

心电形态与节律特征融合的轻量房颤 检测模型及可解释性研究

高 宁^{1,2}, 李玉榕^{1,2*}, 陈 泓^{1,2}, 陈文升^{1,2}, 贾梓豪^{1,2}

(1. 福州大学电气工程与自动化学院, 福建福州 350108; 2. 福建省医疗器械和医药技术重点实验室, 福建福州 350108)

摘 要: 房颤是一种常见的心律失常, 通常与中风、心力衰竭等心血管疾病相关。近年来, 虽然有许多研究者使用深度学习方法在房颤检测上取得了重大进展, 但所提出的方法大都需要大量的计算资源, 并且由于深度学习模型的黑盒效应, 模型的检测结果较难以在临床上推广应用。为此, 本文提出一种基于特征融合的轻量房颤检测模型并对其进行可解释性研究, 模型由 ECG (ElectroCardioGram) 主干网络和 RRI (R-R Interval) 支路组成。ECG 主干网络使用深度可分离卷积以及少量的标准卷积来提取心电信号的深层形态特征, RRI 支路使用多尺度卷积提取 RRI 的深层节律特征, 网络通过融合二者来学习全面鲁棒的特征表示, 实现准确的房颤检测。进一步, 基于 Grad-CAM++ 来可视化不同特征对于分类结果的贡献实现模型的可解释性分析。本文在长期房颤数据库 LTAfDB 进行训练与数据集内部测试, 准确率达到了 97.99%。为了验证模型的泛化性能, 利用 MIT-BIH 心房颤动数据库 AFDB 与中国生理信号挑战赛数据库 CPSC2021 开展跨数据集的外部测试, 分别取得了 95.17% 和 93.81% 的准确率。实验结果表明, 本文提出的方法具有轻量级特性, 稳定性和准确性良好, 同时可解释性深度学习的引入使得本文所提出的方法在房颤的临床诊断中具有更加广阔的应用前景。

关键词: 心电信号; 房颤; 轻量级神经网络; 可视化技术; 特征融合

基金项目: 国家自然科学基金 (No. 62373108)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)02-0503-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240998

Lightweight Atrial Fibrillation Model Based on Feature Fusion of Morphology and Rhythmic and Interpretability Analysis

GAO Ning^{1,2}, LI Yu-rong^{1,2*}, CHEN Hong^{1,2}, CHEN Wen-sheng^{1,2}, JIA Zi-hao^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou, Fujian 350108, China;

2. Fujian Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou, Fujian 350108, China)

Abstract: Atrial fibrillation (AF) is a common arrhythmia often associated with cardiovascular diseases such as stroke and heart failure. Although numerous researchers have made substantial progress in AF detection using deep learning methods in recent years, most of these methods require extensive computational resources. Moreover, the clinical application of these models is challenging due to the black-box nature of deep learning models. Therefore, this paper proposes a lightweight AF detection model based on feature fusion and conducts an interpretability study. The model comprises an ECG (ElectroCardioGram) backbone network and an RRI (R-R Interval) branch. The ECG backbone network uses depth-wise separable convolutions along with a few standard convolutions to extract deep morphological features of the ECG signals, while the RRI branch employs multi-scale convolutions to extract deep rhythm features of the RRI. The network learns robust feature representations by fusing morphological features and rhythm features to detect AF accurately. As to interpretability analysis, Grad-CAM++ is utilized to visualize the contribution of different features to the classification results. In this paper, the training and dataset internal tests are conducted in the LTAfDB and achieved an accuracy of 97.99%. In order to validate the generalization performance of the model, external testing experiments are conducted using the AFDB and the CPSC2021, achieving an accuracy of 95.17% and 93.81%, respectively. Experimental results demonstrate that the pro-

posed method is lightweight, stable, and accurate, and the incorporation of interpretable deep-learning techniques suggests that the proposed method holds significant potential for the clinical diagnosis of AF.

Key words: ElectroCardioGram(ECG); atrial fibrillation; lightweight neural network; visualization technologies; feature fusion

Foundation Item(s): National Natural Science Foundation of China (No. 62373108)

1 引言

心房颤动是最常见的心律失常形式之一^[1],研究表明,随着年龄的增长,房颤的发生率显著增大^[2],房颤患者与正常人相比,中风的风险增大了五倍^[3],同时心力衰竭等心血管疾病发病率也有增加^[4]. 而由于房颤的阵发性使得许多患者在出现严重的并发症之前一直都不知道患有房颤,因此,早期发现房颤对于为患者提供及时的护理和治疗非常重要.

心电图是一种方便快捷且非侵入式的检测方法,能够反映心脏健康状况的重要信息^[5],临床上将12导联的ECG(ElectroCardioGram)作为识别房颤的金标准^[6]. 由于房颤的阵发性,使得基于常规短时12导联ECG准确检测房颤更加具有挑战性. 与连续两周的心电监测相比,每日的12导联心电图快照漏诊了65%的房颤患者^[7]. 近年来,用于持续监测心脏活动的单导联ECG设备不断出现^[8],长时间以及低成本的动态心电信号能够在医院之外被及时记录,使得房颤的漏检可能性大大降低,但同时会产生海量的心电数据,诊断需要耗费医务人员大量的时间. 因此,为了减少房颤漏诊事件的发生以及减轻医务人员的工作量,迫切需要开发一种能够应用于单导联ECG设备的房颤自动检测算法,实现房颤的早期检测,提前干预治疗以减轻患者的医疗负担.

房颤在波形上的特征包含P波缺失与不规则的R-R间期,基于这一特征,研究者们使用不同的算法手工提取特征,特征包含香农熵^[9]、样本熵^[10]、庞加莱图^[11,12]、心率的不规则特征^[13]、形态特征^[14,15]、小波特征^[16]等,基于所提取到的特征,利用支持向量机(Support Vector Machine, SVM)、K近邻算法(K Nearest Neighbor, KNN)、随机森林(Random Forest)等传统机器学习方法进行分类. 然而,由于节律特征中心房信息的缺乏以及形态特征易受噪声干扰的问题,在一定程度上限制了基于机器学习的房颤检测算法的性能. 此外,手工提取特征需要合适并且巧妙的特征工程将原始心电数据转换成特征表示,这是一个耗时耗力的开发过程,限制了技术的先进性.

随着深度学习的发展,越来越多的研究者将其应用到房颤检测中,端到端的方法论避免了繁琐的特征工程和模块化设计,简化了开发的流程. 同时由于深度学习模型自动学习最佳的特征表示,减少了人为干预和错误传播的风险. 一部分研究者使用神经网络模型

对提取到的心电RRI(R-R Interval)数据进行分析. Faust等人^[17]使用残差网络ResNet提取RRI的特征,使得模型能够区分房颤、房扑以及正常窦性心律. 文献[18]将卷积神经网络与循环神经网络相结合实现了房颤与正常窦性心律的二分类模型,模型以RRI作为输入,在两个外部测试集上实验以验证模型的泛化性能. 虽然基于RRI的深度学习方法已经实现了较为准确的房颤检测,但在实际应用中,异位搏动导致的RRI不等通常会使得模型误判,限制了模型的性能.

因此,越来越多的研究者使用神经网络模型对原始心电数据进行特征提取并分类. Fang等人^[19]将单导联的心电图转换为频谱图与庞加莱图的二维表示,使用改进的VGG-Net实现了房颤的准确检测. 文献[20]基于密集网络DenseNet的原始架构做了改进使其适应于一维心电信号的房颤检测任务,在两个数据集上取得了0.831和0.826的F1得分. Fan等人^[21]提出了一种多尺度融合卷积神经网络来捕获单导联心电信号中不同尺度的特征,从而实现房颤的检测,但作者没有进一步开展其他数据集的实验,模型的泛化性能无法验证. Li等人^[22]提出了一个轻量级架构的房颤检测模型,网络通过两条路径与逐层交叉的注意力融合机制实现房颤相关特征的提取. Cai等人^[23]将密集网络DenseNet与挤压激励模块(Squeeze-and-Excitation Block, SE Block)相结合,从而实现房颤的高精度自动关注检测方法. 文献[24]提出了一种基于残差的时间注意力块,利用残差生成注意力权重,从而增强房颤相关的特征,提高模型的房颤检测能力,然而由于追求高精度而设计的复杂模型结构导致计算成本的显著增加,超出了低端芯片的计算要求,无法嵌入现有的临床可穿戴心电设备中. 除此之外,现有的大多数房颤检测模型都是黑盒分类器,缺乏可解释性,虽然这些模型均取得了令人满意的结果,但由于其结果不具有可解释性,限制了其在临床上的推广应用. 因此,建立一个基于可解释深度学习的房颤检测模型至关重要.

因此,本文提出了一种融合心电形态与节律特征的可解释轻量房颤检测模型,不仅适合临床应用,同时,低计算成本使得模型在可穿戴设备上的部署成为可能. 我们提出的模型通过使用DenseNet密集网络架构并在模型中引入深度可分离卷积,解决了在网络结构加深时计算成本显著增加的问题. 进一步,引入RRI

支路使得模型能够提取更加鲁棒的节律特征,提高模型的泛化性能.同时,通过解释输入信号中对分类结果起重大贡献的局部区域,解释了房颤检测模型分类决策的模式,使模型分类结果更加具有说服力.通过在三个公开数据集上的大量实验证明了模型在保持低计算成本的同时表现出强大的房颤检测性能.

2 提出的方法

2.1 网络的总体架构

本文提出了一个基于特征融合的轻量房颤检测模

型,模型结构是基于卷积神经网络(Convolutional Neural Network, CNN)实现的,主要包括 ECG 主干网络与 RRI 支路两个部分,如图 1 所示.其中 ECG 主干网络是由标准卷积与深度可分离卷积构成的轻量 DenseNet^[25],用于心电信号形态特征的提取;RRI 支路由多尺度卷积长短时记忆网络(Long Short Term Memory, LSTM)组成,提取输入 RRI 数据中的节律特征,用于形态特征的补充.将形态特征与节律特征融合之后送入分类器,分类器输出所推理的房颤与非房颤的概率,具体的结构如表 1 所示.

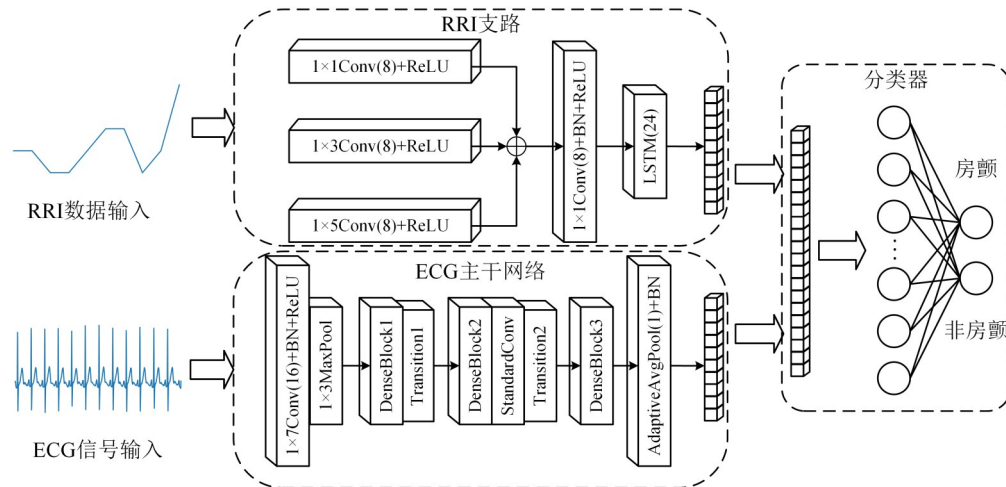


图 1 网络的整体结构

2.2 ECG 主干网络设计

开发一种能够集成到穿戴式心电监护设备上的模型,要求模型有低参数量以及低计算量的特点,因此对于 ECG 主干网络部分,本文采用基于深度可分离卷积的 DenseNet 密集网络结构来对提取心电信号的形态特征.引入 DenseNet 来处理高精细度的心电信号,可以有效地缓解梯度消失,进行特征复用,提高网络中特征的流动性;而深度可分离卷积的引入,在减少模型参数量与计算量的同时,保持了 DenseNet 的泛化性能.

2.2.1 深度可分离卷积

在计算机视觉领域,许多轻量级模型都是基于深度可分离卷积或其变体构建的.深度可分离卷积的计算包含两个阶段:(1)在通道维度上对输入的特征图进行卷积,其中每个通道的特征图只与一个卷积核进行卷积;(2)对第一阶段得到的特征图进行 1×1 逐点卷积得到深度可分离卷积的输出,如图 2 所示.与标准卷积相比,深度可分离卷积的参数量和计算量更少,计算效率更高,深度可分离卷积的参数量与计算量的具体计算如下:

$$P_D = K \times C_I + C_O \times C_I = C_I \times (K + C_O) \quad (1)$$

$$F_D = N_C \times C_I \times (K + C_O) \quad (2)$$

$$N_C = L - K - 1 \quad (3)$$

其中 K 代表卷积核的大小, L 代表输入信号的长度, C_I 与 C_O 分别是输入通道数与输出通道数, N_C 表示对一条信号进行卷积时所需要的乘法运算的次数.




图 2 深度可分离卷积示意图

标准卷积的参数量与计算量的具体计算如式(4)和式(5)所示:

$$P_S = C_I \times K \times C_O \quad (4)$$

$$F_S = N_C \times C_I \times K \times C_O \quad (5)$$

从式(1)~式(5)可以得出,当 $(K \times C_O) > (K + C_O)$ 时,标准卷积的参数量与计算量均大于深度可分离卷积,并且二者的差异随着卷积核尺寸 K 以及输出通道数 N_C 的增加而增加.

在本文中,深度可分离卷积构成了 ECG 主干网络的

表 1 网络的具体结构

	层	输出尺寸	结构
ECG 主干网络	Conv+BN+ReLU	16×640	1×7Conv, S=2, P=3
	MaxPool	16×320	1×3Max pool, S=2, P=1
	Dense Block1	48×20	$\begin{bmatrix} 1 \times 1 \text{Conv} \\ 1 \times 9 \text{Conv}, P=4 \end{bmatrix} \times 4$
	Transition1	24×160	$\begin{bmatrix} 1 \times 1 \text{Conv} \\ 1 \times 2 \text{Avg pool}, S=2, P=2 \end{bmatrix}$
	Dense Block2	56×160	$\begin{bmatrix} 1 \times 1 \text{Conv} \\ 1 \times 7 \text{Conv}, P=3 \end{bmatrix} \times 4$
	Transition2	28×80	$\begin{bmatrix} 1 \times 1 \text{Conv} \\ 1 \times 2 \text{Avg pool}, S=2, P=2 \end{bmatrix}$
	Standard Conv	28×80	$\begin{bmatrix} 1 \times 7 \text{Conv}, P=3 \\ 1 \times 80 \text{Avgpool} \\ 1 \times 1 \text{Conv} \end{bmatrix}$
	Dense Block3	92×80	$\begin{bmatrix} 1 \times 1 \text{Conv} \\ 1 \times 5 \text{Conv}, P=2 \end{bmatrix} \times 8$
	BN+AvgPool	92×1	1×80Avgpool
	Flatten	1×92	
RRI 支路	Conv+ReLU	8×12	1×1Conv, P=1
	Conv+ReLU	8×12	1×3Conv, P=2
	Conv+ReLU	8×12	1×5Conv, P=3
	Concatenation	24×12	
	LSTM	24×12	Hidden Size=24
	Conv+ReLU+BN	8×12	1×1Conv
	Flatten	1×96	
分类器	Concatenation	1×188	
	Fully Connected Layer	1×2	188×2

主体,确保能够以较低的计算成本提取特征.由于心电信号是时间序列信号,不仅通道内的特征相互依赖,不同通道之间的特征也有着密切的关联,而深度可分离卷积无法实现有效的通道间信息交换,可能会破坏心电信号中信息的连续性与完整性^[22].因此,本文在 ECG 主干网络的中间部分插入了一个标准卷积块,如图 3 所示,使用两层标准卷积与平均池化的组合提取通道之间的依赖关系,输出不同通道的权重并与输入信号相乘,提升模型关注不同通道之间特征耦合关系的能力.




图 3 标准卷积块结构图

2.2.2 DenseNet 密集网络

DenseNet 与传统的 CNN 卷积神经网络不同,传统 CNN 的每一层仅与后一层相连接,而在 DenseNet 中,每一层与后续的所有层都有直接连接,如图 4 所示.如

此,前馈过程中后续的任何层都可以复用前面层的特征图,同时也大大缓解了梯度消失的问题^[26].与传统的 CNN 卷积神经网络相比,DenseNet 只需要更少的参数就能够实现同样好的性能.因此,本文选择 DenseNet 作为 ECG 主干网络的主体架构.




图 4 DenseBlock 密集块结构图

DenseNet 最初被设计用于二维图像的分类^[25],且更加倾向于使用 3×3 的小卷积核来识别图像中的细微变化.为了使其更加轻量,并且能够应用于房颤检测,本文在遵循 DenseNet 原始架构的基础上做了以下改动:(1)将原始结构的二维卷积替换为一维卷积,使得模型适用于处理一维心电数据;(2)本文中的 DenseNet 仅包含 3 个密集块,分别具有 4、4、8 个密集层,与原始的 DenseNet 架构相比,大大减少了卷积层的数量;

(3) 本文将 DenseNet 中的标准卷积替换为深度可分离卷积, 进一步减少模型的参数量与计算量, 同时在模型的中部插入了一个标准卷积块用于增加特征通道间的信息交换; (4) 对于从前到后的 3 个密集块, 本文分别使用大小为 9、7、5 的卷积核尺寸, 随着特征图的缩小, 小卷积核更能够发现特征的细微变化。

2.3 RRI 支路设计

根据文献[27], RRI 绝对不等是临床诊断房颤的主要指标之一, 因此本文引入了一个 RRI 支路用于提取 RRI 的不规则信息。对于不同的数据来源, 由于心电信号采集设备、人种等多个因素的影响, 会导致心电的形态信息存在细微差异, 而节律信息 RRI 所受到的影响相对更小。尽管心电信号很容易受到干扰, 但仍可以稳健地检测到 R 峰^[28]。因此, RRI 支路的引入可以提高模型的泛化性能以及鲁棒性。

如图 1 上半部分所示, 本文使用多尺度卷积与单层 LSTM 来构建 RRI 支路, 多尺度卷积使用不同大小的卷积核从 RRI 中提取不同尺度的不规则特征。此外, 在每个卷积层之后都添加了非线性激活函数 ReLU, 并且在多尺度卷积的末尾引入了批量归一化用于提高网络的训练效率。LSTM 基于提取的特征捕获其中的时间依赖性, 输出 RRI 支路判别特征, 接着将 RRI 支路提取的节律特征与 ECG 主干网络提取的心电信号形态特征分别展平(Flatten), 并将展平后的特征拼接得到融合特征, 最终融合特征输入分类器得到分类结果。

3 实验结果与分析

3.1 实验数据及其预处理

为了验证所提出的方法的有效性, 本文在三个房颤相关的公共数据库上进行了实验, 这三个数据库均可从 PhysioNet^[29] 获得。数据库的具体信息介绍如下。

(1) MIT-BIH 心房颤动数据库 (Atrial Fibrillation DataBase, AFDB)^[30]。AFDB 包括患有房颤(大部分是阵发性房颤)的 25 个受试者的长期心电图记录, 其中两条记录由于缺乏注释被排除在外。记录的平均持续时间为 10.19 h, 所有信号均以 250 Hz 采样。

(2) 2021 年第四届中国生理信号挑战赛数据库 (China Physiological Signal Challenge 2021, CPSC2021)^[31]。CPSC2021 包含导联 I 和导联 II 中的可变长度心电记录, 以 200 Hz 采样。公开的两个训练集为 Training1 与 Training2, Training1 包含 12 名房颤患者和 42 名非房颤患者的 730 条记录, Training2 包含 37 名房颤患者和 14 名非房颤患者的 706 条记录。

(3) 长期房颤数据库 (Long Term AF DataBase, LTAfDB)^[32]。LTAfDB 包含阵发性或持续性房颤受试者的 84 条长期心电图记录。所有记录均由 128 Hz 采样的双通道心电信号组成, 记录持续时间各不相同, 通常

为 24~25 h。

在将数据输入网络之前, 需要对数据进行预处理:

(1) 将记录划分为 10 s 的片段, 并且保证片段之间没有重叠部分。

(2) 将数据重采样至 128 Hz, 即每条样本包含 1 280 个样本点。

(3) 使用带通频率范围为 0.5~40 Hz 的五阶巴特沃斯滤波器去除基线漂移和低频噪声, 同时对数据进行 z-score 标准化^[33] 来消除偏移效应所带来的影响。

(4) 使用 Hamilton 算法^[34] 检测信号中的 R 峰, 并计算 RRI, 为了保持 RRI 序列的长度一致为 10, 对于长度大于 10 的 RRI 数据, 使用保留数据的中间部分的方式将数据长度控制为 10, 如长度为 12 的 RRI 数据, 通过切片的方式截取索引 2~11 的 RRI 数据; 对于长度小于 10 的 RRI 数据, 则使用均值填充的方式, 将该条 RRI 数据的均值填充在数据的末尾。

同时, 由于外部测试数据库 AFDB 与 CPSC2021 划分得到的房颤与非房颤类型片段数量的比例差距较大 (AFDB 为 16 003:35 541, CPSC2021 为 117 574:229 953), 需要对来自 AFDB 与 CPSC2021 的数据进行数据均衡的处理。而由于在受试者内部, 不同类别的数据通常极不均衡, 且少数类样本数量充足, 因此本文提出了一种通过限制受试者的多数类样本上限, 保留受试者的少数类样本, 以解决测试实验中数据不均衡的方法, 具体流程如图 5 所示。CAF、CNAFi 与 M 为数据集的统计参数, 其中 CAF 为房颤片段的数量, CNAFi 为第 i 个受试者所能划分的非房颤片段的数量, M 为含有非房颤数据的受试者的数量。均衡算法确定的 Q_2 为受试者非房颤片段数量的上限, AFDB 与 CPSC2021 数据库经过均衡处理得到的 Q_2 分别为 850 与 2 250。不同数据集中提取的房颤和非房颤片段的分割细节如表 2 所示, 可以看到, 均衡后 AFDB 与 CPSC2021 两个类别片段数量的比例近似 1:1。

3.2 实验设置与评价指标

本文的实验基于 Pytorch 深度学习框架, 使用 Python 3.8 编程, 硬件设备使用的 CPU 为 Intel(R) Core (TM) i7-13700 KF, 内存大小为 32 GB, GPU 型号为 NVIDIA GeForce GTX 4070 Ti, 显存大小为 12 GB。模型在训练过程中使用 Adam 优化器优化, 学习率固定为 5×10^{-4} , 总迭代次数设置为 50, 批处理大小为 64, 并使用交叉熵作为损失函数。

参考相关研究, 本文使用准确率、F1 得分、精确率与召回率四个指标来全面评估模型的性能。

3.3 实验结果

为了评估所提出模型的泛化能力, 本文进行了同数据集内跨受试者以及跨数据集的实验。具体的实验方案: 将 LTAfDB 中的 84 名受试者的心电记录按照 6:1:3 的比例划分为训练集、验证集与内部测试集。此

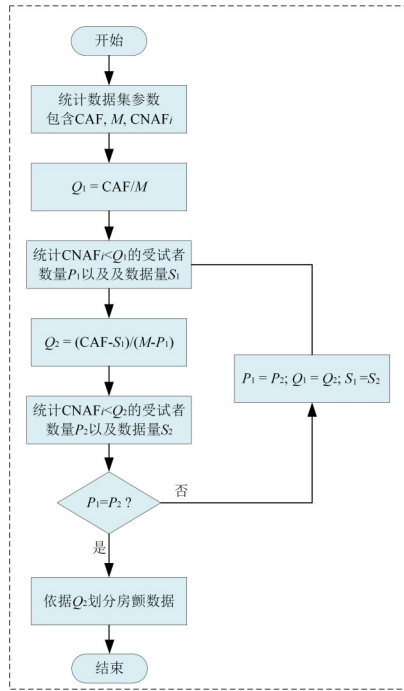


图5 数据均衡算法流程图

表2 预处理后数据集的分割细节

数据来源	所选导联	房颤片段	非房颤片段
LTAfDB	ECG1	350 579	292 309
AFDB	ECG1	16 003	15 752
CPSC2021	I, II	117 574	119 393

外,在LTAfDB上训练的模型在两个外部数据集(AFDB与CPSC2021)上进行了独立的测试,以进一步验证模型的泛化性和鲁棒性。模型在三个数据集上的测试结果如表3~表5所示,在LTAfDB的跨受试者内部测试中,模型虽然在精确率上略低于RTA-CNN与DDNN,但在另外三个指标上均取得了最优的效果。而在外部数据集的测试中,模型在准确率、F1得分以及精确率上均为最优,在召回率上表现次优。可以看出,本文所提出的模型在内部与外部测试中均有着较高的F1得分、精确率以及准确率,这意味着模型能够准确地区分正常类型与房颤类型的心电。总的来说,这些实验结果证明了本文所提出模型在同数据集内跨受试者实验以及跨数据集实验上的优良性能。

3.4 对比试验分析

本文复现了一些具有代表性的深度学习房颤检测模型,在相同的训练与测试条件下进行实验,并与本文提出的方法的实验结果相比较,以此来评估模型的有效性。所选取的深度学习模型包括DenseNet-37^[20]、将长短时记忆网络与卷积神经网络结合的LSTM+CNN^[35]、基于轻量级架构设计的LCG-Net^[22]、基于残差的时间注意力卷积神经网络RTA-CNN^[24]、结合多尺度

卷积与挤压激励模块的DDNN^[23]。本文在一个内部测试集以及两个外部测试集上对不同模型进行评估。

如表3所示,其中最好的指标加粗表示,在内部测试集的实验中,所有模型都表现出了优良的性能,本文所提出的模型在准确率、F1得分与召回率上表现出最优,而在精确率上略低于DDNN与RTA-CNN,从整体指标来看,本文所提出模型的性能最为优异。且根据表6可得,本文提出的模型的参数量与计算量远远小于RTA-CNN的参数量与计算量,这意味着本文提出的模型与结构复杂的模型(RTA-CNN与LSTM+CNN)或是轻量模型(DenseNet-37、LCG-Net与DDNN)相比时,有着更强大的分类能力。

如表4和表5所示,其中最好的指标加粗表示,在外部测试集的实验中,本文所提出的方法仅在AFDB外部测试的召回率指标上略低于DenseNet-37与DDNN,在其他指标上均表现出明显的性能差距。反观DenseNet-37与DDNN,二者的精确率相对较低,意味着在外部数据集的测试中存在更多的误诊现象,而本文所提出模型在两个外部测试中均有着最优的精确率,进一步证明了本文所提出的模型较所对比的方法有着更强大的泛化能力。

表3 内部测试集LTAfDB上的实验结果 单位:%

方法	准确率	F1得分	精确率	召回率
DenseNet-37	95.95±2.90	95.63±2.79	95.54±3.80	95.86±3.72
LSTM+CNN	94.19±2.91	93.67±3.31	94.45±4.27	93.10±4.68
LCG-Net	96.51±2.32	96.17±2.64	97.68±2.80	94.83±4.16
RTA-CNN	97.40±1.99	97.13±2.25	99.18±1.73	95.27±3.90
DDNN	97.03±2.17	96.72±2.45	99.24±1.63	94.42±4.27
本文	97.99±1.72	97.82±1.91	98.94±1.92	96.79±3.19

表4 外部测试集AFDB上的实验结果 单位:%

方法	准确率	F1得分	精确率	召回率
DenseNet-37	87.72±4.07	88.53±3.89	80.26±6.08	99.02±1.83
LSTM+CNN	81.25±4.88	83.21±4.97	75.01±7.00	93.93±4.09
LCG-Net	89.28±3.76	88.96±4.17	91.05±5.15	87.27±5.94
RTA-CNN	92.07±3.37	92.10±3.56	91.45±4.91	92.96±4.52
DDNN	92.55±3.39	92.57±3.36	88.80±5.31	96.90±2.94
本文	95.17±2.60	95.18±2.27	93.79±4.14	96.75±3.00

表5 外部测试集CPSC2021上的实验结果 单位:%

方法	准确率	F1得分	精确率	召回率
DenseNet-37	92.45±3.36	92.15±3.45	89.96±5.27	95.44±3.72
LSTM+CNN	89.45±3.86	89.35±4.18	89.14±5.53	89.86±5.49
LCG-Net	90.91±3.57	90.44±3.97	93.23±4.63	88.09±5.79
RTA-CNN	92.96±3.16	92.77±3.38	93.46±4.47	92.30±4.72
DDNN	92.07±3.39	91.99±3.57	91.15±4.98	93.07±4.56
本文	93.81±3.08	93.58±3.31	94.98±4.02	92.41±4.79

表 6 模型复杂度对比

参数	DenseNet-37	LSTM+CNN	LCG-Net	RTA-CNN	DDNN	本文
参数量	61.9 K	188.0 K	41.6 K	1.37 M	58.3 K	48.2 K
计算量	0.76 B	1.90 B	0.31 B	8.25 B	1.96 B	0.42 B

3.5 消融试验分析

为了验证所引入的标准卷积块、RRI 支路以及深度可分离卷积的有效性,在三个测试集上进行了消融实验测试.具体操作是在网络中分别去除标准卷积块、RRI 支路以及将深度可分离卷积替换为标准一维卷积

后开展实验,并与完整网络的实验结果进行比较,以分析标准卷积块、RRI 支路以及深度可分离卷积对网络的贡献.

图 6 是模型在三个数据集上的消融实验结果.可以看出,模型在去除了标准卷积块之后,模型在三个测试集上的准确率、F1 得分以及精确率均表现出了不同程度的降低,这意味着在去除了标准卷积块之后,模型区分房颤与正常样本能力的下降,将更多的正常样本错误分类为房颤类别,证明了标准卷积块的引入使得模型能够关注通道间特征的相关性,提取不同数据集之间的通用特征,从而提高了模型的泛化性能.




图 6 模型消融实验结果

在模型移除了 RRI 支路之后,模型在 LTAfDB 上表现出较小的性能下降,而在 AFDB 与 CPSC2021 上所表现出的性能下降较大.这应当是由于,在内部测试集 LTAfDB 中,数据的分布差异较小,主要体现在受试者之间,此时模型根据心电信号的形态特征就可以实现较为准确的分类.在外部测试集中,数据的分布差异增大,限制了模型依赖心电信号的形态特征分类的能力.而由于 RRI 是节律信息,在不同数据集上的差异较小,模型在外部测试集上更多地依赖 RRI 进行推理.因此模型在移除 RRI 支路后,在外部测试集的性能指标比在内部测试集的性能指标表现出更明显的下降.

可以看到,将模型中的深度可分离卷积替换为标准卷积之后,在内部测试集 LTAfDB 上,模型的性能指标基本没有发生变化,而外部测试集 AFDB 与 CPSC2021 中,模型表现出了明显的性能下降.这是由于深度可分离卷积的引入大幅度减少了卷积核数量,减少了模型过拟合的风险,提高模型的泛化能力,因此在外部测试集中,使用深度可分离卷积的模型表现出更加优越的性能.

本文消融实验中不同模型的数量与计算量如图 7 所示.可以看出,由于 RRI 数据的长度相对较短,因此 RRI 支路的引入对于模型数量与计算量的增加较少.对于基于标准卷积的 DenseNet,本文所提出的模型在数量与计算量分别减少了 27.7% 与 35.1% 的情况下,仍然表现出了更加优异的房颤检测性能.

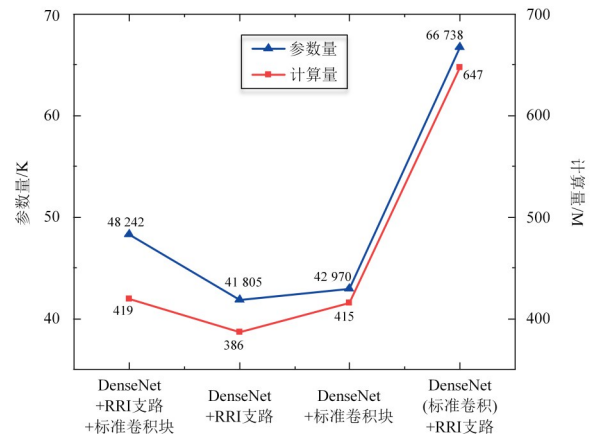


图 7 消融实验模型复杂度对比

3.6 可解释性分析

Grad-CAM++ (Gradient weighted Class Activation Mapping) 是一种应用广泛的可视化方法,其基本思想是将某一分类对应的特征图的权重表示为梯度,利用梯度的全局平均值来计算权重.与文献[36]中故障诊断的可解释性分析类似,本文使用一维的 Grad-CAM++ 对模型的两种分类结果进行可解释性分析.除房颤数据之外,非房颤数据的类型主要包括窦性心律与房性早搏,因此本文对正常窦性心律、房颤以及房性早搏三种类型的心律进行可解释性分析.

正常心律 CAM 值可视化如图 8(a) 所示,颜色级别

越高, CAM 值越大, 特征区分度越高, 左半部分是心电图信号的波形及其 CAM, 右半部分是对应心电图的 RRI 数据及其 CAM 值的可视化. 根据文献[37], 正常的心电图的特征是规律的心律, 每个 QRS 波群前有正常的直立的 P 波(导联 II)以及恒定的 PR 间期. 从图中可以看出, R 波、P 波以及 PR 间期均有着较高的 CAM 值, 意味着这三者对模型将信号分类为非房颤所起到的作用更大. 而在右半部分图中, 模型更加关注 RRI 变化最小的部分, 说明规律的心律是 RRI 支路输出非房颤预测结果的一个重要因素.

房颤的特点是缺乏可辨别的 P 波, 代之以颤动 f 波, 同时表现出 RR 间期的绝对不等^[37]. 如图 8(b) 所示, 显示的结果与指南中房颤诊断的定义一致, 在 P 波消失出现 f 波的位置, 模型给予更高的权重, 说明模型关注到了这一形态信息. 从右半部分的 RRI 支路的结果可以看出, 当 RRI 持续表现出较大变化时, 模型会相

应给予这些部分更多的关注, 解释了模型在引入 RRI 支路后召回率的提高.

文献[37]中提出房性早搏患者的心电图通常具有以下三个特征:(1)异常形态的 P 波;(2)提前出现的 QRS 波群;(3)代偿间歇不完全. 本文所提出的模型对房性早搏样本的 CAM 值可视化结果如图 8(c) 所示, 可以发现, 模型对信号中异常形态的 P 波以及提前出现的 QRS 波群关注度更大, 意味着这二者对模型的决策起到了更大的作用. 代偿间歇不完全的特征表现为 RRI 长短的交替出现, 但是模型对于长 RR 间期的部分以及 RRI 数据的交替变化部分, 所表现出的关注度较低. 意味着模型在对房性早搏样本进行推理时, 更多依靠异常形态的 P 波以及提前出现的 QRS 波群, 而较少关注代偿间歇不完全, 这可能是房性早搏样本被错误分类为房颤的比例较高的原因(19%).

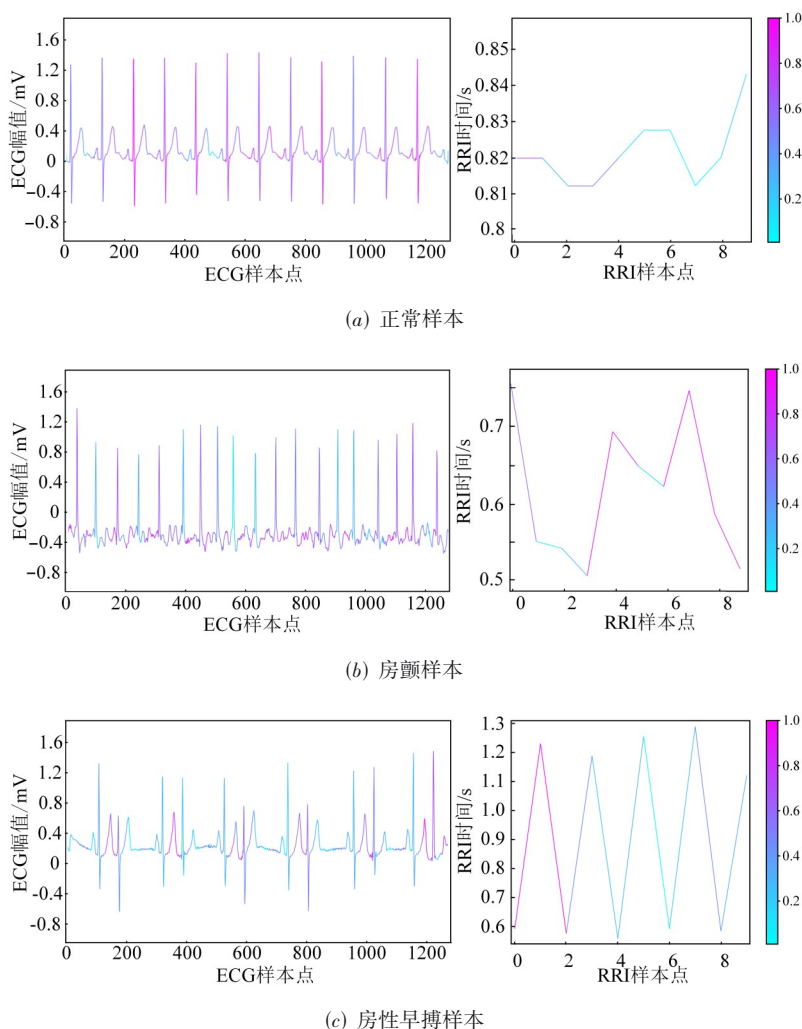


图 8 不同类型心电图的 GradCAM 可视化结果

通过对比相关特征的 CAM 值,医生可以更加细致地了解模型是如何区分房颤与非房颤,尤其是对于正常心电与房颤.可解释性分析的结果证明了模型对于样本的决策是符合临床诊断标准的,这些信息可以帮助临床诊断,并有可能指导进一步的决策.

4 结论

为了解决现有的深度学习房颤检测模型计算成本高、泛化能力以及可解释性差的缺点,本文提出了一种可解释的轻量房颤检测模型.模型使用 DenseNet 的架构,在利用深度可分离卷积提取心电信号深层次特征的同时,使用包含少量标准卷积的块来解决深度可分离卷积不同通道之间信息交互不足的问题.通过引入 RRI 支路使得模型能够提取心电信号的节律特征,与 ECG 主干网络所提取的深层次的形态特征相融合,减少了不同数据集之间心电信号形态上的差异所带来的影响,从而提高模型的泛化性能.与现有算法相比,本文所提出的方法在低计算成本的条件下,实现了更准确、稳定的房颤检测,证明了模型的轻量与高效.可解释性分析的结果显示了驱动模型预测的重要特征与指南中房颤诊断的定义的一致性,证明了模型分类决策的有效性,具有良好的临床应用前景.本文所提出的可解释的轻量房颤检测模型所展现的低计算成本与强大的分类性能,对基于各种生理信号的分析以及分类模型构建的研究具有重要意义.未来,我们计划调整模型使得能够用于多种心律失常的分类,进一步探索模型

参考文献

- [1] HAIM M, HOSHEN M, REGES O, et al. Prospective national study of the prevalence, incidence, management and outcome of a large contemporary cohort of patients with incident non-valvular atrial fibrillation[J]. *Journal of the American Heart Association*, 2015, 4(1): e001486.
- [2] LLOYD-JONES D M, WANG T J, LEIP E P, et al. Lifetime risk for development of atrial fibrillation: The Framingham Heart Study[J]. *Circulation*, 2004, 110(9): 1042-1046.
- [3] HINDRICKS G, POTPARA T, DAGRES N, et al. 2020 ESC Guidelines for the diagnosis and management of atrial fibrillation developed in collaboration with the European Association for Cardio-Thoracic Surgery (EACTS): The Task Force for the diagnosis and management of atrial fibrillation of the European Society of Cardiology (ESC) Developed with the special contribution of the European Heart Rhythm Association (EHRA) of the ESC[J]. *European Heart Journal*, 2021, 42(5): 373-498.
- [4] HENDRIKS J M L, HEIDBÜCHEL H. The management of atrial fibrillation: An integrated team approach-insights of the 2016 European society of cardiology guidelines for the management of atrial fibrillation for nurses and allied health professionals[J]. *European Journal of Cardiovascular Nursing*, 2019, 18(2): 88-95.
- [5] 吕杭, 蒋明峰, 李杨, 等. 基于混合时频域特征的卷积神经网络心律失常分类方法的研究[J]. *电子学报*, 2023, 51(3): 701-711.
LÜ H, JIANG M F, LI Y, et al. Research on arrhythmia classification by using convolutional neural network with mixed time-frequency domain features[J]. *Acta Electronica Sinica*, 2023, 51(3): 701-711. (in Chinese)
- [6] FREEDMAN B, CAMM J, CALKINS H, et al. Screening for atrial fibrillation: A report of the AF-SCREEN international collaboration[J]. *Circulation*, 2017, 135(19): 1851-1867.
- [7] QUER G, FREEDMAN B, STEINHUBL S R. Screening for atrial fibrillation: Predicted sensitivity of short, intermittent electrocardiogram recordings in an asymptomatic at-risk population[J]. *Europace*, 2020, 22(12): 1781-1787.
- [8] 汪毅峰, 李江涛, 徐峥一, 等. 基于电容耦合式电极的非接触式 ECG 采集方法研究[J]. *仪器仪表学报*, 2022, 43(2): 138-147.
WANG Y F, LI J T, XU Z Y, et al. A non-contact ECG measurement method based on capacitance coupling electrodes[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(2): 138-147. (in Chinese)
- [9] ZHOU X L, DING H X, UNG B, et al. Automatic online detection of atrial fibrillation based on symbolic dynamics and Shannon entropy[J]. *Biomedical Engineering Online*, 2014, 13(1): 18.
- [10] ALCARAZ R, ABÁSOLO D, HORNERO R, et al. Optimal parameters study for sample entropy-based atrial fibrillation organization analysis[J]. *Computer Methods and Programs in Biomedicine*, 2010, 99(1): 124-132.
- [11] PARK J, LEE S, JEON M. Atrial fibrillation detection by heart rate variability in Poincaré plot[J]. *Biomedical Engineering Online*, 2009, 8: 38.
- [12] GARCIA-ISLA G, CORINO V, MAINARDI L. Poincaré plot image and rhythm-specific atlas for atrial bigeminy and atrial fibrillation detection[J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(4): 1093-1100.
- [13] CZABANSKI R, HOROBA K, WROBEL J, et al. Detec-

- tion of atrial fibrillation episodes in long-term heart rhythm signals using a support vector machine[J]. *Sensors*, 2020, 20(3): 765.
- [14] LADAVICH S, GHORAANI B. Rate-independent detection of atrial fibrillation by statistical modeling of atrial activity[J]. *Biomedical Signal Processing and Control*, 2015, 18: 274-281.
- [15] SBROLLINI A, MARCANTONI I, MORETTINI M, et al. Spectral F-wave index for automatic identification of atrial fibrillation in very short electrocardiograms[J]. *Biomedical Signal Processing and Control*, 2022, 71: 103210.
- [16] KUMAR M, PACHORI R B, RAJENDRA ACHARYA U. Automated diagnosis of atrial fibrillation ECG signals using entropy features extracted from flexible analytic wavelet transform[J]. *Biocybernetics and Biomedical Engineering*, 2018, 38(3): 564-573.
- [17] FAUST O, KAREEM M, ALI A L, et al. Automated arrhythmia detection based on RR intervals[J]. *Diagnostics*, 2021, 11(8): 1446.
- [18] ANDERSEN R S, PEIMANKAR A, PUTHUSSERY-PADY S. A deep learning approach for real-time detection of atrial fibrillation[J]. *Expert Systems with Applications*, 2019, 115: 465-473.
- [19] FANG B, CHEN J X, LIU Y, et al. Dual-channel neural network for atrial fibrillation detection from a single lead ECG wave[J]. *IEEE Journal of Biomedical and Health Informatics*, 2023, 27(5): 2296-2305.
- [20] BUI T H, HOANG V M, PHAM M T. Automatic varied-length ECG classification using a lightweight DenseNet model[J]. *Biomedical Signal Processing and Control*, 2023, 82: 104529.
- [21] FAN X M, YAO Q H, CAI Y P, et al. Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings[J]. *IEEE Journal of Biomedical and Health Informatics*, 2018, 22(6): 1744-1753.
- [22] LI Y J, CHEN M, JIANG X E, et al. An atrial fibrillation detection algorithm based on lightweight design architecture and feature fusion strategy[J]. *Biomedical Signal Processing and Control*, 2024, 91: 106016.
- [23] CAI W J, CHEN Y D, GUO J, et al. Accurate detection of atrial fibrillation from 12-lead ECG using deep neural network[J]. *Computers in Biology and Medicine*, 2020, 116: 103378.
- [24] GAO Y B, WANG H, LIU Z H. An end-to-end atrial fibrillation detection by a novel residual-based temporal attention convolutional neural network with exponential nonlinearity loss[J]. *Knowledge-Based Systems*, 2021, 212: 106589.
- [25] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 4700-4708.
- [26] 郭一楠, 邵慧杰, 巩敦卫, 等. 基于希尔伯特黄变换和深度卷积神经网络的房颤检测[J]. *电子与信息学报*, 2022, 44(1): 99-106.
- GUO Y N, SHAO H J, GONG D W, et al. Atrial fibrillation detection based on Hilbert-Huang transform and deep convolutional neural network[J]. *Journal of Electronics & Information Technology*, 2022, 44(1): 99-106. (in Chinese)
- [27] 中华医学会心血管病学分会, 中国生物医学工程学会心律分会. 心房颤动诊断和治疗中国指南[J]. *中华心血管病杂志*, 2023, 51(6): 572-618.
- CHINESE SOCIETY OF CARDIOLOGY C M A HEART RHYTHM COMMITTEE OF CHINESE SOCIETY OF BIOMEDICAL E. Chinese guidelines on diagnosis and management of atrial fibrillation[J]. *Chinese Journal of Cardiology*, 2023, 51(6): 572-618. (in Chinese)
- [28] ZOU Y G, YU X Y, LI S Y, et al. A generalizable and robust deep learning method for atrial fibrillation detection from long-term electrocardiogram[J]. *Biomedical Signal Processing and Control*, 2024, 90: 105797.
- [29] GOLDBERGER A L, AMARAL L A, GLASS L, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): 215-220.
- [30] MOODY G. A new method for detecting atrial fibrillation using RR intervals[J]. *Proceedings of Computing Cardiology*, 1983, 10: 227-230.
- [31] WANG X, MA C, ZHANG X, et al. Paroxysmal atrial fibrillation events detection from dynamic ecg recordings: The 4th china physiological signal challenge 2021[J]. *PhysioNet*, 2021, 1: 1-83.
- [32] PETRUTIU S, SAHAKIAN A V, SWIRYN S. Abrupt changes in fibrillatory wave characteristics at the termination of paroxysmal atrial fibrillation in humans[J]. *Europace*, 2007, 9(7): 466-470.
- [33] KUMAR K S, YAZDANPANA B, KUMAR P R. Removal of noise from electrocardiogram using digital FIR

and IIR filters with various methods[C]//2015 International Conference on Communications and Signal Processing (ICCSP). Piscataway: IEEE, 2015: 157-162.

[34] HAMILTON P. Open source ECG analysis[C]//Computers in Cardiology. Piscataway: IEEE, 2002: 101-104.

[35] ZHANG X Y, LI J Q, CAI Z P, et al. Over-fitting suppression training strategies for deep learning-based atrial fi-

brillation detection[J]. Medical & Biological Engineering & Computing, 2021, 59(1): 165-173.

[36] ZHANG X, HE C, LU Y P, et al. Fault diagnosis for small samples based on attention mechanism[J]. Measurement, 2022, 187: 110242.

[37] LUTHRA A. ECG Made Easy[M]. New Delhi: Jaypee Brothers Medical Publishers, 2019: 171-178.

作者简介



高 宁 男, 2000年11月出生, 福建人. 现为福州大学电气工程与自动化学院硕士研究生. 主要研究方向为心电信号的去噪与智能识别技术.

E-mail: gaoning001128@163.com



李玉榕 女, 1973年2月出生, 福建人. 现为福州大学电气工程与自动化学院教授、博士生导师. 主要研究方向为多模态电生理信号建模与智能康复技术研究与应用.

E-mail: liyurong@fzu.edu.cn