

本文引用格式：丘荣建,王剑卓.基于卷积注意力的单导联心电图房颤检测方法[J].自动化与信息工程,2024,45(4):18-23.

QIU Rongjian, WANG Jianzhuo. Single lead electrocardiogram atrial fibrillation detection method based on convolutional attention[J]. Automation & Information Engineering, 2024,45(4):18-23.

## 基于卷积注意力的单导联心电图房颤检测方法\*

丘荣建 王剑卓

(广东工业大学, 广东 广州 510006)

**摘要:** 随着可穿戴心电设备的普及,从单导联心电图自动检测房颤的方法越来越重要。针对可穿戴心电设备采集的单导联心电图存在噪声干扰的问题,提出一种基于卷积注意力的残差神经网络模型 Resnet34-CAB。通过融合卷积注意力块(CAB),在模型复杂度少量增加的情况下,选择性地关注心电图的关键特征,自适应地抑制噪声,提高了模型的检测性能。在公开数据集上的实验结果表明,Resnet34-CAB模型优于Resnet34、Resnet34-Transformer模型,验证了融合CAB的有效性。

**关键词:** 单导联心电图;卷积注意力块;房颤检测;残差神经网络

中图分类号: TP391

文献标志码: A

文章编号: 1674-2605(2024)04-0003-06

DOI: 10.3969/j.issn.1674-2605.2024.04.003

开放获取

### Single Lead Electrocardiogram Atrial Fibrillation Detection Method Based on Convolutional Attention

QIU Rongjian WANG Jianzhuo

(Guangdong University of Technology, Guangzhou 510006, China)

**Abstract:** With the popularity of wearable electrocardiographic devices, the method of automatically detecting atrial fibrillation from single lead electrocardiograms is becoming increasingly important. A residual neural network model Resnet34-CAB based on convolutional attention is proposed to address the issue of noise interference in single lead electrocardiograms collected by wearable electrocardiographic devices. By integrating Convolutional Attention Blocks (CAB), the detection performance of the model is improved by selectively focusing on key features of the electrocardiogram and adaptively suppressing noise, with a small increase in model complexity. The experimental results on public datasets show that the Resnet34 CAB model outperforms the Resnet34 and Resnet34 Transformer models, verifying the effectiveness of the fusion CAB.

**Keywords:** single lead electrocardiogram; convolutional attention block; atrial fibrillation detection; residual neural network

## 0 引言

房颤是一种可通过心电图 (electrocardiogram, ECG) 诊断的心律失常疾病,会增加中风和血栓栓塞的风险,发病率和死亡率较高<sup>[1]</sup>。临床医生通过可穿戴设备获得患者的 ECG 信号,可及时识别房颤,进行早期干预治疗。考虑到成本和便利性,许多可穿戴设备仅采集单导联 ECG 信号<sup>[2]</sup>。因此,有必要开发一种可靠的单导联 ECG 房颤检测方法。

在早期的研究中,一般采用人工提取 ECG 信号

特征的方法实现房颤检测<sup>[3-5]</sup>。BIN 等<sup>[6]</sup>收集了 ECG 信号不同阶段波形的持续时间和振幅、R-R 间期的统计数据、QRS 波形之间的相关性等特征,用于训练决策树集合并作为分类器来检测心律。然而,这类方法易受噪声影响;忽略了 ECG 信号的关键信息,影响房颤检测的准确性和效率;泛化能力较弱,难以满足实际应用场景的需求。

随着深度学习技术的快速发展,应用其提取 ECG 信号的特征,提高了房颤检测的准确性。LEE 等<sup>[7]</sup>和

BUI 等<sup>[8]</sup>提出了基于卷积神经网络 (convolutional neural network, CNN) 模型, 实现端到端地从 ECG 信号中自动提取局部特征进行房颤检测。为了对 ECG 信号序列的长期依赖关系进行建模, WARRICK 等<sup>[9]</sup>、CHENG 等<sup>[10]</sup>、ZHANG 等<sup>[11]</sup>将基于长短期记忆 (long short-term memory, LSTM) 网络与 CNN 结构融合, 提出一种能够同时利用 ECG 信号的局部特征信息和序列长期依赖关系的模型, 提高了房颤检测的准确性。为了使模型能够动态关注 ECG 信号序列中的重要信息, NANKANI 等<sup>[12]</sup>利用 Transformer<sup>[13]</sup>, 通过自注意力机制捕获 ECG 信号的局部和全局依赖性, 实现自适应地抑制噪声。然而引入 Transformer, 导致计算资源随输入长度而二次增长, 增加了计算量。HUO 等<sup>[14]</sup>在图像领域提出一种卷积调制模块, 通过计算大核卷积和逐点卷积输出间的 Hadamard 乘积, 实现自注意力机制的作用, 既不会显著增加模型复杂度, 还能选择性地关注 ECG 信号的关键信息。

受文献[12, 14]启发, 本文提出一种基于卷积注意力的单导联 ECG 房颤检测方法。采用基于 CNN 的 Resnet34<sup>[15]</sup>作为主干网络, 并在 Resnet34 中融合卷积注意力块 (convolutional attention block, CAB), 设计了 Resnet34-CAB 模型, 在增加少量参数和较低浮点运算量的情况下, 自适应地抑制噪声, 提高了模型的鲁棒性和心律分类性能。

## 1 网络模型与损失函数

### 1.1 网络模型

融合了 Resnet34 与 CAB 的 Resnet34-CAB 模型的结构和参数设置如图 1 所示。

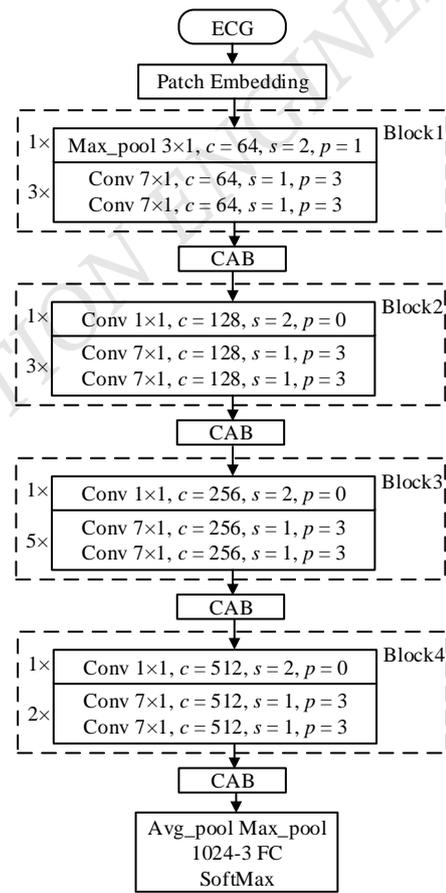
Resnet34-CAB 模型具体处理流程如下:

首先, 将预处理后的 ECG 信号输入到 Patch Embedding 模块中进行浅层特征提取, 降低输入长度。Patch Embedding 模块由一个卷积层 (Conv)、批量归一化层 (Batch Norm) 和激活函数 (ReLU) 组成, 结构和参数设置如图 2 所示。

然后, 利用残差块 (Block) 提取 ECG 信号的局部特征, 并输入到 CAB 中。Resnet34-CAB 模型包含

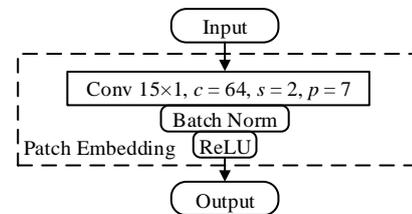
4 个 Block 和 4 个 CAB, 即每个 Block 后均跟随 1 个 CAB, 实现特征的自适应降噪。每个 Block 均包含用于降低数据维度的下采样层和多个卷积层, 具体结构和参数设置参见文献[15]。

最后, 经过 4 个 Block 和 4 个 CAB 处理后, 提取的特征通过平均池化和最大池化操作来降维。将降维后的一维特征向量进行拼接, 输入到全连接层进行分类。



$c$ —通道数;  $s$ —步长;  $p$ —填充。

图 1 Resnet34-CAB 模型的结构和参数设置

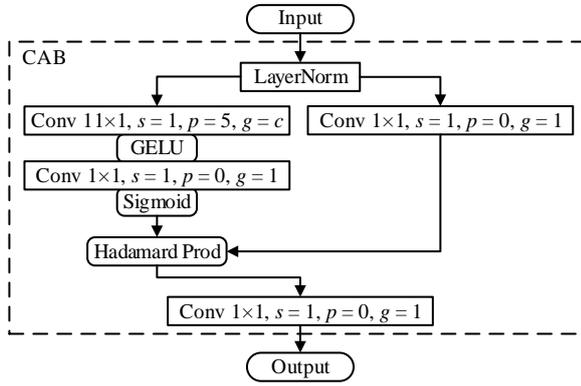


$c$ —通道数;  $s$ —步长;  $p$ —填充。

图 2 Patch Embedding 模块的结构和参数设置

## 1.2 CAB

CAB 结构和参数设置如图 3 所示。



$c$ —通道数;  $s$ —步长;  $p$ —填充;  $g$ —分组。

图 3 CAB 的结构和参数设置

首先, 输入信号经过层归一化 (LayerNorm) 处理分为 2 个分支: 一个分支利用深度可分离卷积来提取注意力权值, 并通过 Sigmoid 函数得到对应的注意力权值分数; 另一个分支利用  $1 \times 1$  卷积进行线性变换。

然后, 将经过  $1 \times 1$  卷积线性变换的特征与注意力权值分数进行 Hadamard 乘积, 得到经过注意力机制调整的特征信号。

最后, 通过  $1 \times 1$  卷积对调整后的特征信号进行线性变换, 并输出到下一层网络结构中。

## 1.3 损失函数

本文通过 Resnet34-CAB 模型对 ECG 信号进行正常 (Normal)、房颤 (AF) 和其他异常心律 (Other) 三分类。采用交叉熵损失函数作为 Resnet34-CAB 模型最小化的目标:

$$L_{\text{loss}} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{i,k} \ln p_{i,k} \quad (1)$$

式中:  $N$  为样本总数;  $K$  为类总数;  $y_{i,k}$  为 one-hot 编码向量, 如果第  $i$  个样本属于第  $k$  个类, 其值为 1, 否则为 0;  $p_{i,k}$  为第  $i$  个样本属于第  $k$  个类的概率。

## 1.4 评价指标

Resnet34-CAB 模型的评价指标采用 F1 分数。F1

分数是精确度 (precision) 和召回率 (recall) 的调和平均值<sup>[16]</sup>, 计算公式分别为

$$P_{\text{precision}} = \frac{TP}{TP + FP} \quad (2)$$

$$R_{\text{recall}} = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = \frac{2 \times P_{\text{precision}} \times R_{\text{recall}}}{P_{\text{precision}} + R_{\text{recall}}} \quad (4)$$

$$F1_{\text{Avg}} = \frac{1}{K} \sum_{k=1}^K (F1_k) \quad (5)$$

式中:  $TP$  为正确将阳性样本识别为阳性的样本总数,  $FP$  为将非阳性样本识别为阳性的样本总数,  $FN$  为将阳性样本识别为阴性的样本总数,  $F1_{\text{Avg}}$  为所有类别对应的 F1 分数的平均值。

## 2 数据

### 2.1 数据集

本文采用的数据集为 2017 年 PhysioNet/Cin 挑战赛使用的公开数据集<sup>[16]</sup>, 简称 2017 挑战赛数据集。该数据集共包括 8 528 个单导联 ECG 信号, 这些信号由 AliveCor 设备采集, 信号长度为 9 ~ 61 s 不等。由于 2017 年挑战赛的测试数据集尚未对外公开, 因此将 2017 挑战赛数据集按 8 : 1 : 1 的比例划分为训练集、测试集和验证集, 且确保在不同的子数据集中, 3 种心律类型的分布相同。

### 2.2 数据预处理

考虑到采集的 ECG 信号中存在噪声干扰。首先, 采用窗口尺寸为 200 ms、边缘忽略尺寸为 100 ms 的中值滤波器去除 ECG 信号中的基线漂移; 然后, 利用小波基 DB5 进行 4 级离散小波变换, 并利用软阈值处理技术<sup>[17]</sup>, 消除 ECG 信号中的工频干扰; 最后, 将所有的 ECG 信号重采样至 120 Hz, 缩短输入长度, 并将所有小于 60 s 的 ECG 信号在末尾补 0, 直到信号长度为 60 s。

### 3 实验

实验采用Centos7.9系统, Python版本为3.7.16, 深度学习框架为PyTorch1.13.1。计算机的CPU为 Inter Corei9-13900k@5.80 GHz, 内存为128 GB, GPU为NVIDIA Geforce RTX4090 24 GB。

在实验中,设置批大小为32,总迭代次数为100次。采用 Adam 优化器进行优化,初始学习率为 $1 \times 10^{-4}$ ,权重衰减系数为 $1 \times 10^{-6}$ 。若验证集损失在连续迭代5次后没有下降,则学习率下调10倍;直到连续迭代20次后,验证集损失没有下降或总迭代次数达到100次,则训练结束。

#### 3.1 对比实验

为了验证本文方法的心律分类性能,选取以下4种单导联 ECG 房颤检测方法进行对比实验:

1) CNN-LSTM<sup>[9]</sup>, 通过 CNN 的特征提取能力与 LSTM 的长期依赖信息能力来检测房颤;

2) MCNN-BLSTM<sup>[11]</sup>, 通过多分支 CNN 与双向 LSTM 的结合, 提取 ECG 信号特征;

3) TWO-VGG16<sup>[18]</sup>, 通过2个独立的VGG-16分别提取 ECG 信号的时频谱和 R-R 间期的庞加莱图特征信息;

4) DResnet<sup>[19]</sup>, 通过将 ECG 信号分解为伪 QRS 波和伪 P-T 波, 训练扩张残差神经网络, 实现心律分类。

上述4种方法与本文方法采用相同的数据集划分比例和损失函数,且预测任务(三分类)也相同,实验结果如表1所示。

表1 5种单导联 ECG 房颤检测方法心律分类性能比较

方法	F1			
	Normal	AF	Other	Avg.
CNN-LSTM	0.903	0.822	0.732	0.819
MCNN-BLSTM	0.920	0.820	0.796	0.845
TWO-VGG16	0.900	0.830	0.750	0.827
DResnet	0.919	0.816	0.793	0.843
本文方法	<b>0.924</b>	<b>0.855</b>	<b>0.816</b>	<b>0.865</b>

由表1可知:本文方法的心律分类性能优于其他4种方法,房颤的 $F1$ 分数比 TWO-VGG16 提高了0.025, $F1_{Avg}$ 比 MCNN-BLSTM 提高了0.021;本文方法在 Resnet34 的基础上融合了注意力机制,有效地自适应抑制噪声,比基于 CNN 和 LSTM 的方法更优;Resnet34 凭借残差网络的优势,在局部特征提取能力方面优于 TWO-VGG16 方法。

#### 3.2 消融实验

为了进一步验证本文模型(Resnet34-CAB)的有效性,利用以下2种模型进行对比实验:

1) Resnet34 模型;

2) Resnet34-Transformer 模型,融合了 Resnet34 模型与 Transformer 模型,其中 Transformer 的层数为3,注意力头数为8。

消融实验除了模型结构不同外,其他设置,如数据集、损失函数、优化器等均相同,实验结果如表2、3所示。

表2 3种模型的心律分类性能对比

模型	F1			
	Normal	AF	Other	Avg.
Resnet34	<b>0.928</b>	0.803	0.799	0.843
Resnet34-Transformer	0.923	0.803	<b>0.817</b>	0.849
Resnet34-CAB	0.924	<b>0.855</b>	0.816	<b>0.865</b>

由表2可知,本文模型(Resnet34-CAB)的 $F1_{AF}$ 比其他2种模型均提高了5.2%, $F1_{Avg}$ 最高,达到了86.5%。

表3 3种模型的数量与浮点运算量对比

模型	参数量/M	浮点运算量/ GFLOPs	$F1_{Avg}$
Resnet34	<b>16.593</b>	<b>5.801</b>	0.843
Resnet34-Transformer	43.341	11.847	0.849
Resnet34-CAB	17.652	6.138	<b>0.865</b>

由表3可知:本文模型(Resnet34-CAB)的参数量、浮点运算量、 $F1_{Avg}$ 比 Resnet34 模型分别增加了1.059 M、0.337 GFLOPs、0.022;Resnet34-Transformer 模型的参数量、浮点运算量、 $F1_{Avg}$ 比 Resnet34 模型

分别增加了 26.748 M、6.046 GFLOPs、0.006，说明 CAB 可以很好地实现自注意力机制的功能，在提高模型房颤检测能力的同时，仅小幅增加模型的复杂度。

### 3.3 梯度加权类激活映射可视化分析

为进一步验证本文提出 CAB 的有效性，利用梯度加权类激活映射<sup>[20]</sup>生成热力图，直观地显示 Resnet34-CAB 模型在心律分类决策时，每个 ECG 信号采样点对决策的贡献程度。本文利用深紫色到亮黄色的渐变，表示该采样点对心律分类决策的贡献程度（从 0 到 1）。

在 Resnet34-CAB 模型中，对第一个 CAB 前后的特征图进行梯度加权类激活映射，得到的热力图分别如图 4、5 所示。在数据集中选用的文件为“A00001”。

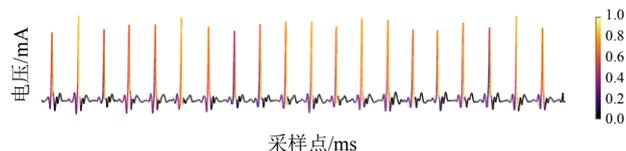


图 4 CAB 前的梯度加权类激活映射热力图

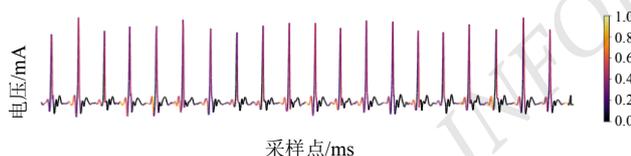


图 5 CAB 后的梯度加权类激活映射热力图

通过对比图 4、5 可以看出：增加 CAB 前，R 波部分偏亮黄色，其他部分偏深紫色，说明模型对 ECG 信号的关注度主要集中在 R 波部分；增加 CAB 后，P 波（R 波前 60~100 ms）、R 波部分都偏亮黄色，说明模型保持了对 R 波关注度的同时，加深了对 P 波部分的关注度；结合房颤心律的特征（不规则的 R-R 间期与 P 波消失），可以判断加入 CAB 可增强模型选择性地关注关键区域的能力，增强房颤的检测性能。

对 Resnet34 模型和 Resnet34-CAB 模型在输入平均池化和最大池化之前的特征图进行梯度加权类激活映射，得到的热力图分别如图 6、7 所示。在数据集中选用的文件为“A07553”。

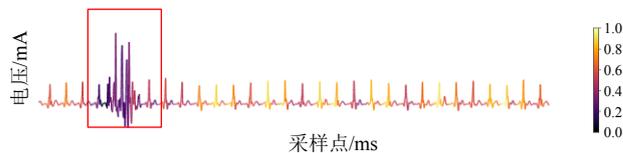


图 6 Resnet34 模型生成的热力图

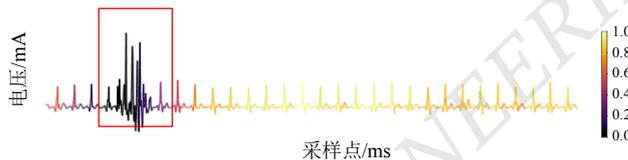


图 7 Resnet34-CAB 模型生成的热力图

通过对比图 6、7 可以看出：Resnet34 模型对噪声的抑制能力较差，在心律分类阶段仍然关注噪声含量较高的 ECG 信号区域，如图 6 中长方形框标出的区域颜色偏紫红色，对心律分类决策的贡献程度在 0.2~0.6 之间；Resnet34-CAB 模型在特征提取时，忽略了噪声含量较高的 ECG 信号区域，如图 7 中长方形框标出的区域颜色偏深紫色，对心律分类决策的贡献程度低于 0.2，关注度集中在噪声含量小、清晰度高、易于区分的 ECG 信号区域，如图 7 中长方形框以外的区域，表明增加 CAB，可实现噪声的自适应抑制，降低了单导联 ECG 信号中的噪声干扰。

## 4 结论

本文提出了一种结合 CAB 的残差神经网络，通过卷积简化注意力计算，实现选择性地关注 ECG 信号，并自适应地抑制噪声。虽然通过卷积计算注意力权值增加了 CAB，但并未显著增加模型的复杂度，实现了在少量增加模型参数量和浮点运算量的情况下，提高模型的房颤检测性能。在 2017 挑战赛数据集上进行了对比实验和消融实验，验证了本文方法的优越性和 CAB 的有效性。

本文虽然利用卷积注意力实现了比现有方法更优的单导联房颤检测精度，但 CAB 与 Resnet34 结合无法适配可穿戴边缘计算设备的计算能力。为能将算法部署到可穿戴设备中，需要进一步将 CAB 与现有边缘计算设备检测算法进行结合，以提高边缘计算设

备检测算法的精度。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

## 参考文献

- [1] SCHOTTEN U, VERHEULE S, KIRCHHOF P, et al. Pathophysiological mechanisms of atrial fibrillation: A translational appraisal[J]. *Physiological Reviews*, 2011,91(1):265-325.
- [2] BAIG M M, GHOLAMHOSSEINI H, CONNOLLY M J. A comprehensive survey of wearable and wireless ECG monitoring systems for older adults[J]. *Medical & Biological Engineering & Computing*, 2013,51:485-495.
- [3] PLESINGER F, NEJEDLY P, VISCOR I, et al. Automatic detection of atrial fibrillation and other arrhythmias in holter ECG recordings using rhythm features and neural networks[C]//2017 Computing in Cardiology (CinC). IEEE, 2017:1-4.
- [4] BILLECI L, CHIARUGI F, COSTI M, et al. Detection of AF and other rhythms using RR variability and ECG spectral measures[C]//2017 Computing in Cardiology (CinC). IEEE, 2017:1-4.
- [5] TZIAKOURI M, PITRIS C, ORPHANIDOU C. Classification of AF and other arrhythmias from a short segment of ECG using dynamic time warping[C]//2017 Computing in Cardiology (CinC). IEEE, 2017:1-4.
- [6] BIN G, SHAO M, BIN G, et al. Detection of atrial fibrillation using decision tree ensemble[C]//2017 Computing in Cardiology (CinC). IEEE, 2017:1-4.
- [7] LEE H, SHIN M. Learning explainable time-morphology patterns for automatic arrhythmia classification from short single-lead ECGs[J]. *Sensors*, 2021,21(13):4331.
- [8] BUI T H, PHAM M T. Automatic varied-length ECG classification using a lightweight DenseNet model[J]. *Biomedical Signal Processing and Control*, 2023,82:104529.
- [9] WARRICK P A, HOMSI M N. Ensembling convolutional and long short-term memory networks for electrocardiogram arrhythmia detection[J]. *Physiological Measurement*, 2018,39(11):114002.
- [10] CHENG J, ZOU Q, ZHAO Y. ECG signal classification based on deep CNN and BiLSTM[J]. *BMC Medical Informatics and Decision Making*, 2021,21:1-12.
- [11] ZHANG H, GU H, GAO J, et al. An effective atrial fibrillation detection from short single-lead electrocardiogram recordings using MCNN-BLSTM network[J]. *Algorithms*, 2022,15(12):454.
- [12] NANKANI D, BARUAH R D. Atrial fibrillation classification and prediction explanation using transformer neural network [C]//2022 International Joint Conference on Neural Networks (IJCNN). IEEE, 2022:1-8.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [14] HOU Q, LU C Z, CHENG M M, et al. Conv2former: A simple transformer-style convnet for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024:1-10. DOI:10.1109/TPAMI.2024.3401450.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [16] CLIFFORD G D, LIU C, MOODY B, et al. AF classification from a short single lead ECG recording: The PhysioNet/computing in cardiology challenge 2017[C]//2017 Computing in Cardiology (CinC). IEEE, 2017:1-4.
- [17] YU Z, CHEN J, LIU Y, et al. DDCNN: A deep learning model for AF detection from a single-lead short ECG signal[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022,26(10):4987-4995.
- [18] FANG B, CHEN J, 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*, 2021,27(5):2296-2305.
- [19] LI Y, XIA Y. Atrial fibrillation detection with signal decomposition and dilated residual neural network[J]. *Physiological Measurement*, 2023,44(10):105001.
- [20] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: Visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017:618-626.

## 作者简介:

丘荣建, 男, 1994 年生, 硕士研究生, 主要研究方向: 模式识别、生物信号处理。E-mail: jianfyy@163.com

王剑卓, 男, 1998 年生, 硕士研究生, 主要研究方向: 模式识别、生物信号处理。E-mail: 2913725799@qq.com