] GALIE N, HUMBERT M, VACHIERY J L, et al. 2015 ESC/ERS guidelines for the diagnosis and treatment of pulmonary hypertension: the joint task force for the diagnosis and treatment of pulmonary hypertension of the European Society of Cardiology(ESC) and the European Respiratory Society(ERS); endorsed by: Association for European Paediatric and Congenital Cardiology(AEPC), International Society for Heart and Lung Transplantation(ISHLT)[J]. European Heart Journal, 2016, 37(1):67-119.
- [4] YAGHI S, NOVIKOV A, TRANDAFIRESCU T. Clinical update on pulmonary hypertension[J]. Journal of Investigative Medicine, 2020, 68(4):821-827.
- [5] MARON B A, KOVACS G, VAIDYA A, et al. Cardiopulmonary hemodynamics in pulmonary hypertension and heart failure: JACC review topic of the week[J]. Journal of the American College of Cardiology, 2020, 76(22):2671-2681.
- [6] THOMAS C A, ANDERSON R J, CONDON D F, et al. Diagnosis and management of pulmonary hypertension in the modern era: insights from the 6th world symposium[J]. Pulmonary Therapy, 2020, 6(1):9-22.
- [7] SOMMER N, GHOFRANI H A, PAK O, et al. Current and future treatments of pulmonary arterial hypertension[J]. British Journal of Pharmacology, 2021, 178(1):6-30.
- [8] PASCALL E, TULLOH R M R. Pulmonary hypertension in congenital heart disease[J]. Future Cardiology, 2018, 14(4):343-353.
- [9] SIMONNEAU G, MONTANI D, CELERMAJER D S, et al. Haemodynamic definitions and updated clinical classification of pulmonary hypertension[J]. European Respiratory Journal, 2019, 53(1):1913-1926.
- [10] SHUVO S B, ALAM S S, AYMAN S U, et al. NRC-Net: Automated noise robust cardio net for detecting valvular cardiac diseases using optimum transformation method with heart sound signals[J]. Biomedical Signal Processing and Control, 2023, 86(1):105272.
- [11] TANG H, RONG Y, CHAI L, et al. Deep Learning Radar for High-Fidelity Heart Sound Recovery in Real-World Scenarios[J]. IEEE Sensors Journal, 2023, 23:17803-17814.
- [12] WANG W B, QIN D M, WANG S B, et al. A multi-channel UNet framework based on SNMF-DCNN for robust heart-lung-sound separation[J]. Computers in Biology and Medicine, 2023, 164:10.
- [13] ELOLA A, ARAMENDI E, OLIVEIRA J, et al. Beyond Heart Murmur Detection: Automatic Murmur Grading From Phonocardiogram[J]. IEEE Journal of Biomedical and Health Informatics, 2023, 27:3856-3866.
- [14] GE B B, YANG H B, MA P Y, et al. Detection of pulmonary hypertension associated with congenital heart disease based on time-frequency domain and deep learning features[J]. Biomedical Signal Processing and Control, 2023, 81:11.
- [15] WANG X Z, YANG H B, ZONG R, et al. Heart sound classification based on sub-band envelope and convolution neural network[J]. Journal of Biomedical Engineering, 2021, 38(5):969-978.
- [16] NIZAM N B, NUHASH S I S K, HASAN T. Hilbert-envelope

- features for cardiac disease classification from noisy phonocardiograms[J]. *Biomedical Signal Processing and Control*, 2022, 78(1):253-262.
- [17] KAMSON A P, SHARMA L N, DANDAPAT S. Multi-centroid diastolic duration distribution based HSMM for heart sound segmentation[J]. *Biomedical Signal Processing and Control*, 2019, 48(1):265-272.
- [18] YILDIRIM M. Automatic classification and diagnosis of heart valve diseases using heart sounds with MFCC and proposed deep model[J/OL]. *Concurrency and Computation: Practice and Experience* (2022-07-25). <https://onlinelibrary.wiley.com/doi/10.1002/cpe.7232>.
- [19] CHEN P, ZHANG Q. Classification of heart sounds using discrete time-frequency energy feature based on S transform and the wavelet threshold denoising[J]. *Biomedical Signal Processing and Control*, 2020, 57(1):348-358.
- [20] DAR J A, SRIVASTAVA K K, LONE S A. Spectral features and optimal Hierarchical attention networks for pulmonary abnormality detection from the respiratory sound signals[J]. *Biomedical Signal Processing and Control*, 2022, 78(1):355-372.
- [21] KUI H, PAN J, ZONG R, et al. Heart sound classification based on log Mel-frequency spectral coefficients features and convolutional neural networks [J]. *Biomedical Signal Processing and Control*, 2021, 69(1):175-190.
- [22] GUPTA C N, PALANIAPPAN R, SWAMINATHAN S, et al. Neural network classification of homomorphic segmented heart sounds[J]. *Applied Soft Computing*, 2007, 7(1):286-297.
- [23] TANG H, JIANG Y, LI T, et al. Identification of pulmonary hypertension using entropy measure analysis of heart sound signal [J]. *Entropy*, 2018, 20(5):389-405.
- [24] LI W H, WANG W B, GONG W G. Acoustic feature extraction of anomalous sounds in public spaces under low signal-to-noise ratio[J]. *Acta Acustica*, 2019, 44(5):934-944.
- [25] GHAFFAR M S B A, KHAN U S, IQBAL J, et al. Improving classification performance of four class FNIRS-BCI using Mel Frequency Cepstral Coefficients(MFCC)[J]. *Infrared Physics & Technology*, 2021, 112(1):425-436.
- [26] HOLLMANN N, MULLER S, EGGENSPERGER K, et al. TabPFN: A transformer that solves small tabular classification problems in a second[J/OL](2022-11-29). <https://arxiv.org/abs/2207.01848>.



**WANG Yanlin**, born in 1998, postgraduate. Her main research interests include signal processing and machine learning.



**WANG Weilian**, born in 1947, bachelor, professor. His main research interests include signal processing and pattern recognition, biological signal processing, digital-analog hybrid IC and ASIC design.