

## 结合多模态融合方式的脉搏波房颤识别

张瑞芳<sup>1</sup>, 梁永波<sup>1,2,3</sup>, 崔谋<sup>1</sup>, 陈真诚<sup>1,2,3</sup>

1. 桂林电子科技大学生命与环境科学学院, 广西 桂林 541004; 2. 广西高校生物医学传感及智能仪器重点实验室, 广西 桂林 541004; 3. 广西人体生理信息无创检测工程技术研究中心, 广西 桂林 541004

**【摘要】**针对心房颤动疾病诊断检测复杂,病理检查有创等问题,构建基于脉搏波与深度学习的心房颤动分类预测模型,实现对心房颤动疾病的准确预测。首先,通过脉搏波设备采集数据,与MIMIC-III数据库数据共同构建PPG-AF数据集;其次,基于Pytorch深度学习框架构建用于房颤分类的ResNet-CBAM-IDCNN双通道卷积神经网络;最后,将数据集按照8:1:1的比例划分为训练集,验证集和测试集,将脉搏波和其对应的格拉姆角场图作为输入,通过对网络结构和超参数的优化,在测试集中分类的F1分数达到了97.30%,准确度达到98.12%。本研究基于脉搏波信号与双通道卷积神经网络模型,能够实现对心房颤动疾病的准确诊断,有望为临床医师制定最佳治疗决策提供重要依据。

**【关键词】**心房颤动;深度学习;脉搏波;Resnet-CBAM;格拉姆角场

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2023)10-1260-10

## Multimodal fusion approach to detect atrial fibrillation using PPG

ZHANG Ruifang<sup>1</sup>, LIANG Yongbo<sup>1,2,3</sup>, CUI Mou<sup>1</sup>, CHEN Zhencheng<sup>1,2,3</sup>

1. School of Life and Environmental Sciences, GuiLin University of Electronic Technology, GuiLin 541004, China; 2. Guangxi Colleges and Universities Key Laboratory of Biomedical Sensors and Intelligent Instruments, Guilin 541004, China; 3. Guangxi Engineering Technology Research Center of Human Physiological Information Noninvasive Detection, Guilin 541004, China

**Abstract:** To address the problems in diagnosis and detection of atrial fibrillation (AF) and invasive pathological examination, a model for AF classification based on pulse waves and deep learning is constructed to realize the accurate prediction of AF. The data collected from the photoplethysmography (PPG) acquisition device and the MIMIC-III database data are used to establish PPG-AF dataset, and a ResNet-CBAM-IDCNN dual-channel convolutional neural network for AF classification is constructed based on the Pytorch deep learning framework. The established dataset is divided into a training set, a validation set and a test set in a ratio of 8:1:1. The PPG and its corresponding Gramian angular field map are taken as input. After the optimization of network structure and hyperparameters, the proposed model obtains a F1 score of 97.30% in the test set, and has an accuracy of 98.12% for AF classification. The multimodal fusion approach based on PPG and dual-channel convolutional neural network can achieve the accurate diagnosis of AF, which is expected to provide an important basis for decision-making in clinic.

**Keywords:** atrial fibrillation; deep learning; pulse wave; Resnet-CBAM; Gramian angular field

### 前言

**【收稿日期】**2023-05-23

**【基金项目】**国家自然科学基金(61627807, 62101148); 广西自然科学基金(2020GXNSFBA297156); 广西创新驱动发展专项(Guik AA19254003)

**【作者简介】**张瑞芳, 硕士研究生, 研究方向: 生物医学电子与仪器, E-mail: zhang15138277223@163.com

**【通信作者】**陈真诚, 教授, 博士生导师, 研究方向: 生物传感与智能仪器, E-mail: chenzhcheng@163.com

心房颤动是一种持续性心律失常疾病<sup>[1]</sup>, 发病率随人口老龄化而增加, 75岁以上人群房颤的发生率可达10%<sup>[2]</sup>。房颤时心跳快而不规则, 心房失去有效的收缩功能, 若不治疗, 可导致头晕、黑蒙、晕厥, 严重时可能致死, 也是卒中的主要原因之一<sup>[3]</sup>。光电容积脉搏描记法(Photoplethysmography, PPG)是一种低成本、非侵入性连续监测心率的方法, 可以反映血液容量的变化<sup>[4]</sup>。PPG已成为监测心率的重要工具, 可在多种可穿戴设备中应用。PPG可以得到多个生理参数, 包括血流量、血氧、呼吸频率等<sup>[5]</sup>, 因此在人体无创检测领域很有价值。虽然大多数房颤检测依

赖于心电图(ECG)<sup>[6-8]</sup>,但是相比之下,PPG方法采集信息容易,方便携带,更适合长期监测<sup>[9]</sup>。且脉搏波和ECG有很强的相关性,Zhu等<sup>[10]</sup>通过PPG导出了ECG波形。过去使用PPG检测房颤主要是通过提取脉搏波的特征,然后使用机器学习的方式进行分类<sup>[11-13]</sup>。然而,阵发性心房颤动由于其特异性,很难根据ECG信号进行检测,许多使用脉搏波对心房颤动进行分类的方法需要对信号进行滤波和去噪等处理,这可能会过滤掉有用的信息。

针对上述问题,本文通过使用深度学习的方法构建了基于多模态融合的双通道卷积神经网络,将脉搏波信号转换为格拉姆角场(Gramian Angular

Field, GAF)二维图片和脉搏波信号段同时作为输入从而实现房颤分类。本文所提出的模型称为ResNet-CBAM-1DCNN。信号滤波时可能会导致有用的信息丢失,将信号转换为图片可以有效避免这种情况<sup>[14-15]</sup>。最后,使用准确率,特异性,召回率,F1分数,AUC值对模型进行全面评估。

1 材料与方法

通过将多种模态的脉搏波数据融合在一起,能获得比单一模态更多更有效的生理信息<sup>[16-17]</sup>。多模态融合方式房颤分类流程图如图1所示,该方法主要由数据采集,预处理,特征提取和分类4个部分组成。




图1 多模态融合方式房颤分类流程图  
Figure 1 Flowchart of atrial fibrillation classification by multimodal fusion approach

1.1 数据集

本文的数据主要来自于美国麻省理工学院MIMIC-III公开数据库和笔者采集的数据。MIMIC-III公开数据库涵盖了30 000名重症加强护理病房患者的数据,包含了67 830条信号集。同时设计一套脉搏波信号采集设备,脉搏波传感器MAX30102采集人体的指端脉搏波数据,通过IIC协议传入STM32F103中,通过串口发送到上位机,经过处理后实时显示PPG的波形并保存为txt文件。通过设计实验,使用

该脉搏波采集设备收集了20名25~29岁的健康志愿者脉搏波数据作为本文的补充数据集。使用HUAWEI WATCH 3 Pro手表诊断志愿者是否有房颤,这款手表支持ECG分析(粤械注准20202071705),可实现房颤的实时诊断。将MIMIC-III公开数据集和笔者采集的20名志愿者数据组合到一起作为本文研究用到的数据集(PPG-AF)。图2为脉搏波采集过程图。




图2 脉搏波采集过程图  
Figure 2 Diagram of PPG acquisition process

本研究中脉搏波检测房颤的算法模型是基于PPG-AF数据集建立的,将数据集中的数据切割为10 s的信号段并委托桂林医学院心脏病科室几位经验丰富的临床医生及相关研究人员,根据患者的同步ECG信号来判断患者是否有房颤,对脉搏波进行标注,最终获得了6 937条带有数据标签的10 s脉搏波信号段,按照8:1:1的比例分为训练集,验证集和测试集。

1.2 实验数据预处理

由于脉搏波属于时序信号,滤波会造成时序信息的丢失。脉搏波信号转化为图像数据后就可以充分利用卷积神经网络(Convolutional Neural Networks, CNN)在图像分类识别上的优势,进行建模,提高房颤分类的准确度。GAF具体转换过程如图3所示。




图3 格拉姆角场编码图的示意图  
Figure 3 Schematic diagram of Gramian angular field encoding

根据编码过程中采用的三角函数的不同,GAF可以将时间序列转化成格拉姆角差场(Gramian Angular Difference Field, GADF)和格拉姆角和场(Gramian Angular Summation Field, GASF)2种特征图像,GASF矩阵计算通过余弦函数作角度差,GADF通过正弦函数做角度差,二者矩阵的计算式分别为:

$$\text{GASF} = \begin{pmatrix} \cos(\varphi_1 + \varphi_1) & \cdots & \cos(\varphi_1 + \varphi_n) \\ \vdots & & \vdots \\ \cos(\varphi_n + \varphi_1) & \cdots & \cos(\varphi_n + \varphi_n) \end{pmatrix} \quad (1)$$

$$\text{GADF} = \begin{pmatrix} \sin(\varphi_1 + \varphi_1) & \cdots & \sin(\varphi_1 + \varphi_n) \\ \vdots & & \vdots \\ \sin(\varphi_n + \varphi_1) & \cdots & \sin(\varphi_n + \varphi_n) \end{pmatrix} \quad (2)$$

通过GASF矩阵可知,原序列的时间相关性通过矩阵的主对角线得到了很好的保留<sup>[17]</sup>。图4为不同编号的被试对应的GASF图像。

1.3 ResNet-CBAM结构

2015年,He等<sup>[18]</sup>提出了残差网络ResNet,通过添加残差连接,加深网络的同时保证了图像的分类性能。卷积注意力模块(Convolutional Block Attention Module, CBAM)是由通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial attention module, SAM)组成的一种综合注意力机制模块,CBAM结构如图5所示<sup>[19]</sup>。为了提高训练效率,关注通道和空间信息,本研究在残差块中引入了CBAM,通过注意力机制提高表征能力,关注重要特征并抑制不重要的信息。




图4 不同编号被试对应的格拉姆角场编码示意图  
Figure 4 Schematic diagram of Gramian angular field encoding in different subjects

CAM在通道维度上关注特征信息,SAM在空间维度上关注特征信息。本文以ResNet34网络结构为

基础,在残差块中加入CBAM,图6为改进后的残差网络结构图。






图5 卷积注意力机制模块结构

Figure 5 Convolutional block attention module




图 6 ResNet-CBAM 网络结构

Figure 6 ResNet-CBAM network structure

## 1.4 双通道卷积神经网络

将多种模态的数据融合在一起,能弥补不同模态数据的异质性差异,获得比单一模态数据更多且更有效的生理信息<sup>[20]</sup>。本研究通过构建多模态双通道卷积神经网络,将原始时间序列脉搏波信号和转换后的GAF图作为输入,实现多模态脉搏波数据的提取与融合,从而达到房颤的自动识别。多模态融合算法模型结构如图7所示。

基于多模态的双通道卷积神经网络实现了一维信号与二维图片的特征提取与融合,其中CNN用于提取原始脉搏波时间序列信号特征,将卷积层,批处理归一化层和ReLU层可视化地组合成一个卷积单元,使用了3个连续的卷积和池化操作实现一维脉搏波信号的特征提取,该通道模型参数信息如表1所示。

通道 2 为 ResNet-CBAM 网络,如图 8 所示,主要




图 7 多模态融合模型结构

Figure 7 Structure of multimodal fusion model

表 1 卷积神经网络模型的参数设置

Table 1 Parameter settings of convolutional neural network model

网络层	卷积核/步长	参数量	输出形状	填充	训练参数
Conv1	3×1/2×1	10	624×1@10	Same	Epoch=100
Pool1	3×1/2×1	10	311×1@10	Valid	Dropout=0.25
Conv2	3×1/2×1	20	155×1@20	Same	Optimizer=Adam
Pool2	3×1/2×1	20	77×1@20	Valid	Learning rate=0.001
Conv3	1×1/2×1	40	39×x1@40	Same	Batch size=64
Flatten	-	-	1 560	-	

用于 GAF 图中的二维特征,ResNet-CBAM 网络由 3 个包含 64 个卷积核,4 个包含 128 个卷积核,6 个包含 256 个卷积核,3 个包含 512 个卷积核的残差块和两层全连接层,将通道 1 提取的 30 维特征和通道 2 提取的 100 维特征拼合连接后,得到 130 维的特征,再通过两个全连接层,最终实现基于脉搏波的房颤识别。

1.5 评价指标

在房颤检测过程中,利用混淆矩阵可获得相关指标,包括准确率 (Accuracy, Acc)、精确率 (Precision, Pre)、召回率 (Recall, Rec)、F1 分数、受试者操作特征 (Receiver Operating Characteristic, ROC) 曲线、曲线下面积 (Area Under Curve, AUC),公式如下所示:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{FP} + \text{TN}} \tag{3}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{4}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{5}$$

$$\text{F1-Score} = \frac{2\text{TP}}{2\text{TP} + \text{FN} + \text{FP}} \tag{6}$$

其中,TP:将无房颤样本预测为无房颤的个数;FN:将

无房颤样本预测为房颤的个数;FP:将房颤样本预测为无房颤的个数;TN:将房颤样本预测为房颤的个数。

ROC 曲线用于评估不同阈值情况下分类器性能,是度量分类中的非均衡性工具<sup>[21]</sup>。AUC 是指由 ROC 曲线下方的坐标轴所围成的面积大小,在评价模型性能时,AUC 越接近 1,模型的分类效果越好。

本研究主要基于 PyTorch 深度学习框架进行搭建,其中硬件环境 CPU 为 Intel(R)Xeon(R)CPUE5-2690v4@2.60GHz, GPU 为 NVIDIA-SMI TITAN Xp 显卡,Python 版本为 3.7.12, Torch 版本为 1.5.1。

2 实验结果

随着网络在深度学习模型中不断深化,模型在训练过程中不可避免地会出现过拟合现象,数据增强可减少过拟合,将 GAF 图变换成像素为 300×300 的图片,以 0.5 的概率进行水平翻转,并对数据进行归一化处理。

2.1 不同输入对模型的影响

脉搏波信号作为单变量时间序列,在某种程度上无法解释数据的共性和潜在状态,而将其转化为




图8 通道2:ResNet-CBAM网络结构  
Figure 8 ResNet-CBAM network structure of channel 2

图片后就包含了更丰富的信息。为验证不同类型的图片对模型分类效果的影响,首先将脉搏波数据进行数据转换,通过连续小波变换的方法将脉搏波信号转换为时频(Timefrequency, TF)图,经格拉姆矩阵将脉搏波信号转换为GAF图,变换后的信号如图9所示。

将时频图和GAF图分别输入到ResNet34网络中训练,验证和测试,结果如表2所示。GAF图作为输入时,分类的准确率达到93.90%,与时频图作为输入相比分类准确率提高了3.64%,并且精准率,召回率和F1分数均有提高,分类效果更好。与时频图相比,GAF图既能保留信号的完整信息,也保持着信号对时间的依赖性,在房颤分类效果上更胜一筹。

2.2 不同注意力机制对模型的影响

通过上述实验结果可以看出,即使将GAF图作为输入,使用ResNet34网络训练房颤分类模型,其在测试集上的分类效果仅为93.90%,效果并不理想,若将其应用到临床的心房颤动早期识别当中,会出现误诊漏诊的情况。

为了强化房颤识别模型提取特征的能力,提高对房颤数据的分类识别效果,本实验分别在ResNet34网络的残差块中加了SE(Squeeze-and-Excitation)注意力机制、ECA(Efficient Channel Attention)注意力机制和CBAM注意力机制3种不同的注意力机制模块,构建了ResNet-SE、ResNet-ECA、ResNet-CBAM 3种模型。GAF图作为输入,经过对模型的调试,结果如表3所示。

从上述结果可以看出,加入注意机制后,所有模型都得到了不同程度的改进。但是,与CBAM注意机制相比,SE注意力机制和ECA注意力机制的改进效果要稍弱一些。SE注意力机制与ECA注意力机制仅关注通道注意,而CBAM注意力机制则将通道与空间结合起来,引入空间注意与通道注意两个维度,形成通道-空间顺序注意力结构。通过将注意力分配到二个维度上,增强了注意力机制对模型性能的影响。

2.3 双通道模型的性能比较

将时频图和脉搏波信号以及GAF图和脉搏波信号段分别输入到双通道卷积神经网络当中训练,经过模型的验证和测试,根据训练结果,得到的混淆矩阵如图10所示,使用混淆矩阵来说明预测标签和实际标签之间的不一致性。

通过对比混淆矩阵可以得出,以时频图和GAF图作为输入的2DCNN-2DCNN模型分类性能较差,其正样本正确识别数(TP)达到了0.13,证明该模型易将房颤信号诊断为正常的,容易出现漏诊的情况,这种情况在医学检测中是很危险的。根据混淆矩阵分别计算各个实验的准确率,精确率,召回率和F1分数等评价指标,结果如表4所示。

将脉搏波信号段和GAF图片同时输入到ResNet-CBAM-1DCNN双通道卷积神经网络当中,准确率达到98.12%。通过对比以GAF作为输入的ResNet-CBAM模型和以GAF和脉搏波信号作为输入的ResNet-CBAM-1DCNN模型分类指标,ResNet-CBAM-1DCNN模型因加入了脉搏波信号通道,分类准确度提高了2.52%,F1分数提高了3.49%,说明了多模态融合的方式对房颤的分类是有促进作用的。






图9 不同类型的ECG信号和脉搏波信号时频光谱图和GAF图

Figure 9 Time-frequency maps and Gramian angular field maps of different types of ECG and PPG

表 2 不同输入对模型分类效果的实验对比

Table 2 Experimental comparison of the effects of different inputs on model classification

输入	准确率/%	精确率/%	召回率/%	F1 分数/%	AUC
时频图	90.26	89.19	85.56	87.33	0.927
GAF 图	93.90	91.12	92.91	92.01	0.965

3 讨论

为验证使用不同深度学习网络模型对房颤数据集的分类结果影响,将脉搏波信号生成的GAF图作为输入,分别使用VGGNet, GoogLeNet, ResNet, ResNet-CBAM以及ResNet-CBAM-1DCNN算法模型进行训练,最终实验结果如表5所示。

表 3 不同注意力机制对模型分类的影响

Table 3 Effects of different attention mechanisms on model classification

模型	准确率/%	精确率/%	召回率/%	F1 分数/%	AUC
ResNet	93.90	91.12	92.91	92.01	0.965
ResNet-SE	94.60	89.83	95.50	92.58	0.964
ResNet-ECA	94.53	91.56	92.79	92.17	0.968
ResNet-CBAM	95.60	92.17	95.50	93.81	0.989

与VGGNet、GoogLeNet相比,ResNet网络的准确率最高,准确率达到93.90%,在ResNet的残差块中加入CBAM注意力机制的ResNet-CBAM模型,分类准确率达到95.63%,相比较ResNet模型的准确率

提升了1.73%,双通道卷积神经网络ResNet-CBAM-1DCNN算法模型的准确率达为98.12%,相比ResNet-CBAM模型的准确率提升了2.49%,达到了最好的分类准确度。ResNet-CBAM-1DCNN模型的




图 10 不同分类模型生成的混淆矩阵

Figure 10 Confusion matrix generated by different classification models

表 4 不同输入对双通道模型的影响						
Table 4 Effects of different inputs on the dual-channel model						
输入	模型	准确率/%	精确率/%	召回率/%	F1 分数/%	AUC
TF+GAF	2DCNN-2DCNN	90.19	87.33	86.94	87.13	0.949
TF+PPG	ResNet-1DCNN	91.49	87.24	92.00	89.56	0.958
	ResNet-CBAM-1DCNN	95.53	94.53	94.18	94.35	0.967
GAF	ResNet-CBAM	95.60	92.17	95.50	93.81	0.989
GAF+PPG	ResNet-1DCNN	94.84	90.21	95.50	92.78	0.985
	ResNet-CBAM-1DCNN	98.12	97.30	97.30	97.30	0.991

表 5 不同模型的分类效果对比					
Table 5 Comparison of classification performances among different models					
模型	准确率/%	精确率/%	召回率/%	F1 分数/%	AUC
GoogLeNet	92.50	85.37	94.59	89.74	0.960
VGGNet	93.44	87.50	94.59	90.91	0.976
ResNet	93.90	91.12	92.91	92.01	0.965
ResNet-CBAM	95.63	92.17	95.50	93.81	0.989
Resnet-CBAM-1DCNN	98.12	97.30	97.30	97.30	0.991

精确率、召回率、F1 分数和 AUC 值都大于其他模型，可见 ResNet-CBAM-1DCNN 算法模型在房颤自动检测的任务中的性能优于各个子结构模型。这说明，本文模型 ResNet-CBAM-1DCNN 可以将 CNN 结构、ResNet 结构和 CBAM 结构的优点有效地融合在一起，它不但可以捕捉到 PPG 数据中的时序性特征和

各医学变量之间的相关性特征，而且还可以获得各医学变量之间的差异性特征，每个结构均在房颤检测任务中发挥了重要作用。

图 11 显示了 5 种心房颤动脉搏波识别算法模型的 ROC 曲线图，ResNet-CBAM-1DCNN-GAF 模型的 ROC 曲线最靠近 ROC 空间的左上角，综合各项评估






图11 不同模型对应的ROC曲线和AUC值

Figure 11 ROC curves and AUC values  
corresponding to different models

指标分析后得出,在5种深度学习算法中,以脉搏波信号和GAF图作为输入的ResNet-CBAM-1DCNN算法模型对房颤的识别效果要优于其他算法。

将本文提出的ResNet-CBAM-1DCNN模型与其他相关的研究工作进行对比。研究发现,基于ECG的研究中所使用的房颤检测模型和数据各不相同。Kashiwa等<sup>[22]</sup>开发了一个腕带式PPG监测器,使用两个统计值进行房颤检测,实现了81.0%的敏感性和96.4%的特异性。Väliäho等<sup>[23]</sup>利用脉搏间隔方差、振幅和基于自相关的形态学特征建立了一个多变量预测模型,敏感性为95.1%,特异性为93.7%,AUC为0.982。Mendez等<sup>[24]</sup>使用基于HRV图像矩阵的CNN和GA进行特征选择,取得了87.2%的分类准确率。

在基于PPG的房颤检测研究中,Aschbacher等<sup>[25]</sup>比较了传统的心率变异性指数、仅使用心率数据的LSTM神经网络和使用原始PPG数据的DNN。DNN模型取得了最佳性能,其敏感性、特异性和AUC值分别为98.5%、88%和0.983。Sun等<sup>[13]</sup>使用DCNN对面部视频记录中的PPG信号进行分割,在第30 s和10 s时检测带有NSR的房颤和其他异常情况的准确率分别达到90.0%和97.1%。Tabei等<sup>[26]</sup>使用Boosting和Bagging函数对每个受试者进行个性化的房颤检测,个性化房颤检测的准确率为96.08%。Chang等<sup>[27]</sup>使用Garmin智能手表进行24 h流动ECG监测和PPG记录,检测房颤的敏感性为97.3%,特异性为88.6%,阳性预测值为91.6%,AUC为0.90。

## 4 结论

本文模型将卷积神经网络与注意力机制模块相结合,更好地提取出脉搏波的深层信息,检测效率更高。GAF图既能保留有脉搏波信号的完整信息和对时间的依赖性。将脉搏波信号段和GAF图同时作为双通道卷积神经网络的输入,最终达到了98.12%的

准确率,实验结果表明该方法具有较高的分类精度,可作为临床辅助诊断的重要工具。然而心律失常的种类有很多,准确可靠的监测所有类型的心律失常需要更多的数据支持。下一步的工作中,可基于目前的研究,需要采集更多的数据,将分类模型应用到更多种类型的心律失常的分类。

## 【参考文献】

- [1] Williams BA, Honushefsky AM, Berger PB. Temporal trends in the incidence, prevalence, and survival of patients with atrial fibrillation from 2004 to 2016[J]. Am J Cardiol, 2017, 120(11): 1961-1965.
- [2] Lee SR, Choi EK, Han KD, et al. Trends in the incidence and prevalence of atrial fibrillation and estimated thromboembolic risk using the CHA2DS2-VASc score in the entire Korean population[J]. Int J Cardiol, 2017, 236: 226-231.
- [3] Steger C, Pratter A, Martinekregel M, et al. Stroke patients with atrial fibrillation have a worse prognosis than patients without: data from the austrian stroke registry[J]. Eur Heart J, 2004, 25(19): 1734-1740.
- [4] 赵远东. 基于光电容积脉搏波描记法的心率腕表研制[D]. 沈阳: 东北大学, 2017.
- [5] Zhao YD. Development of a heart rate wristwatch based on photoelectric volumetric pulse wave tracing method[D]. Shenyang: Northeastern University, 2017.
- [6] 陈斌. 光电容积脉搏波描记法原理、应用及其电路设计[J]. 电子技术与软件工程, 2014(18): 132-133.
- [7] Chen B. Principle, application and circuit design of optoelectronic volumetric pulse wave tracing method[J]. Electronic Technology and Software Engineering, 2014(18): 132-133.
- [8] 李芳, 戴淑婷, 韩敏, 等. 利用心电散点图快速识别心房颤动和心房扑动[J]. 临床医药实践, 2019, 28(8): 598-600.
- [9] Li F, Dai ST, Han M, et al. Rapid identification of atrial fibrillation and atrial flutter using electrocardiographic scattergram[J]. Clinical Medicine Practice, 2019, 28(8): 598-600.
- [10] 王凯, 杨枢, 李超. 一种基于ECG的多层共轭对称Hadamard特征变换的房颤异常信号分类方法[J]. 中国医学物理学杂志, 2019, 36(9): 1068-1073.
- [11] Wang K, Yang S, Li C. ECG-based multi-level conjugate symmetric Hadamard feature transformation for classification of abnormal signals of atrial fibrillation[J]. Chinese Journal of Medical Physics, 2019, 36(9): 1068-1073.
- [12] 秦默然, 李宙童, 翟月英, 等. 基于空洞卷积神经网络的心律失常分类算法[J]. 中国医学物理学杂志, 2023, 40(1): 87-94.
- [13] Qin MR, Li ZT, Zhai YY, et al. Arrhythmia classification algorithm based on cavity convolutional neural network[J]. Chinese Journal of Medical Physics, 2023, 40(1): 87-94.
- [14] Andel J, Ungureanu C, Aarts R, et al. Using photoplethysmography in heart rate monitoring of patients with epilepsy[J]. Epilepsy Behav, 2015, 45: 142-145.
- [15] Zhu Q, Tian X, Wong CW, et al. ECG Reconstruction via PPG: A pilot study[C]//2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), IEEE, 2019.
- [16] Eerikainen LM, Bonomi AG, Schipper F, et al. Detecting atrial fibrillation and atrial flutter in daily life using photoplethysmography data[J]. IEEE J Biomed Health Inform, 2020, 24(6): 1610-1618.
- [17] Kwon S, Hong J, Choi E K, et al. Deep learning approaches to detect atrial fibrillation using photoplethysmographic signals (Preprint)[J]. JMIR Mhealth Uhealth, 2018, 7(6): e12770.
- [18] Sun Y, Yang YY, Wu BJ, et al. Contactless facial video recording with deep learning models for the detection of atrial fibrillation[J]. Sci Rep, 2022, 12(1): 281.
- [19] Xu X, Wei S, Ma C, et al. Atrial fibrillation beat identification using the combination of modified frequency slice wavelet transform and convolutional neural networks[J]. J Healthc Eng, 2018, 2018: 2102918.
- [20] Ren Z, Zhang Q, Gao X, et al. Multi-modality learning for human action recognition[J]. Multimed Tools Appl, 2021, 80(11): 16185-16203.

- [16] Vielzeuf V, Lechervy A, Pateux S, et al. CentralNet: a multilayer approach for multimodal fusion [C]//Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 2018.
- [17] 张占龙,肖睿,武雍烨,等. 换流变压器振动信号多层次特征提取模型研究[J]. 中国电机工程学报, 2021, 41(20): 7093-7104.
- Zhang ZL, Xiao R, Wu YY, et al. Multi-level feature extraction modeling of converter transformer vibration signals[J]. Proceedings of the CSEE, 2021, 41(20): 7093-7104.
- [18] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778.
- [19] Woo S, Park J, Lee JY, et al. CBAM: convolutional block attention module[M]. Cham: Springer International Publishing, 2018.
- [20] 李红利,丁满,张荣华,等. 基于特征融合神经网络的运动想象脑电分类算法[J]. 中国医学物理学杂志, 2022, 39(1): 69-75.
- Li HL, Ding M, Zhang RH, et al. Motor imagery EEG classification algorithm based on feature fusion neural network [J]. Chinese Journal of Medical Physics, 2022, 39(1): 69-75.
- [21] 董慧妍. 基于机器学习的糖尿病性视网膜病变图像分级研究[D]. 北京: 北京邮电大学, 2019.
- Dong HY. Research on image grading of diabetic retinopathy based on machine learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [22] Kashiwa A, Koyama F, Miyamoto K, et al. Performance of an atrial fibrillation detection algorithm using continuous pulse wave monitoring[J]. Ann Noninvasive Electrocardiol, 2019, 24(2): e12615.
- [23] Väliaho ES, Kuoppa P, Lipponen JA, et al. Wrist band photoplethysmography autocorrelation analysis enables detection of atrial fibrillation without pulse detection[J]. Front Physiol, 2021, 12: 654555.
- [24] Mendez MM, Hsu MC, Yuan JT, et al. A heart rate variability-based paroxysmal atrial fibrillation prediction system[J]. Applied Sciences, 2022, 12(5): 2387.
- [25] Aschbacher K, Yilmaz D, Kerem Y, et al. Atrial fibrillation detection from raw photoplethysmography waveforms: a deep learning application[J]. Heart Rhythm O2, 2020, 1(1): 3-9.
- [26] Tabei F, Abohelwa M, Davis D, et al. A novel smartphone-based & personalized atrial fibrillation detection: a preliminary study[C]//2022 IEEE Healthcare Innovations and Point of Care Technologies (HI-POCT). IEEE, 2022: 18-21.
- [27] Chang PC, Wen MS, Chou CC, et al. Atrial fibrillation detection using ambulatory smartwatch photoplethysmography and validation with simultaneous holter recording[J]. Am Heart J, 2022, 247: 55-62.

(编辑:薛泽玲)