

基于频域特征图的高血压靶器官损伤脉搏波预测模型

蔡书琛¹, 杨晶东¹, 翁雯浩¹, 齐晨浩¹, 尧明慧², 燕海霞²

(1. 上海理工大学光电信息与计算机工程学院, 上海 200093; 2. 上海中医药大学基础医学院, 上海 201203)

摘要: 针对高血压靶器官损伤时域脉搏波预测模型效率较低和分类精度较差的问题, 本文提出了一种基于频域脉搏波特征图预测模型, 实现高效无创辅助诊断。本文采用高斯滤波替换三角滤波, 将脉搏波时域特征转换为频域矩阵特征图, 并采用一种改进的 SiMAM 注意力机制模型 EfficientNetS, 提高脉搏波全局特征提取能力。608 例临床高血压靶器官损伤脉搏波样本经 5-Fold 交叉验证后分类模型评估指标 F_1 score、Accuracy、Precision、Sensitivity、曲线下面积 (Area under the curve, AUC) 值分别为: 97.31%、98.72%、97.71%、97.04%、99.13%。与典型模型相比, 本文方法具有较高的分类精度和泛化性能。此外, 本文采用随机森林算法研究时域和频域特征与脉搏波分类相关性, 深入挖掘潜在的影响高血压靶器官损伤分类的关键因素, 发现高血压靶器官损伤的发病机理, 为临床诊断提供有效支持。

关键词: 高血压靶器官损伤; 脉搏波; 频域特征图; 迁移学习

中图分类号: TP181 文献标志码: A

Prediction of Pulse Wave for Target Organ Damage in Hypertension Based on Frequency-Domain Feature Maps

CAI Shuchen¹, YANG Jingdong¹, WENG Wenhao¹, QI Chenhao¹, YAO Minghui², YAN Haixia²

(1. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Basic Medical College, Shanghai University of Traditional Chinese Medicine, Shanghai 201203, China)

Abstract: For less efficiency and low accuracy of predicting on hypertensive target organ damage, this paper proposes a prediction of hypertensive pulse wave based on mel frequency cepstral coefficient (MFCC)-based feature maps to accomplish the efficient and non-invasive diagnosis on target organ damage. For low accuracy of pulse-taking classification in temporal domain, pulse wave is transformed to the MFCC-based feature maps in frequency domain via replacing angular filter with Gaussian filter, an improved EfficientNet model, EfficientNetS is employed to enhance the ability of global feature extraction via adding the improved SiMAM attention mechanism. The clinical 608 cases of hypertension target organ damage concerning pulse-taking diagnosis are used. The evaluation indicators of five-fold cross-validation classification, i.e. F_1 score, accuracy, precision, sensitivity, area under the curve (AUC), are 97.31%, 98.72%, 97.71%, 97.04%, 99.13%, respectively. Compared to the typical models, the proposed method has higher classification accuracy and generalization performance. In addition, this paper also studies the correlation between classification of pulse wave and its features, and analyzes the feature importance ranking in temporal domain and frequency domain of pulse-taking, which can help clinicians seek the

occurrence mechanisms of hypertension caused by target organ damage, and find the effective measurements for timely prevention and treatment.

Key words: hypertensive target organ damage; pulse wave; frequency-domain feature map; transfer learning

引 言

高血压靶器官损害是指高血压引起或伴随的心、脑、肾、血管及其他器官的病理性损害,可分为功能性和结构性损害、急性或慢性损害、亚临床靶器官损害或临床并发症。因此,高血压防治中应特别注意早期检查亚临床靶器官损害,预防和及时治疗早期损害可明显提高患者的生存质量和治疗成功率。但现有诊断主要依靠实验室及影像学检查,常规化验包括:血常规、尿常规、血生化及心电图CT等影像学检查等,虽然检测精度较高,但检验费较高且诊断周期较长,常被患者忽视。

许多学者采用人工智能(Artificial intelligence, AI)技术实现早期高血压预测。Park等^[1]提出了一种混合特征选择方法,并采用贝叶斯网络诊断高血压,分类精度 F_1 score达到0.923。Ren等^[2]提出一种基于扩散边界的条件欧拉流体力学分析模型,采用血流动力学方法诊断高血压。Gupta等^[3]设计了一种基于静电转换机制的生物血压传感器测量血压范围。Altintas等^[4]提出了一种基于可穿戴、低压力和芯片实验室式的平台连续测量血压,该方法是一种基于波动法和上臂式血压监测的技术。刘杨漾等^[5]提出基于高斯层次聚类的高血压分类模型,可以有效处理动态血压缺失数据,提高高血压检测效率。田晓红^[6]根据病人心电图指标辅助诊断隐匿型高血压。李世锋等^[7]采用无创心功能检查方法诊断妊娠期高血压。赵唯唯等^[8]通过检测脉搏波传导速度诊断老年高血压患者。近年来深度学习已经运用于中医学脉诊研究,根据脉搏波分类结果分析患者心血管疾病。许文杰等^[9]融合线性预测倒谱系数(Linear prediction cepstrum coefficient, LPCC)和平均幅度差函数(Average magnitude difference function, AMDF)等特征,将不同声音的识别准确率提升到95%,但是两种特征均基于自相关函数构建,两特征频率较高且差异较大,无法体现脉搏波低频特性。刘森^[10]采用五层小波分解法提取每层脉搏波信号能量特征,提高了健康对照组和心血管疾病特征区分性。Zhang等^[11]采用9层卷积神经网络对脉诊样本分类,平均精度达到93.49%,但样本数量较少,模型泛化性较差。Li等^[12]提出了一种改进卷积神经网络(Convolutional neural network, CNN)模型对脉搏波分类,针对多种数据集测试,最高精度可达到95%,该模型增加dropout层减少过拟合,但不同脉诊样本对分类精度影响较大。文献[13]采用CNN模型研究Ⅱ型糖尿病患者的脉搏波特征图分类,最高精度可达到90.6%,但仅脉搏波样本无法根本上提高模型分类精度。文献[14]基于GooleNet和ResNet框架提出MIRnet模型对健康和亚健康人群脉象分类,准确率达到87.84%,但该模型还不适合靶器官损伤脉诊样本分类。Chen等^[15]采用了基于ResNet框架BRNet模型对女性脉搏波分类,判断是否处在妊娠期,预测准确率达到89%,曲线下面积(Area under the curve, AUC)值为0.91。虽然这些方法一定程度上解决了梯度消失问题,但模型深度多数为4~6层,无法学习到脉搏波深度时序特征。文献[16]将浅层特征和深层语义特征融合,采用传统机器学习方法进行舌象分类,该方法特征融合能力较弱,无法充分利用特征间的差异性提高分类精度。Yang等^[17]针对H型高血压脉诊数据,提出了一种异质集成模型,结合脉诊与问诊模型进行决策级融合,准确率提高到79.34%。该模型采用决策级融合方式,两种模型结果互不影响,但融合模型权重具有一定随机性,可能出现过拟合现象。此外,该方法针对H型高血压的脉诊和问诊数据,提出了一种网格搜索方法确定决策级融合权重,虽然可以得到较为可靠的最优化模型,但效率较低,且新数据加入可能会导致权重变化,增加分类的不稳定性。Grant等^[18]分别提取心脏肥大病患的X胸片特征与ICU特征进行异质特征融合,再通过线性层输出分类结果。该方法是一种决策级融合,各模型权重由模型参数决定。Yan等^[19]提出了一种基于脉搏波特征融合的无创血压预测方法,使用一种可穿戴设备测量血压,并提

取血液特征,使用基于梯度提升决策树(Gradient boosting decision tree, GBDT)的回归算法预测患者的收缩压与舒张压,该方法虽然可以直接对血压值进行预测,但需要采集多种传感器数据,测量误差因素较多。

由于时域脉搏波仅关注单周波图特征,无法体现脉搏波非线性动态特性,使分类区分度降低。因此本文提出一种基于脉搏波特征图的高血压靶器官损伤脉搏波分类模型,将时域脉搏波转化为频域梅尔倒谱系数(Mel frequency ceptral coefficient, MFCC)矩阵特征图,采用深度学习方法实现脉搏波频域特征图的自动分类,本文贡献如下:

- (1)采用改进脉搏波频域特征图的特征提取方法,提高时域脉搏波特征可区分性。
- (2)采用基于改进SiMAM注意力的迁移学习EfficientNet模型,提高脉搏波全局特征提取能力。
- (3)计算脉搏波时频域特征贡献率排名,分析影响高血压分类的时频域脉搏波的关键因素,挖掘高血压靶器官损伤发病机理,为临床诊断提供有效依据。

1 基于多特征融合的脉搏波分类模型

1.1 MFCC 特征提取模型

本文针对脉搏波信号,提出了一种脉搏波频域MFCC系数^[20]提取方法。脉搏波具有一定的非稳定性,使用传统的MFCC分析方法无法得到完整的频域特征,本文提出希尔伯特-黄变换高斯滤(Hilbert-Huang transform Gauss filter,HTTG)-MFCC方法,采用基于Hilbert边际谱和高斯滤波器组提取原信号的MFCC系数,高斯滤波器是一种具有优良特性的理想滤波器^[21],在各领域都有广泛的应用。特征提取的过程主要包括,预加重滤波、分帧、加窗、加噪、经验模态分解(Empirical mode decomposition, EMD)分解、Hilbert变换、时间维度积分、滤波器、对数运算与离散余弦变换(Discrete cosine transform, DCT)变换等步骤,流程如图1所示。

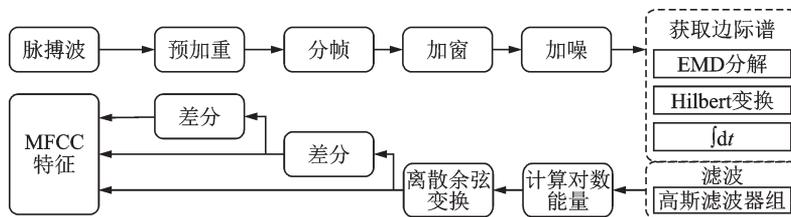


图1 改进 MFCC 特征提取过程

Fig.1 Improved MFCC feature extraction

假设任意时域脉搏波信号 $M(t)$, $t \in [0, T]$, T 为采样长度,经过式(1)预加重得到 $p(t)$,其中 a 为预加重系数,取值范围 $0.9 \sim 1$,其作用相当于高通滤波器,提取脉搏波的高频能量,原始脉搏波信号分帧后的每帧信号 $s(n)$ $n \in [0, N]$, N 为帧数。

$$p(t) = M(t) - a \times M(t - 1) \tag{1}$$

$$s(n) = \text{slice}(p(t), (n - 1) \times (\alpha - \beta), \alpha) \tag{2}$$

式中: α 为每帧长度; β 为帧移。加窗后每帧信号为

$$s'(n) = s(n) \times \omega(n) \tag{3}$$

式中: $\omega(n)$ 为窗函数,常见窗函数有矩形窗、汉明窗、汉宁窗等,计算过程为

$$X^i(n, t) = s^{li}(n, t) + g^i(t) \tag{4}$$

式中: $X^i(n, t)$, $i \in [0, I]$ 为加噪后每帧信号; $t \in [t_1, t_2]$; I 为样本总量; t_1, t_2 为帧的起止时刻; $g^i(t)$ 为加入的噪声信号。

将经过预处理的每帧信号 $x(t)$ 进行经验模态分解, 提取每帧变量边际谱输出。每帧信号 EMD 为 k 阶内涵模态分量 (Intrinsic mode functions, IMF) 分量 $c_k(t)$, $k \in [0, K]$, K 为停止 EMD 分解时的最大阶数。第 k 阶 IMF 分量的希尔伯特黄 (Hilbert-huang transform, HHT) 变换 $\hat{c}_k(t)$, 第 k 阶 IMF 分量的瞬时频率 $a_k(t)$, 瞬时幅值 $\omega_k(t)$, 式 (8) 计算边际谱 $H(\omega)$, 表示幅值频率分布, 与傅里叶谱相比, 边际谱不必为模拟非平稳信号, 增加不存在的谐波分量, 避免失去低频特征, 计算过程为

$$c_k(t) = \text{EMD}_k(X(t)) \quad (5)$$

$$a_k(t) = \sqrt{c_k(t)^2 + \hat{c}_k(t)^2} \quad (6)$$

$$\omega_k(t) = \frac{d}{dt} \arctg \frac{\hat{c}_k(t)}{c_k(t)} \quad (7)$$

$$H(\omega) = \int_0^T \text{Re} \left(\sum_{k=1}^K a_k(t) e^{j\omega_k(t)t} \right) dt \quad (8)$$

信号频率上下限边界映射为 Mel 尺度^[20], 构建 Mel 尺度下的高斯滤波器组, 根据式 (9) 计算 Mel 尺度下第 m 个高斯滤波器组 $\phi_m(\omega)$, $m \in [0, M]$, M 为滤波器组的总数, 通常为 26, 通过式 (10) 计算高斯滤波器标准差 σ^m , 第 m 个滤波器组中心频率 p_m 。式 (11) 计算出每个滤波器组输出的对数能量 $s(m)$, 经过离散余弦变化为 MFCC 系数 $G(l)$, $l \in [1, L]$, L 为 MFCC 系数阶数, 具体计算过程如下式

$$\phi_m(\omega) = e^{-\frac{(\omega - p_m)^2}{2\sigma_m^2}} \quad (9)$$

$$\sigma^m = p_{m+1} - p_m \quad (10)$$

$$s(m) = \ln \left(\sum_{\omega=0}^{W-1} |H(\omega)|^2 \phi_m(\omega) \right) \quad (11)$$

$$G(l) = \sum_{m=0}^{N-1} s(m) \cos \left(\frac{\pi l (m - 0.5)}{M} \right) \quad (12)$$

得到脉搏波 $M(t)$ 静态 MFCC 系数 $G(l)$, 经过差分计算, 得到对应一阶动态差分参数与二阶动态差分参数。

1.2 基于频域特征图的脉搏波分类模型

人体脉搏波信号具有周期短、不稳定、样本量少、局部特征复杂的特点, 转换为 MFCC 特征同样具有丰富的局部特征, 且具有非周期性特点。迁移学习网络 EfficientNet^[22] 具有分类精度高和训练速度快的特点, 对于脉搏波 MFCC 信号具有较好的分类效果。EfficientNet 模型通过堆叠基础模块 MBConv, 调整网络结构深度、宽度和分辨率, 保持较低的网络参数数量和较高的网络分类精度。但随着网络深度和宽度增加, 可能导致模型过拟合, 使验证集分类精度降低。

为此本文在 MBConv 基础上加入 SimAM^[23] 注意力机制模块, SimAM 模块没有增加网络参数, 使 MBConv 模块输出三维权重数据, 与不同通道的一维权重和不同位置的二维权重相比, 三维权重提高了注意力模块学习能力。因此, 改进 EfficientNet 网络没有增加网络复杂度, 但保留了 EfficientNet 速度快的优点, 又提升了对局部特征与深层特征的提取能力。在 MBConv 模块基础上, 本文提出了基于融合注意力机制的迁移学习模型 EfficientNetS, 在不增加额外参数的情况下提升网络分类效果, 其中改进后 MBConv 如图 2 所示, 图 2 中批量样本归一化用 BN 表示, 全连接层用 FC 表示。为了提高 SimAM 在网

络中的适应性,本文对原本的 SimAM 的进行了封装处理,在其之前加入了卷积层增加局部上下文信息,并在 SimAM 模块之后加入 BatchNorm 层和激活函数,增强网络对输出特征的判别能力。针对脉搏波提取的 MFCC 数据,加入了 SimAM 模块后,可以提取深层非周期性特征。MFCC 特征包括静态系数与动态差分系数,使频域脉搏波具有更好的区分性。本文采用 EfficientNetS 模型提取时域脉搏波数据对应的 36 维度频域 MFCC 特征,频域 MFCC 脉搏波动和静态特征包含了输入脉搏波的所有包络信息,现代中医脉诊通过其包络信息中提取数据特征对脉搏波进行分类诊断,这从另一角度说明了 MFCC 特征的有效性,同时输出特征还包含了脉搏波的频域边际谱信息。基于 MFCC 频域特征脉搏波分类模型结构如图 3 所示。

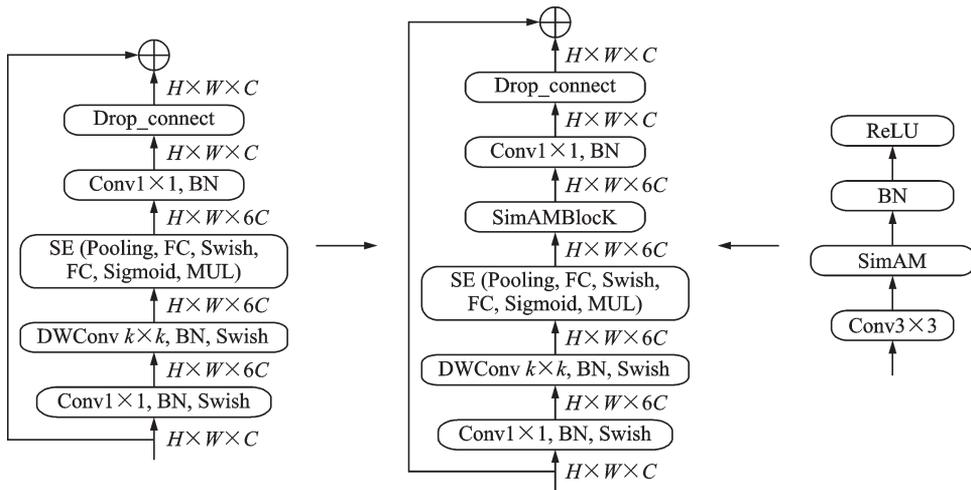


图 2 改进 MBConv 模块
Fig.2 Improved MBConv module

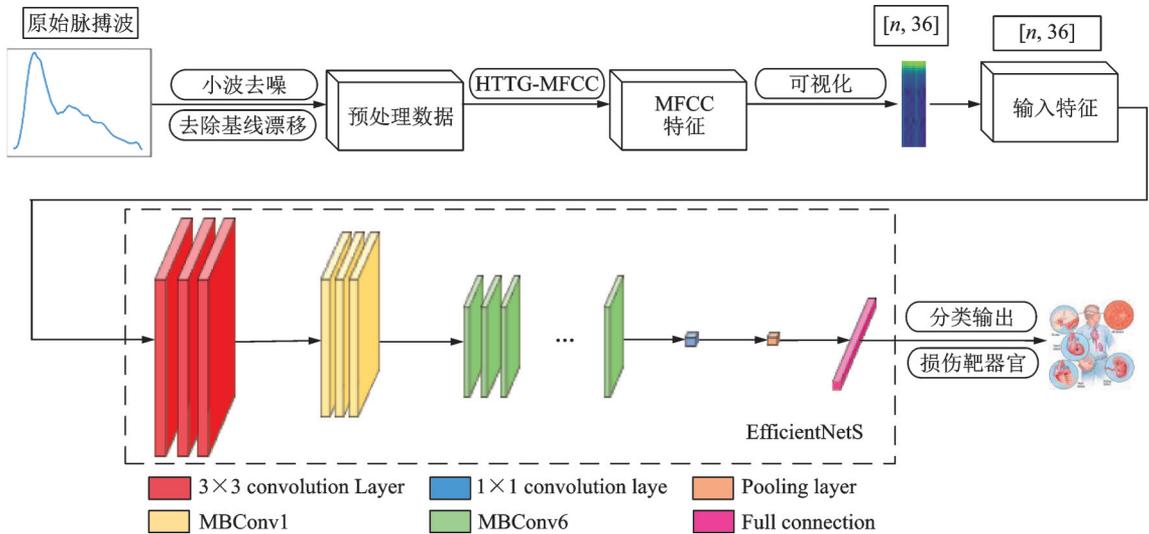


图 3 脉搏波分类模型结构图

Fig.3 Architecture of classification model of pulse wave

实现过程如下:

输入: X_i, Y_i, Inc_i , where $i = 1, 2, \dots, n$, X pulse data, Y label, n number of train data, F number of frames in pulse

data, m number of train epoch, t number of test date

输出: $P(X, Y) = F, M, C$

- (1) for $i = 1, 2, 3, \dots, n$ do
 - (2) $M_i = \text{MFCC}(X_i)$
 - (3)
$$D_i = \frac{\sum_{t=1}^T t \times (M_{j+t} - M_{j-t})}{2 \times \sum_{t=1}^T t^2}$$
 - (4)
$$DD_i = \frac{\sum_{t=1}^T n \times (D_{j+t} - D_{j-t})}{2 \times \sum_{t=1}^T t^2}$$
 - (5) $F(X_i) = (M, D, DD)$ for $i = 1, 2, 3, \dots, m$ do
 - (6) for $j = 1, 2, 3, \dots, n/m$ do
 - (7) $P_{ij} = \text{EfficientNet.train}(M_{ij}, Y_{ij})$
 - (8) $\text{EfficientNet.backPropagation}()$
 - (9) end for
 - (10) for $k = 1, 2, 3, \dots, t$ do
 - (11) $T = \text{EfficientNet.test}(M_{ik}, Y_{ik})$
 - (12) $\text{accuracy} = \text{calculateAcc}(T, Y_{ik})$
 - (13) if $\text{accuracy} > \text{maxAccuracy}$:
 - (14) $\text{update}(\text{maxAccuracy})$
- End

2 样本分布与性能评估

2.1 样本分布

本文脉诊数据通过脉诊仪采集,患者在采集之前放松 5 min,确保采集到平稳的脉搏数据,采样频率一般为 1 000 Hz。本文实验采用上海中医药大学附属龙华医院与中西医结合医院所提供的临床脉诊数据,共有 608 例患者样本。其中,男性病例占 243 例子,平均年龄 66 岁,女性病例 365 例,平均年龄 69 岁。其中一级损伤 181 人,二级损伤 152 人,三级损伤 275 人,样本分布如图 4 所示。

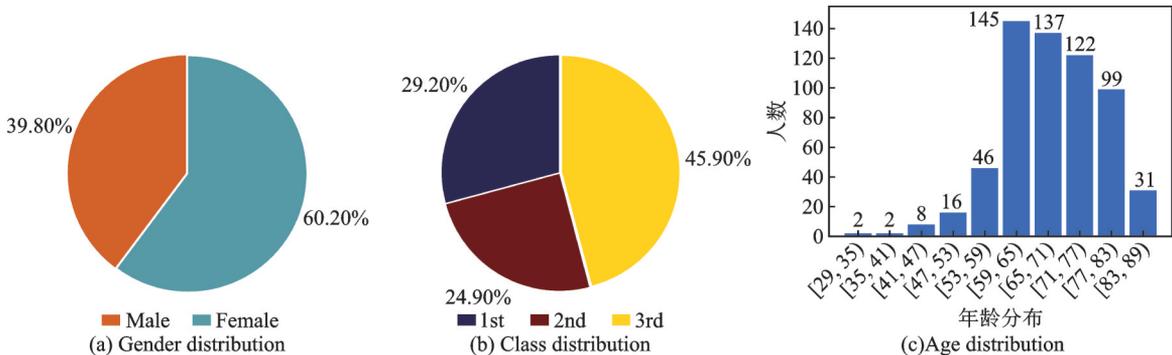


图4 样本分布

Fig.4 Sample distribution

2.2 评估标准

本文分类模型评价指标包括模型预测的混淆矩阵4个基本指标,分别是真阳性(True positive, TP),假阳性(False positive, FP),真阴性(True negative, TN),以及假阴性(False negative, FN),进而得到针对多分类常用的3个评估指标,即准确度(Accuracy),召回率(Recall),以及 F_1 score。其中Accuracy衡量的是所有分类正确的样本占全部样本的比例;Recall表示在所有正例的样本中被正确分类的比例; F_1 score是模型精确率和召回率的一种加权平均,同时兼顾了分类模型的精确率和召回率。本文3分类任务使用微平均(Micro-averaging)方法计算评价参数,微平均是对数据集中每一个实例不分类,统计全局混淆矩阵,微平均部分参数计算公式如下

$$\text{Micro_precision} = \frac{\sum_{i=1}^n \text{TP}_i}{\sum_{i=1}^n \text{TP}_i + \sum_{i=1}^n \text{FP}_i} \quad (13)$$

$$\text{Micro}_{\text{Sensitivity}} = \frac{\sum_{i=1}^n \text{TP}_i}{\sum_{i=1}^n \text{TP}_i + \sum_{i=1}^n \text{FN}_i} \quad (14)$$

$$\text{Micro}_{F_1} = \frac{2 \times \text{Micro}_p \times \text{Micro}_{\text{Sen}}}{\text{Micro}_p + \text{Micro}_{\text{Sen}}} \quad (15)$$

本文还采用接收者操作特征(Receiver operating characteristic, ROC)曲线和精度-召回率(Precision recall, PR)曲线来可视化模型分类性能。评价基线漂移处理和降噪处理的指标有信噪比(Signal noise ratio, SNR),均方根误差(Root mean square error, RMSE)和相关系数(Correlation coefficient, COR),计算方法如下

$$\text{RMSE} = \sqrt{\frac{(x'_1 - x_1)^2 + (x'_2 - x_2)^2 + \dots + (x'_n - x_n)^2}{n}} \quad (16)$$

$$\text{COR} = \frac{\sum_{i=1}^n (x_i - \bar{x})(x'_i - \bar{x}')}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (x'_i - \bar{x}')^2}} \quad (17)$$

$$\text{SNR} = 10 \lg \left(\frac{\sum_{n=1}^N x^2}{\sum_{n=1}^N [x'^2 - x]^2} \right) \quad (18)$$

式中: x 为原始信号; x' 为处理后信号。

2.3 模型超参数

本文EfficientNetS模型构造参数如表1所示。特征层主要由MBS_Conv构成,在每个Stage中,重复堆叠的MBS_Conv块中第1个MBS_Conv的步长为表1中给出值,其余MBS_Conv的Stride为1,使这一层输出与下一层输入数据格式相同。输出层主要由池化层和全连接层组成。其中Filters size为每层滤波器内核尺寸,OutPutChannels为每个Stage输出数据的通道数,OutPutShape为输出数据中每个通道数据的尺寸,Repeats为每个Stage中,模块重复堆叠数。

2.4 脉诊波形预处理

本文使用小波降噪(Wavelet-based denosing)方法对脉搏波形进行降噪处理,采用不同阶数小波基

表1 模型超参数

Table 1 Model hyperparameters

Stage	Layer	Filters size	Output channel	Stride	Output shape	Repeat
0	Input	0	0	0	240×240	1
1	Conv	3×3	32	2	120×120	1
2	MBS1_Conv	3×3	16	1	120×120	2
3	MBS6_Conv	3×3	24	2	120×120	4
4	MBS6_Conv	5×5	40	2	60×60	4
5	MBS6_Conv	3×3	80	2	30×30	6
6	MBS6_Conv	5×5	112	2	15×15	6
7	MBS6_Conv	5×5	192	1	15×15	8
8	MBS6_Conv	3×3	320	2	7×7	2
9	Conv	1×1	1 280	1	7×7	1
10	Pooling		1 280	1	1×1	1
11	Fully Connected	1 280×3	3	1	1×1	1

函数的降噪效果进行对比实验^[24]。图5给出了小波阶数为 N ,小波基为db,sym和coif时,脉搏波SNR与RMSE对比结果。表2给出了不同小波基与不同阶数的评估指标SNR和RMSE值的对比数据。分析可知,sym9小波SNR=41.444 7最大, RMSE=5.084 33最小。本文采用sym9小波作为去噪小波基。这是因为,与db小波基相比,sym小波具有更好的对称性与正则性,可以有效地避免脉搏波去噪过程产生的相位畸变,在一定程度上能够减少信号重构时相位失真。与Coif小波基相比,sym小波消失距阶数更小,正则性更大,在去噪过程中,获取数据具有更好的连续可微性,有助于后续提取更有效的脉搏波特征^[25]。

图6显示了原始脉搏波经过小波降噪与去除基线漂移后的图像。分析可知,经过降噪和基线漂移去除后,原始脉搏波的基线漂移和均值均有所降低,其中基线漂移后的波形幅度降低了约20%。同时,脉搏波减少了低频噪声和极端噪点,波形趋于稳定,具有较好的周期性和可区分性。

图7比较了3种常用的基线漂移去除方法评估指标。分析可知,针对高血压靶器官损伤脉诊样本,与小波变化(Wavelet transform, WT)和EMD算法相比,连续投影算法(Successive projections algo-

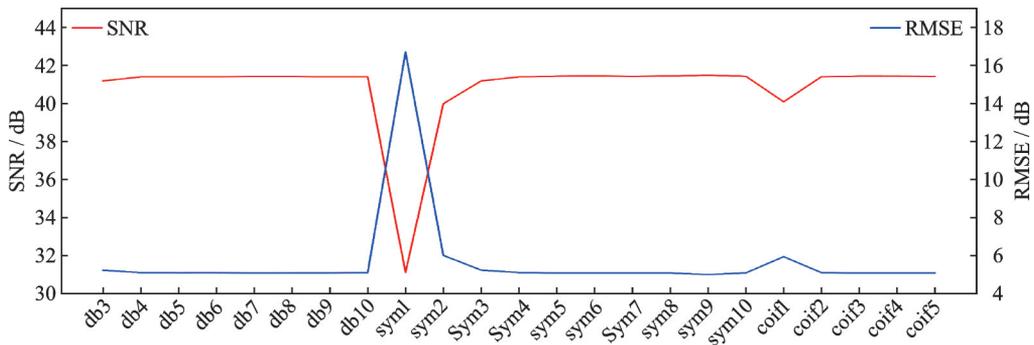


图5 不同小波去噪效果比较
Fig.5 Comparison of different wavelet denoising effects

表 2 不同小波基线漂移去除效果比较

Table 2 Comparison of different wavelet baseline drift correction

N	db		sym		coif	
	SNR	RMSE	SNR	RMSE	SNR	RMSE
1	31.113 3	16.718 66	31.113 3	16.703 20	40.088 6	5.943 42
2	39.988 5	6.005 19	39.988 5	6.012 35	41.408 9	5.105 31
3	41.186 7	5.233 62	41.186 7	5.237 59	41.438 1	5.088 18
4	41.401	5.105 53	41.399 8	5.110 64	41.436 5	5.089 14
5	41.411 7	5.099 62	41.436 6	5.089 03	41.431 3	5.092 16
6	41.409 3	5.100 57	41.443 2	5.085 18		
7	41.421 3	5.093 46	41.431 3	5.092 15		
8	41.421 3	5.096 06	41.442 2	5.085 74		
9	41.405 4	5.096 06	41.444 7	5.084 33		
10	41.402 4	5.104 91	41.431 5	5.092 06		

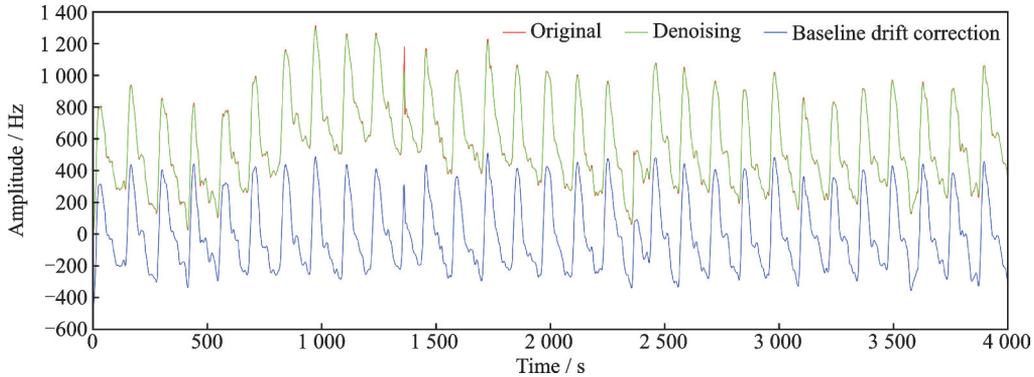


图 6 去除基线漂移和噪声后的数据波形图

Fig.6 Pulse wave after denoising and baseline drift correction

rithm, SPA)算法^[26]保留了基本脉搏波特征,剔除了残余稳态量,具有较高的SNR值和较小的RMSE值,说明SPA算法更适合作为脉搏波基线漂移去除方法。

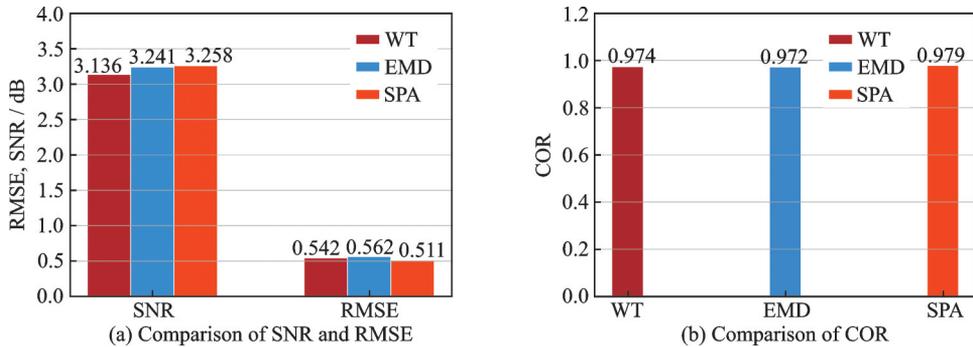


图 7 不同的基线漂移方法对比

Fig.7 Comparison of different baseline drift corrections

2.5 脉诊模型性能分析

2.5.1 特征提取

本文基于 EfficientNet-B1 模型构建了 MFCC 特征提取模型 HTTG-MFCC, 与原始模型相比, 本文使用 HHT 变换提取边际谱替换原模型功率谱, 在 Mel 尺度滤波阶段, 采用高斯滤波器替换原模型三角滤波器。本文实验对比了各种脉搏波特征提取方法, 如图 8 所示。本文采用傅里叶变换对脉搏波进行模对数运算, 获取 8 维 LPCC 特征向量, 输入随机森林模型得到分类结果, 分析可知, 与 LPCC 特征和小波特征相比, MFCC 特征提取模型的 F_1 score 均值分别增加了 24.2%、19.6%, Accuracy 增加 20.7%、17.2%, Sensitivity 增加 20.5%、20.1%。这是由于 LPCC 是一种基于自相关信号的线性预测特征, 近似于脉搏波短时倒谱, 无法完整描述脉搏波周期特征, 特别是在一个周期内的复杂非线性特征。本文对预处理后的原脉搏波进行 8 层分解, 得到每一层能量特征向量, 输入随机森林模型, 得到小波提取特征分类结果。分析可知, 与小波特征提取相比, MFCC 特征提取模型的平均 F_1 score 增加 19.6%, Accuracy 增加 17.2%, Sensitivity 增加 20.1%, 这是由于小波特征的多层分解相当于低通滤波器或高通滤波器, 提取到的不同频率特征属于一种低维线性特征, 无法有效提高脉搏波特征区分性。与传统 MFCC 方法相比, HTTG-MFCC 模型 F_1 score 增加 3.5%, Accuracy 增加 4.3%, AUC 增加 4%。这是由于 HTTG-MFCC 模型采用边际谱代替功率谱提取 MFCC 特征, 可获取更多脉搏波局部信息。与希尔伯特-黄变换 (Hilbert-Huang transform, HHT)-MFCC 模型相比, HTTG-MFCC 模型 F_1 score 增加 1.6%, Accuracy 增加 3.2%, AUC 增加 2%。这是由于采用三角滤波器提取频率固定脉搏波特征, 具有明显共振峰现象, 会增加部分低频特征损失。本文采用高斯滤波器可以有效平滑脉搏波边际谱, 更适合脉搏波的周期性特征。

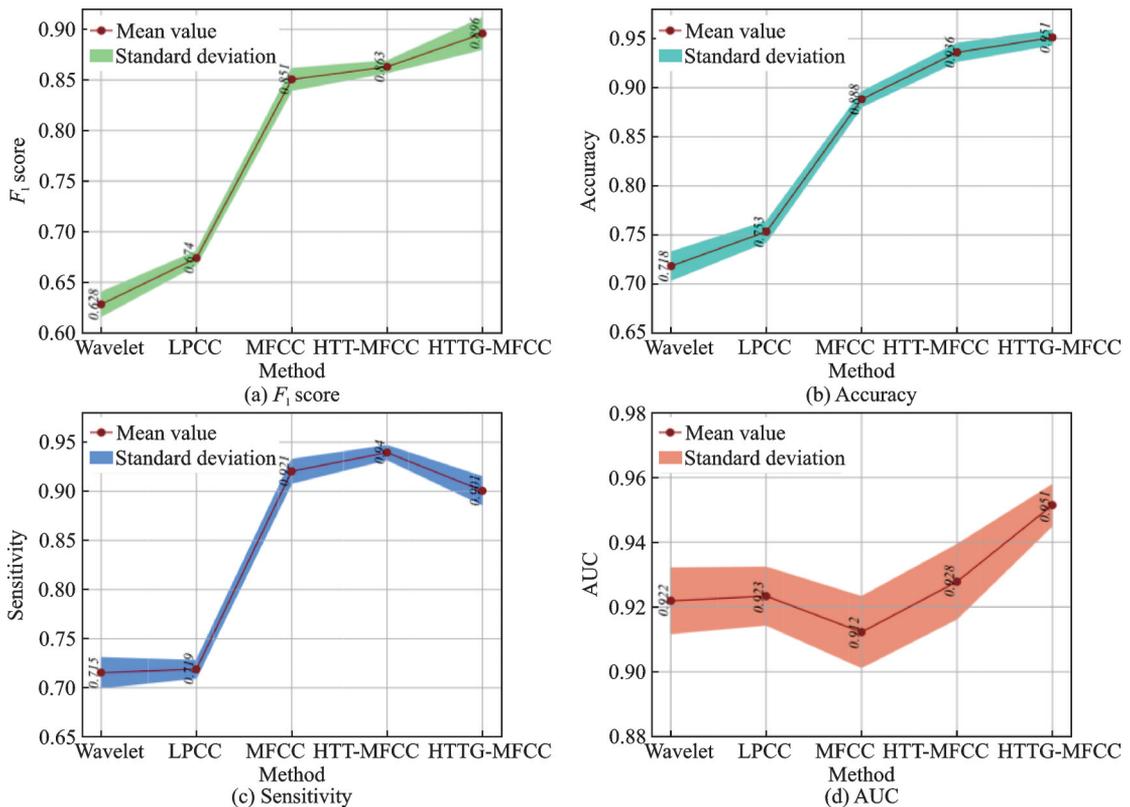


图8 不同特征提取方法比较

Fig.8 Comparison of different MFCC-based feature extraction methods

2.5.2 注意力机制

本文也对 EfficientNet 模型改进,增加了不同注意力机制,并针对高血压靶器官损伤脉诊样本测试分类性能。分别在同一位置加 SK(Selective kernel)、BAM(Bottleneck attention module)、CBAM(Convolutional block attention module)、CA(Coordinate attention)注意力机制模块,并对比测试集评估参数以及 Loss、ROC 与 PR 曲线,如表 3 和图 9 所示。图 9 中,平均精度(Average precision)用 ap 表示,可以看出,本文模型改进的 SimAM 注意力机制分类性能高于其它注意力机制,与次高 CBAM 模型相比, F_1 scores 增加了 5.2%,AUC 提高了 0.8%,这是由于 SimAM 注意力机制使用了权值生成法,不会引入额外参数,提升了模型分类性能。与 SKNet 相比,本文模型 F_1 score 增加 12.3%,Accuracy 增加 13.9%,Precision 增加 11%。这是由于 SKNet 属于卷积核注意力机制,动态生成卷积核,不适合本文分辨率较低的脉搏波 MFCC 特征图像分类。与 Coordinate 注意力模块相比,本文模型 F_1 score 增加 15%,Accuracy 增加 11%,Precision 增加 11%,Sensitivity 增加 17%,AUC 值增加 3.4%。Coordinate 注意力模块考虑了特征空间位置关系,但忽略每个神经元特征重要性。本文模型性能优于 SE 注意力模块,这是由于 SE 仅考虑通道关系,而忽略了位置信息的重要性。本文改进的 SimAM 注意力机制采用最小能量函数,通过对计算每个神经元能量,最小化构成第三维权重,提升模型分类性能。

表 3 注意力机制

Table 3 Performance of different attention mechanism module

Method	F_1 score	Accuracy	Precision	Sensitivity	AUC
SKNET	76.7	88.3	80.6	74.4	95.4
BAM	71.8	83.5	80.02	81.2	87.6
CBAM	84.6	90.8	85.8	84.2	98.1
CA	73.6	83.6	76.7	72.3	95.2
SimAM	89.4	94.2	91	89.5	98.8

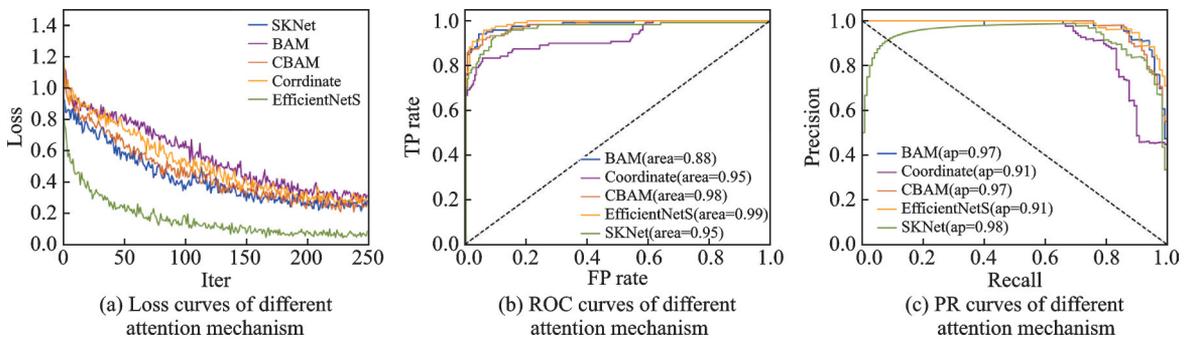


图 9 不同注意力机制 Loss, Roc and PR 比较

Fig.9 Loss, ROC and PR curves of different attention mechanism

2.5.3 各典型脉诊分类模型性能对比

为了验证 EfficientNetS 模型分类效果,本文对比各种典型时序分类模型,如长短时记忆(Long short term memory, LSTM)、MIRNet、BRNet(Back-tracing representative net)、迁移学习模型 InceptionV4、MobileNetV2、EfficientNetV2 等,图 10 为 5 折交叉验证 Loss、ROC 与 PR 曲线。表 4 给出了不同模型针对高血压靶器官损伤脉诊样本的分类评价指标。与 LSTM、BRNet、MIRNet 模型相比,本文 Ef-

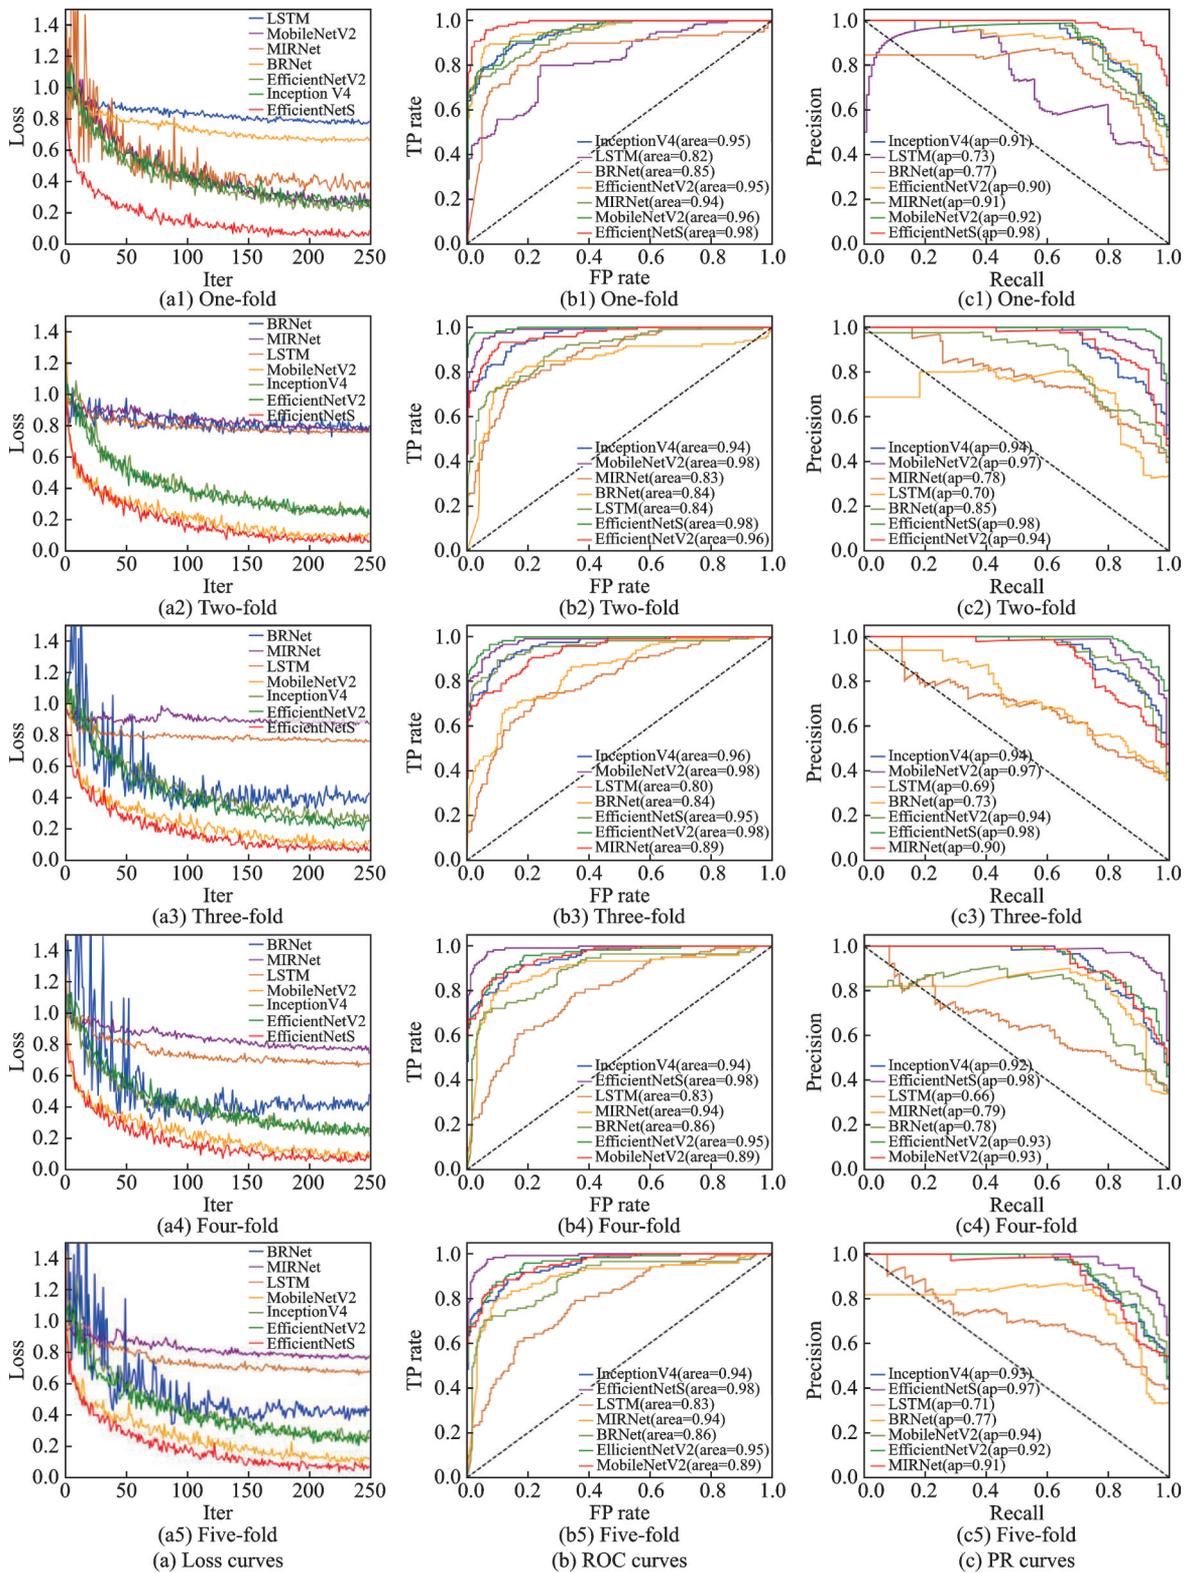


图 10 各模型五折交叉验证 Loss, ROC, PR 曲线

Fig.10 Loss, ROC and PR curves of five-fold cross validation on various models

表4 不同模型分类性能比较

Table 4 Comparison of classification performance of different models

Method	F_1 score	Accuracy	Precision	Sensitivity	AUC
LSTM	60.3±3.24	77.17±5.98	62.3±2.31	60.3±5.62	80.2±3.41
MIRNet	65.8±1.22	84.4±2.31	70.2±3.51	63.7±1.14	95±2.35
Brnet	73.1±2.43	85±4.06	77±1.85	71.1±2.57	96±1.75
EfficientV2	77.3±3.54	74.5±7.34	81.2±8.23	75.8±5.48	82±4.72
Inceptionv4	78.6±2.73	77.3±3.23	85.2±5.15	76.2±4.34	78.2±8.11
MobileNetv2	81.6±3.16	79.5±2.61	91.5±6.12	83.3±5.12	82.1±6.92
EfficientS	89.4±1.45	94.2±3.72	91±2.77	89.5±2.90	98.8±0.52

efficientNetS 模型 F_1 scores 增加 29.1%、23.6%、16.3%；AUC 值增加 18.6%、3.2%、2.8%。这是由于将 MFCC 序列特征转换成图像后，增加模型深度可以更好地提取出不同阶差分系数的全局特征，多维度卷积可以提取 MFCC 特征图像差分系数深层特征。与 InceptionV4 相比，EfficientNetS 模型 F_1 scores 增加 8.8%，AUC 增加 20.6%，这是由于与 InceptionV4 相比，EfficientNetS 在残差结构中增加了 SE 模块，使浅层获得全局感受野，浅层卷积具有更强的全局特征学习能力且网络复杂度不变。

分析图 10 中 Loss 曲线可知，本文 EfficientNetS 模型收敛速度最快，而基于 MFCC 序列特征分类模型 LSTM、MIRNet、BRNet 收敛速度低于 EfficientNetS。这是由于，将量表特征转换成图像特征，可应用更复杂的模型提取关联性较强的深层特征。从图 10 中 PR 曲线和 ROC 曲线可以看出，本文 EfficientNetS 模型具有最好的分类精度和泛化性能。图 11 显示了不同模型交叉验证的 F_1 score, Accuracy, AUC 的箱线图。可以看出 EfficientNetS 模型具有最好的分类精度和泛化性能，虽然 Accuracy 的方差比 MobileNetV2 大 1.11%，但均值相较于 MobileNetV2 增加 14.7%。因此，针对高血压靶器官损伤脉搏波样本，EfficientNetS 具有最好的分类性能。

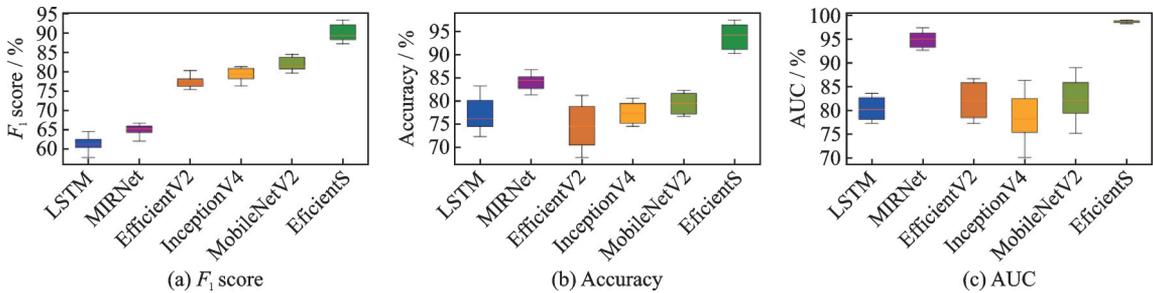


图 11 五折交叉验证性能对比

Fig.11 Performance of various models on five-fold cross validation

3 讨 论

3.1 计算复杂度

图 12 给出了不同模型在训练一个 Epoch 的模型参数量和 FLOPS (Floating point operations per second) 与分类精度 F_1 score 性能关系散点图，分析可知，深度学习网络比机器学习方法具有更多参数。LSTM 模型运行时间最短，这是由于参数量与输入数据的时间片长度呈正相关，而本文数据采用的 MFCC 特征长度较短，故参数量较小。与 EfficientNetV2、InceptionV4 相比，EfficientNetS 模型基于 EfficientNetB1 设计，具有较低的算法复杂度与深度，分类性能更好。而与 MobileNetV2 模型相比，EfficientNetS 牺牲了网络复杂度，提高了模型分类精度。因此，EfficientNetS 在时间复杂度与模型深度上具有较好的折衷性能。

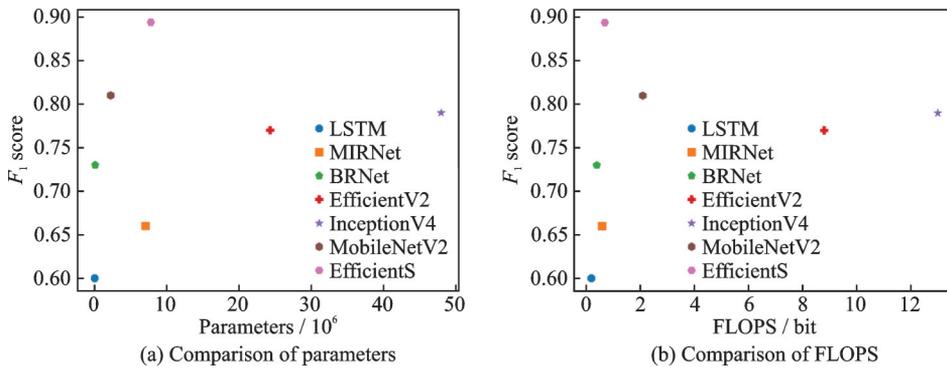


图 12 各模型复杂度比较
Fig.12 Comparison of computational complexity of various models

3.2 特征贡献度

本文采用XGBoost算法^[27]分别针对脉诊样本时域和频域特征贡献率进行分析,图 13、14 给出了脉搏波时频域每一项特征贡献率。贡献率越大,说明其对分类结果的影响越大。本文还增加了 85 名健康人员的问诊样本作为健康对照组,其年龄范围为 43.6 岁 ± 10.8 岁,图 13(b) 给出了本文样本与健康对照组的脉搏波时域特征 p 值与 95% 置信区间。其中,0.95(l) 代表在置信水平为 95% 的情况下,该估计值的下限可能取到的最小值,0.95(h) 代表在置信水平为 95% 的情况下,该估计值的上限可能取到的最大值。

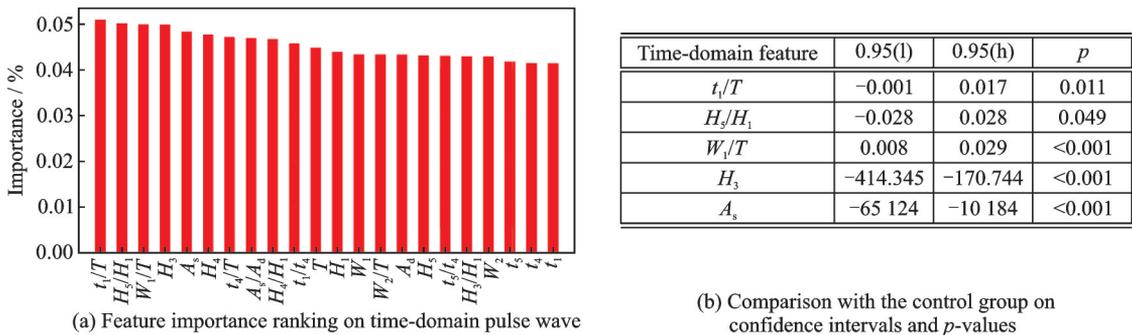


图 13 脉图特征贡献率及其排名前 5 的特征显著性检验
Fig.13 Feature importance ranking and its significance test of top five features on time-domain pulse wave

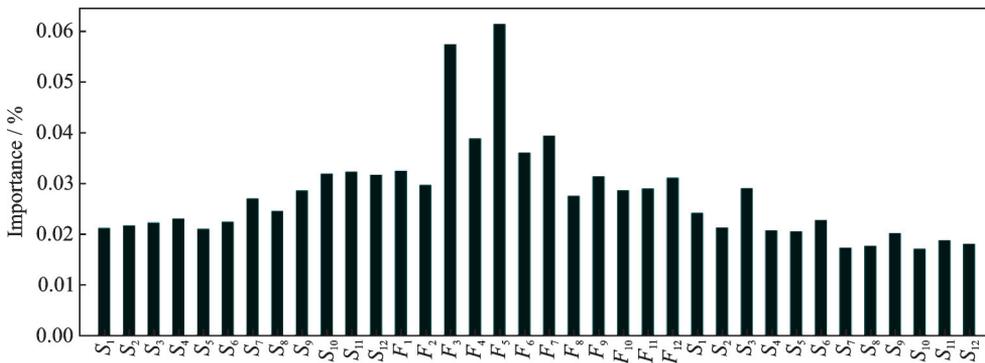


图 14 MFCC 特征贡献率
Fig.14 MFCC feature importance of pulse wave in frequency domain

图 13 中, t_1/T 与心脏射血功能相关^[28], 反映了心室的收缩舒张功能, 贡献率为 5.23%, 为贡献率最高的分类特征, 说明高血压靶器官的损伤程度和位置对心脏功能的影响最大。其次是 H_5/H_1 , 贡献率为 5.08%, 反映了血管的顺应性和主动脉瓣功能情况, 与主动脉的功能性呈正比, 其值越小, 心脏负荷越大。 W_1/T 反应主动脉压力升高的持续时间, 影响该值的主要因素为动脉弹性与外周阻力, 动脉弹性变差或外周阻力增大均会导致该值增大。 H_3 为重搏前波幅度, 通常随着动脉血管硬化或者收缩而升高, A_s 为收缩期总面积, 是动脉腔压力与静脉腔压力之间围成的收缩期总面积, A_d 为舒张期总面积, 是动脉腔压力与静脉腔压力之间围成的舒张期总面积。 A_s 和 A_d 的变化可能表明高血压的存在或风险增加。图 13 给出了脉搏波特征重要性排名和排名前 5 的特征显著性检验结果, 对分类影响程度较高特征排名为: t_1/T (95% C_1 : $-0.001 \sim 0.017$, $p=0.011$)、 H_5/H_1 (95% C_1 : $-0.028 \sim 0.028$, $p=0.45$)、 W_1/T (95% C_1 : $-0.008 \sim 0.029$, $p<0.001$)、 H_3 (95% C_1 : $0.002 \sim 0.013$, $p<0.001$)、 A_s (95% C_1 : $0.036 \sim 0.277$, $p<0.001$)。从上述分析可知, 心脏和动脉血管功能减退是引起高血压患者的心、脑、肾等器官损伤的原因之一, 这与文献[29]结论一致。因此, 减轻高血压靶器官损伤等级需要高血压患者降低动脉压力和血脂, 增加适量运动, 提高心肺功能。

从图 14 可以看出, 一阶 $F_1 \sim F_{12}$ MFCC 系数特征对分类影响较大, $F_1 \sim F_6$ 影响比后半部分更大。这是由于一阶差分系数表示原系数相邻两帧之间关系, 脉搏波中相邻频率能量对分类结果影响较大, 低频段的相邻频率之间的关系对最终分类结果影响更大, 脉搏频率主要分布在低频区域。为了降低靶器官损伤, 应尽量减少相邻频率能量, 当病人的脉搏波频率不稳定, 且前后的振幅变化较大, 则应及时采取预防措施。图 15 给出了脉图特征关注度可视化的热力图, 分析可知, 左部和中部特征颜色较深, 表明脉搏波频域静态系数特征与一阶差分系数特征对 MFCC 分类结果影响较大。这与图 14 中的特征分布特点基本一致, 说明将时域脉搏波特征转化为 MFCC 频域特征使高血压靶器官损伤患者的脉搏波具有更好的区分度。

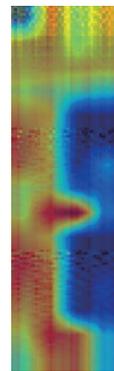


图 15 特征关注度可视化热力图

Fig.15 Visualized heat map of feature attention

4 结束语

本文提出了一种基于频域特征图的高血压靶器官损伤脉搏波分类模型。针对时域脉搏波, 提取频域 MFCC 特征, 并转换为频域特征图。实验结果表明, 与典型模型相比, 本文模型具有较高的分类精度和泛化性能。该模型为中医多诊合参和四诊客观化研究提供一种有效方法。今后将深入研究基于脉搏波频域特征图分类方法, 最大限度保留原始信号波形, 提高脉搏波特征可区分性。并针对更多临床脉搏波样本验证本文模型分类精度和泛化性能。

参考文献:

- [1] PARK H W, LI D, PIAO Y, et al. A hybrid feature selection method to classification and its application in hypertension diagnosis[C]//Proceedings of 8th International Conference on Information Technology in Bio-medical Informatics. [S.l.]: Springer Verlag, 2017: 11-19.
- [2] REN L, WAN S, WEI Y, et al. Towards a non-invasive diagnosis of portal hypertension based on an eulerian CFD model with diffuse boundary conditions[C]//Proceedings of 24th International Conference on Medical Image Computing and Computer Assisted Intervention.[S.l.]: Springer, 2021: 107-116.
- [3] GUPTA S, KAKKAR V, AHMED S, et al. Modeling of on-chip biosensor for the in vivo diagnosis of hypertension in wireless body area networks[J]. IEEE Access, 2021, 9: 95072-95082.

- [4] ALTINTAS E, TAKOH K, OHNO Y, et al. Wearable and low-stress ambulatory blood pressure monitoring technology for hypertension diagnosis[C]//Proceedings of 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society.[S.l.]: IEEE, 2015: 4962-4965.
- [5] 刘杨漾, 冯兴东. 动态缺失数据的聚类分析及在高血压诊断上的应用[EB/OL].[2022-01-11]. <http://10.13860/j.cnki.sljt.20220130-003>.
LIU Yangyang, FENG Xingdong. Cluster analysis of dynamic missing data and its application in hypertension diagnosis[EB/OL].[2022-01-11]. <http://10.13860/j.cnki.sljt.20220130-003>.
- [6] 田晓红. 心电图在高血压疾病诊断中的应用进展[J]. 中国医疗器械信息, 2020, 26(24): 27-29.
TIAN Xiaohong. Application progress of electrocardiogram in diagnosis of hypertension[J]. China Medical Device Information, 2020, 26 (24): 27-29.
- [7] 李世锋, 张芳芳, 王晶晶, 等. 无创心功能检查对妊娠期高血压诊断价值[J]. 中国实用神经疾病杂志, 2019, 22(7): 754-757.
LI Shifeng, ZHANG Fangfang, Wang Jingjing, et al. Diagnostic value of non-invasive cardiac function examination in hypertension complicating pregnancy[J]. Chinese Journal of Practical Neurological Diseases, 2019, 22(7): 754-757.
- [8] 赵唯唯. 脉搏波传导速度(PWV)测定在高血压诊断中的临床评价[J]. 人人健康, 2019(4): 256-257.
ZHAO Weiwei. Clinical evaluation of pulse wave velocity (PWV) in the diagnosis of hypertension[J]. Health for All, 2019(4): 256-257.
- [9] 许文杰, 杨淇善. 基于特征参数LPCC与AMDF的异常声音检测[J]. 长江信息通信, 2021, 34(10): 110-113.
XU Wenjie, YANG Qishan. Abnormal sound detection based on characteristic parameters LPCC and AMDF[J]. Changjiang Information and Communication, 2021, 34 (10): 110-113.
- [10] 刘淼. 基于高斯滤波和小波变换的脉搏信号特征的提取分析[D]. 北京: 北京邮电大学, 2017.
LIU Miao. Pulse signal feature extraction and analysis based on Gaussian filtering and wavelet transform[D]. Beijing: Beijing University of Posts and Telecommunications, 2017.
- [11] ZHANG S, SUN Q. Human pulse recognition based on convolutional neural networks[C]//Proceedings of 2016 IEEE International Symposium on Computer, Consumer and Control.[S.l.]: IEEE, 2016: 366-369.
- [12] LI G, WATANABE K, ANZAI H, et al. Pulse-wave-pattern classification with a convolutional neural network[J]. Scientific Reports, 2019, 9(1): 1-11.
- [13] OUYANG C, GAN Z, ZHEN J, et al. Inter-patient classification with encoded peripheral pulse series and multi-task fusion CNN: Application in type 2 diabetes[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(8): 3130-3140.
- [14] 张选, 胡晓娟. 基于GoogLeNet和ResNet的深度融合神经网络在脉搏波识别中的应用[J]. 计算机系统应用, 2019, 28(10): 15-26.
ZHANG Xuan, HU Xiaojuan. Application of deep fusion neural network based on GoogLeNet and ResNet in pulse wave recognition[J]. Computer System Application, 2019, 28 (10): 15-26.
- [15] CHEN J, HUANG H, HAO W, et al. A machine learning method correlating pulse pressure wave data with pregnancy[J]. International Journal for Numerical Methods in Biomedical Engineering, 2020, 36(1): 10.
- [16] TU Y Q, ZHOU S, PIAO S, et al. Study of traditional Chinese medical diagnostic platform establishment for hyperlipemia [C]//Proceedings of 2011 International Conference on Advanced in Control Engineering and Information Science. [S.l.]: Elsevier, 2011: 1874-1878.
- [17] YANG J, CHEN L, CAI S, et al. Prediction of H-type hypertension based on pulse-taking and inquiry diagnosis[J]. Biomedical Signal Processing and Control, 2022, 75: 10.
- [18] GRANT D, PAPIE B W, PARSONS G, et al. Deep learning classification of cardiomegaly using combined imaging and non-imaging ICU data[C]//Proceedings of 25th Annual Conference on Medical Image Understanding and Analysis.[S.l.]: Springer, 2021: 547-558.
- [19] YAN J, CAI X, ZHU G, et al. A non-invasive blood pressure prediction method based on pulse wave feature fusion[J]. Biomedical Signal Processing and Control, 2022, 74: 10.
- [20] DAS A, JENA M R, BARIK K K. Mel-frequency cepstral coefficient (MFCC)-A novel method for speaker recognition[J]. Digital Technologies, 2014, 1(1): 1-3.

- [21] 欧仁侠, 陈洪斌, 鲍捷. 高斯滤波器特性分析及应用研究[J]. 中国新通信, 2015, 17 (24): 135.
OU Renxia, CHEN Hongbin, BAO Jie. Characteristic analysis and application research of Gaussian filter[J]. China New Communication, 2015, 17 (24): 135.
- [22] TAN M, LE Q. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//Proceedings of 36th International Conference on Machine Learning.[S.l.]: IMLS, 2019: 10691-10700.
- [23] YANG L, ZHANG R, LIL, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks[C]//Proceedings of International Conference on Machine Learning.[S.l.]: PMLR, 2021: 11863-11874.
- [24] CHEN G, XIE W, ZHAO Y. Wavelet-based denoising: A brief review[C]//Proceedings of 2013 Fourth International Conference on Intelligent Control and Information Processing (ICICIP).[S.l.]: IEEE, 2013: 570-574.
- [25] MASOUM A, MERATNIA N, HAVINGA P J M. Coalition formation based compressive sensing in wireless sensor networks[J]. Sensors, 2018, 18(7): 2331.
- [26] 苏志刚, 吕江波, 郝敬堂. 基于平滑先验法去除脉搏波基线漂移[J]. 中国医学物理学杂志, 2018, 35(10): 1197-1202.
SU Zhigang, LU Jiangbo, HAO Jingtang. Removal of pulse wave baseline drift based on smooth prior method[J]. Chinese Journal of Medical Physics, 2018, 35 (10): 1197-1202.
- [27] CHEN T, GUESTRIN C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining.[S.l.]: ACM, 2016: 785-794.
- [28] 燕海霞, 王忆勤, 郭睿, 等. 中医常见脉象脉图特征分析及识别研究[J]. 中华中医药杂志, 2010, 25(12):2295-2298.
YAN Haixia, WANG Yiqin, GUO Rui, et al. Characteristic analysis and recognition of common pulse patterns in traditional Chinese medicine[J]. Chinese Journal of Traditional Chinese Medicine, 2010, 25 (12): 2295-2298.
- [29] 于军, 薛成相, 李洪田, 等. 老年高血压病患者高脉压与靶器官损害[J]. 高血压杂志, 2003(4):319-322.
YU Jun, XUE Chengxiang, LI Hongtian, et al. High pulse pressure and target organ damage in elderly patients with hypertension[J]. Journal of Hypertension, 2003(4): 319-322.

作者简介:



蔡书琛(1997-),男,硕士研究生,研究方向:人工智能、机器学习在医学领域应用等,E-mail:caiscl997@163.com。



杨晶东(1973-),通信作者,男,博士,副教授,研究方向:人工智能、机器学习与大数据分析、机器视觉等,E-mail:eerfriend@yeah.net。



翁雲浩(1999-),男,硕士研究生,研究方向:人工智能、机器学习在医学领域应用等。



齐晨浩(2002-),男,硕士研究生,研究方向:人工智能、机器学习在医学领域应用等。



尧明慧(1998-),女,硕士研究生,研究方向:中医脉诊客观化研究。



燕海霞(1979-),女,医学博士,副教授,研究方向:中医脉诊客观化、标准化研究。

(编辑:陈琚)