

DOI:10.3969/j.issn.1005-202X.2023.12.012

医学信号处理与医学仪器

## 改进轻量化残差网络的心律失常分类方法

张培玲, 裴前勇

河南理工大学物理与电子信息学院, 河南 焦作 454003

**【摘要】**在保证系统准确率的前提下,轻量化分类模型以便于其在硬件资源有限的嵌入式设备或移动终端上部署,提出基于改进轻量化残差网络的心律失常分类方法。该方法首先将一维心电信号通过格拉姆角和场转换成二维图像作为模型输入,接着使用 ShuffleNet V2 卷积单元替换 ResNet34 基本残差块中传统卷积,降低模型参数量,并结合高效通道注意力模块使模型专注于重要特征区域,提升模型的准确率,最终实现心律失常自动分类。基于 MIT-BIH 心律失常数据库的实验结果表明,所提方法的准确率达到 99.78%,与传统 ResNet34 模型相比,Params 减少 95%,FLOPs 和 MAdd 均降低 91%,表明该方法具有轻量化、高准确率的特点,为其在后续的移动端部署提供可能。

**【关键词】**轻量化;心律失常;ResNet34;ShuffleNet V2

**【中图分类号】**R318;R541.7

**【文献标志码】**A

**【文章编号】**1005-202X(2023)12-1531-09

## Arrhythmia classification method using modified lightweight residual network

ZHANG Peiling, PEI Qianrong

School of Physics and Electronic Information Engineering, Henan Polytechnic University, Jiaozuo 454003, China

**Abstract:** On the premise of ensuring system accuracy, lightweight models can be deployed on embedded devices or mobile terminals with limited hardware resources. Therefore, a method using modified lightweight residual network is proposed for arrhythmia classification. The method transforms one-dimensional electrocardiogram data into Gramian angular summation field maps which are then taken as the model input, and reduces the number of model parameters by substituting ShuffleNet V2 convolutional units for the traditional convolution inside the ResNet34 basic residual blocks. In addition, the network incorporating efficient channel attention module makes the model focus on important feature regions, thereby improving model accuracy and realizing the automatic arrhythmia classification. The proposed model has an accuracy of 99.78% on MIT-BIH arrhythmia database, and it reduces the number of parameters, FLOPs and MAdd by 95%, 91% and 91%, as compared with the traditional ResNet34 model, demonstrating its characteristics of lightweight and high accuracy, and proving the possibility of deployment on mobile devices.

**Keywords:** lightweight; arrhythmia; ResNet34; ShuffleNet V2

### 前言

心血管疾病严重威胁到人类的生命健康,每年有超过 1 700 万人因心血管疾病而逝世<sup>[1]</sup>。其中心律失常是最常见的心血管疾病之一,心律失常的诊断和预防对于维护国民健康至关重要。心电图(Electrocardiogram, ECG)作为一种非入侵性医疗工具可以记录心脏的生理状态,是诊断心律失常等疾病的重要手段。然而,传统的人工 ECG 分析耗时耗

力且容易出错,因此实现心律失常自动分类以提高诊断效率显得尤为重要。随着人工智能的发展,深度学习已被广泛用于心律失常的检测<sup>[2-4]</sup>。秦默然等<sup>[5]</sup>利用 1 维(1D)心电信号作为输入设计了空洞卷积金字塔模块,利用多种尺寸的空洞卷积提取信息再将各通道的信息聚合,以 87.97% 的准确率对心律失常进行分类。Sannino 等<sup>[6]</sup>使用深度神经网络检测 MIT-BIH 数据库中 ECG 的时间特征,最终心律失常分类准确率为 99.09%。Wu 等<sup>[7]</sup>设计一种 12 层深度 1D CNN 方法,心律失常分类准确率达到 97.41%。Cui 等<sup>[8]</sup>提出一种结合手工提取特征和 1D CNN 的特征提取方法,旨在找到最佳特征组合进而提升分类准确度,最终达到 98.35% 的分类精度。以上均是基于 1D 心电信号的分类研究,在准确率上有待进一步

**【收稿日期】**2023-05-19

**【基金项目】**国家自然科学基金(41904078)

**【作者简介】**张培玲,博士,副教授,研究方向:通信技术和信号处理,E-mail: plzhang@hpu.edu.cn

提高,大多数深度学习模型都是基于二维(2D)图像输入设计的,将心电信号转换成2D图像可以使这些模型更容易地适应心律失常分类任务,因此本文针对2D化的心电信号进行研究。

2D神经网络能够充分发挥图像处理的优势,可以提取出更多有用的特征信息,从而更好地区分不同类型的心电信号。Jun等<sup>[9]</sup>采用2D CNN系统,无需人工预处理即可实现高分类精度。Ullah等<sup>[10]</sup>和Huang等<sup>[11]</sup>均通过短时傅立叶变换将1D心电时间序列信号转换为2D频谱图作为2D CNN的输入,并分别以99.11%和99.00%的准确率完成了心律失常的分类任务。Liu等<sup>[12]</sup>将心电波形图输入到网络中,并且在模型中嵌入一个反向残差块来降低模型的参数量,以99.41%的准确率将心电信号分成5类。Ma等<sup>[13]</sup>将ECG时间序列转换为格拉姆角和场(Gramian Angular Summation Field, GASF)图像,接着将所得图像输入到嵌有CBAM注意力模块的残差网络中,得到99.23%的分类准确率。尽管采用2D神经网络可以在心律失常分类方面普遍达到较高的准确率,但2D神经网络的复杂度很高,导致难以在实践中直接应用网络模型,因此有必要对模型进行轻量化处理<sup>[14-17]</sup>。

为了克服1D CNN的不足和现有2D CNN在网络复杂度方面的问题,本文将经GASF转换后的2D图像作为输入,提出一种新的轻量化改进模型。在此新模型中设计了两种轻量化模块:结合残差网络和ShuffleNet V2卷积单元设计了轻量化残差(Residual Lightweight, RL)结构模块;在RL模块基础上引入注意力机制得到嵌入注意力机制的轻量化残差(Residual Lightweight Attention, RLA)结构模块,然后利用这两个模块对ResNet34网络进行改进得到最终新模型RLANet。RLANet在保持网络深度的同时拥有轻量化结构,在MIT-BIH数据集上实现了较好的分类效果,能够在保证准确率的情况下降低模型的参数量和计算复杂度,从而为后续模型的硬件移植提供可能。

## 1 相关工作

### 1.1 格拉姆角场(Gramian Angular Field, GAF)

针对1D ECG信号的2D化处理,本文引入GAF<sup>[18]</sup>的数据编码方法将1D ECG转化为2D图像,以便充分利用深度学习在图像分类上的优势。GAF分为GASF与格拉姆角差场(Gramian Angular Difference Field, GADF),本文使用GASF。定义一个长度为 $n$ 的时间序列 $X = \{x_1, x_2, x_3, \dots, x_n\}$ ,首先将 $X$ 归一化到 $[-1, 1]$ 之间:

$$\tilde{x}_i = \frac{(x_i - \max(X)) - (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

将归一化后的序列 $\tilde{X}$ 编码到极坐标系中,其值为角余弦,相应的时间戳为半径:

$$\begin{cases} \Phi = \arccos(\tilde{x}_i) & (-1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \leq X) \\ r = \frac{t_i}{N} & (t_i \in N) \end{cases} \quad (2)$$

式中, $F$ 的取值范围为 $[0, \pi]$ ;  $r$ 为编码后的半径; $t_i$ 为时间戳; $N$ 为正则化极坐标系空间的常数因子;通过将归一化后的时间序列转换为极坐标形式,就可以使用角度视角分析数据间的三角和,以识别不同时间间隔内的时间相关性。GASF的定义如式(3)所示:

$$\text{GASF} = [\cos(\Phi_i + \Phi_j)] = \tilde{X}^T \cdot \tilde{X} - \sqrt{I - (\tilde{X}^2)^T} \cdot \sqrt{I - \tilde{X}^2} \quad (3)$$

本文使用GASF的优势在于转换成2D图像后不会丢失1D心电信号的任何信息,并且从矩阵左上角到右下角时间递增,进而兼顾了信号的时序相关性和时间依赖性,保证信号转换的完整性。

### 1.2 残差网络

通过简单堆叠卷积层来搭建深层网络,会随着网络逐渐加深而发生梯度消失或梯度爆炸的问题,甚至会导致网络退化。He等<sup>[19]</sup>提出残差网络(ResNet),ResNet通过对网络增加恒等映射解决了以上问题,使用残差结构可以搭建深度大且性能好的网络模型。本文选用ResNet34为主干网并对其进行改进,ResNet34中两种基本残差块如图1所示。其中BasicBlock unit1不改变输入特征图大小和通道数,BasicBlock unit2使输入特征图宽高减半且通道数加倍以提取更深层次的特征。

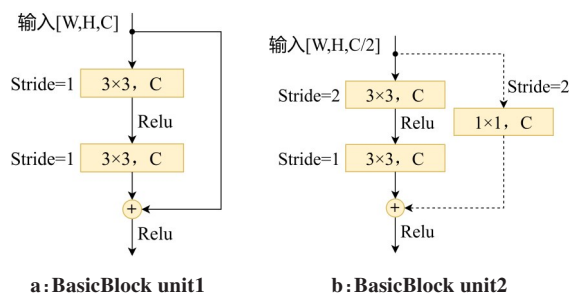


图1 ResNet34两种基本残差块

Figure 1 Two basic residual blocks of ResNet34

### 1.3 ShuffleNet V2 单元

Ma等<sup>[20]</sup>提出设计高效且轻量化网络的4条准则,并根据这4条准则在ShuffleNet V1<sup>[21]</sup>的基础上设计了如图2所示的ShuffleNet V2两种基本单元模块。在图2a所示的ShuffleNet V2 unit1中,先对输入的特

征图进行通道分割(Channel Split),均分成两个支路。左侧支路恒等映射,右侧的支路通过步长均为1的两个1×1普通卷积和一个3×3深度卷积(DWConv)。完成卷积操作后,两个支路的输出特征图进行通道拼接(Concat),最后进行通道混洗(Channel Shuffle),使各组之间的信息互相流通。图2b所示的ShuffleNet V2 unit2为下采样单元,经过此单元特征图的宽高减半,通道数加倍。

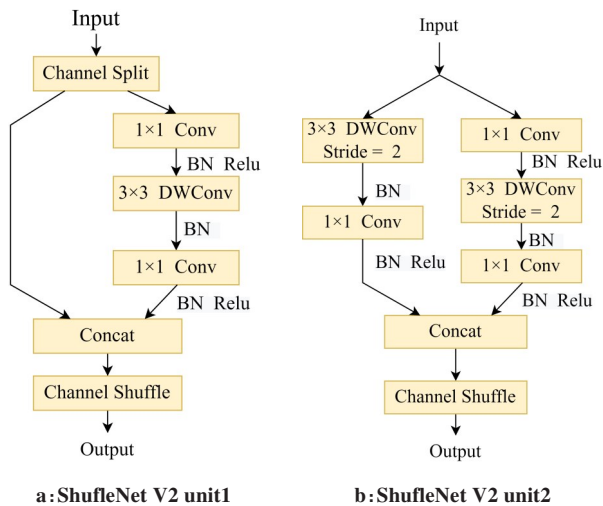


图2 ShuffleNet V2 轻量化单元  
Figure 2 ShuffleNet V2 lightweight units

1.4 高效通道注意力(ECA)模块

注意力机制可以使网络模型得到很好的优化,但是大多数的注意力机制模块的复杂度较高,在优化网络模型的同时带来较大的计算量。Wang等<sup>[22]</sup>提出如图3所示的ECA模块结构图。ECA模块的优点在于其轻量级结构和较低的模型复杂度,且可以明显提高网络模型的性能。ECA模块可以在不降维的前提下对输入特征图使用全局平均池化(GAP),消除了因为降维导致对通道注意力学习效果的影响,接着通过卷积核大小为K的快速1D卷积,可以使各通道和K个相邻的通道之间进行局部跨通道信息交互。其中1D卷积核大小决定了局部跨通道信息交互的范围,通过自适应的方式确定K值,有利于节省计算资源。

2 网络模型设计

2.1 RL 模块

针对网络加深导致参数量和计算复杂度加大的问题,提出RL结构模块,其结构如图4所示。用ShuffleNet V2 unit1替换掉BasicBlock unit1中步长为1的两个3×3卷积,得到图4a所示的RL Moudule unit1,它不改变输入特征图的大小和通道数。用ShuffleNet V2 unit2替换掉BasicBlock unit2中步长为




图3 ECA 模块结构  
Figure 3 ECA module structure

2的3×3卷积,第二个步长为1的3×3卷积用ShuffleNet V2 unit1去替换掉,得到图4b所示的RL Moudule unit2,特征图通过RL Moudule unit2后,其宽高将减半且通道数加倍,有利于深层特征的提取。利用所设计出的RL模块可以搭建深层次网络,并且可以降低网络的参数量和计算复杂度。

2.2 RLA 模块

RL模块可以降低整个网络的参数量和计算复杂度,但是随着网络的加深,通道数逐渐变多,而每个通道的重要程度是不一样的,甚至存在大量冗余信息,应使模型关注到特征图中更重要的部分以改善模型性能。本文设计嵌入注意力机制的RLA模块。

注意力机制选用具有轻量级、低复杂度特点的ECA注意力模块。由于最终模型没有使用到下采样RLA模块,因此只需对RL Moudule unit1改进即可。将ECA注意力模块嵌入到RL Moudule unit1中两个ShuffleNet单元的后边,最终得到的RLA模块如图5所示。该模块优势在于输入特征图经过特征提取过后,可以通过ECA注意力模块给每个输出通道赋予不同权重,可以使网络模型在轻量化的同时关注到重点区域,进而提高网络模型的性能。

2.3 RLANet模型

结合RL模块和RLA模块,本文最终设计一种基于ResNet34改进的轻量化心律失常分类模型



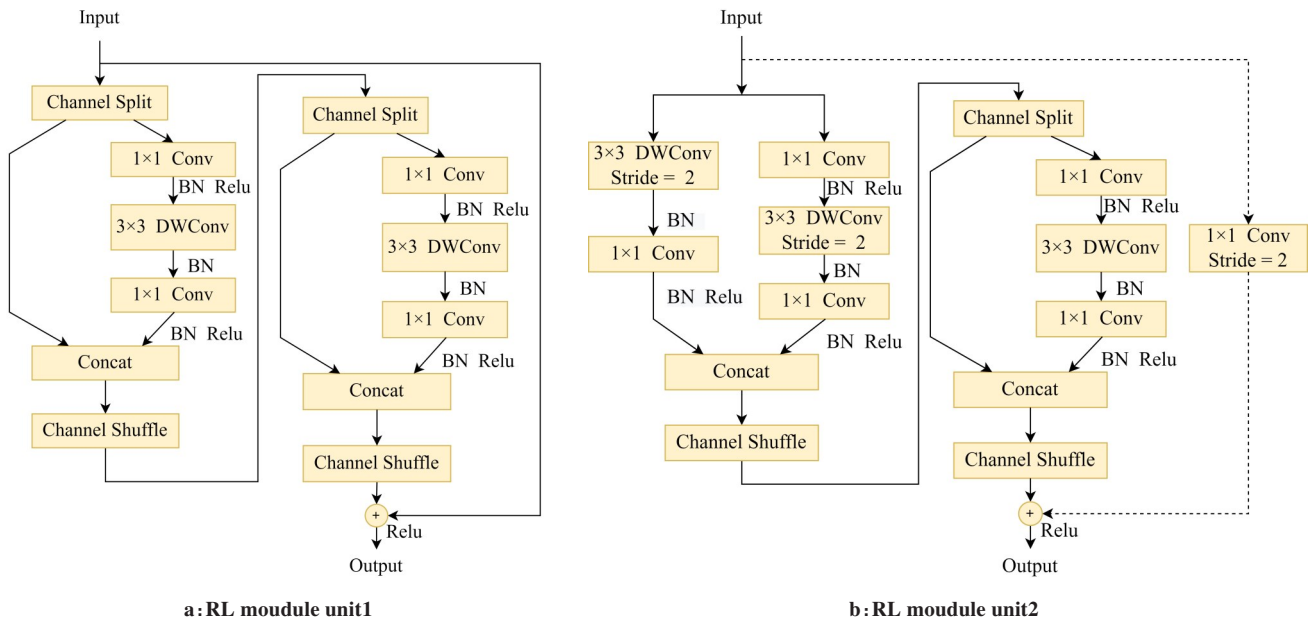


图4 RL 模块单元

Figure 4 RL module units

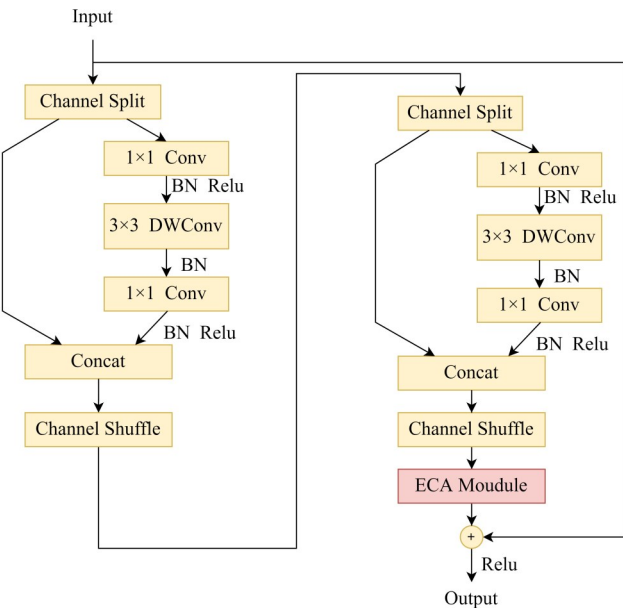


图5 RLA 模块

Figure 5 RLA module

嵌入RLA 模块后可以使网络更好地收敛和保持稳定,并且达到更高的准确率。

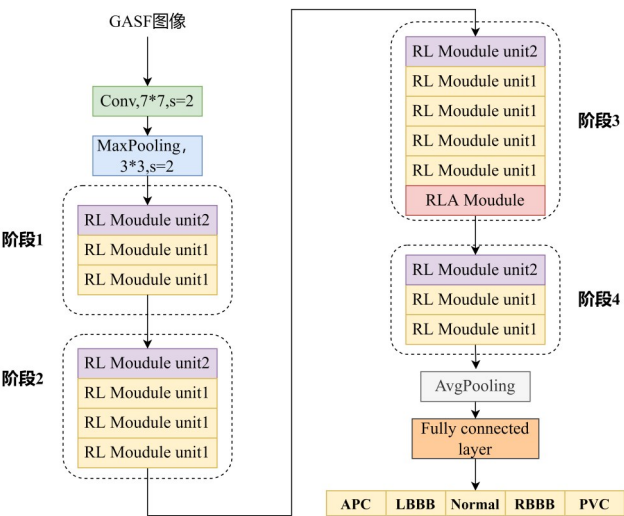


图6 RLNet模型结构

Figure 6 RLNet model structure

RLANet,其结构如图6所示。首先使用所设计的RL模块替换掉ResNet34中的16个基本残差块,得到轻量化残差网络RLNet,其结构如图7所示。其中包含4个阶段,阶段1包含3个RL模块,通道数为64;阶段2中包含4个RL模块,通道数为128;阶段3包含6个RL模块,通道数为256;阶段4包含3个RL模块,通道数为512。这4个阶段的第一个模块均为RL Moudule unit2,可以使每个阶段的输入特征图宽高减半,通道数加倍。接着将阶段3中的最后一个RL模块替换成RLA模块得到改进后的最终模型RLANet,

### 3 实验与结果分析

#### 3.1 实验环境及参数设置

实验均在 Windows10 64位操作系统环境下运行,采用PyTorch1.9.0版本的框架,配合 CUDA 11.1进行训练。处理器为 Intel(R)Xeon(R)CPU E5-2680 v4@2.40 GHz,7核,32 GB内存,RTX3090显卡,24 GB显存。模型训练使用Adam优化器和Cross-entropy损失函数,学习率设置为0.001,批量大小为64,迭代次数为70。

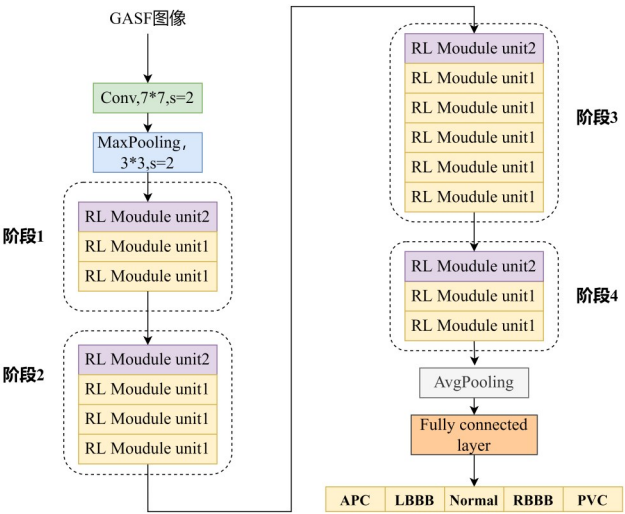


图 7 RLNet 模型结构  
Figure 7 RLNet model structure

3.2 数据来源与处理

在本文的研究中,使用 MIT-BIH 心律失常数据

库(MITDB)<sup>[23]</sup>进行训练和测试。该数据库对 47 名受试者的 48 个 30 min 心电图进行双通道记录,信号的采样频率为 360 Hz。本文研究采用 MLII 导联的心电信号用于分类任务。心电信号被分割成单个心拍去分类识别。选择正常心搏(Normal)、左束支传导阻滞心搏(Left Bundle Branch Block Beat, LBBB)、右束支传导阻滞心搏(Right Bundle Branch Block Beat, RBBB)、室性早搏(Premature Ventricular Contraction, PVC)和房性早搏(Atrial Premature Complexes, APC)作为分类目标。

数据处理流程如图 8 所示。首先采用 db6、db9 尺度小波阈值去噪,然后对心电序列进行分割,以 R 波峰为基准向前取 110 点,向后取 170 点,共计 280 点作为一个心拍。后续通过 GASF 变换将其转换成分辨率为 224×224 的 GASF 图像作为网络模型的输入,各心拍波形典型形式及其对应的 GASF 图像如图 9 所示。




图 8 ECG 数据处理流程图  
Figure 8 ECG data processing flowchart

数据集被划分为训练集和测试集,分割率为 0.2。数据集不平衡会给网络模型训练带来不利影响,需在训练集中将 APC、LBBB、Normal、RBBB 和 PVC 设置相同数量的样本。数据集划分方案如表 1 所示。为了保证平衡训练集后训练集样本总数与测试集样本总数之比近似为 8:2,将训练集中每个类别的样本数目设置为 16 000。将数量少于 16 000 的 4 个类(LBBB、RBBB、PVC、APC)通过 SMOTE 算法去扩充训练集,使其每类达到 16 000 个心拍。Normal 类随机选取 16 000 个心拍即可。测试集保持原有比例,因为这样更符合临床诊断过程。

3.3 评价指标

本文提出的模型目的是能够准确有效地识别出不同类型的心拍,实验选用准确率(Acc)、精确率(PPV)、召回率(TPR)和 F1 分数作为模型性能的评价指标,定义如下:

$$Acc = \frac{TP + TN}{TP + FP + FN + TN}$$

(4)

$$PPV = \frac{TP}{TP + FP}$$

(5)

$$TPR = \frac{TP}{TP + FN}$$

(6)

$$F1 = \frac{2 \times PPV \times TPR}{PPV + TPR} = \frac{2 \times TP}{2 \times TP + FN + FP}$$

(7)

其中,真阳性 TP 表示实际上是正样本,被正确预测为正样本;真阴性 TN 表示实际上是负样本,被正确预测为负样本;假阳性 FP 表示实际上是负样本,被错误预测为正样本;假阴性 FN 表示实际上是正样本,被错误预测为负样本。

3.4 消融实验结果分析

为了证明模型改进的有效性,本文进行消融实验,将 ResNet34、RLNet 和 RLANet 之间进行对比。表 2 记录改进前后模型的参数量(Params)、浮点运算数(FLOPs)和乘加运算量(MAdd),从表 2 中可以看出 RLANet 的 Params、FLOPs 和 MAdd 分别为 1.11 M、0.32 G、0.63 G,相较于 ResNet34 模型,Params 下降

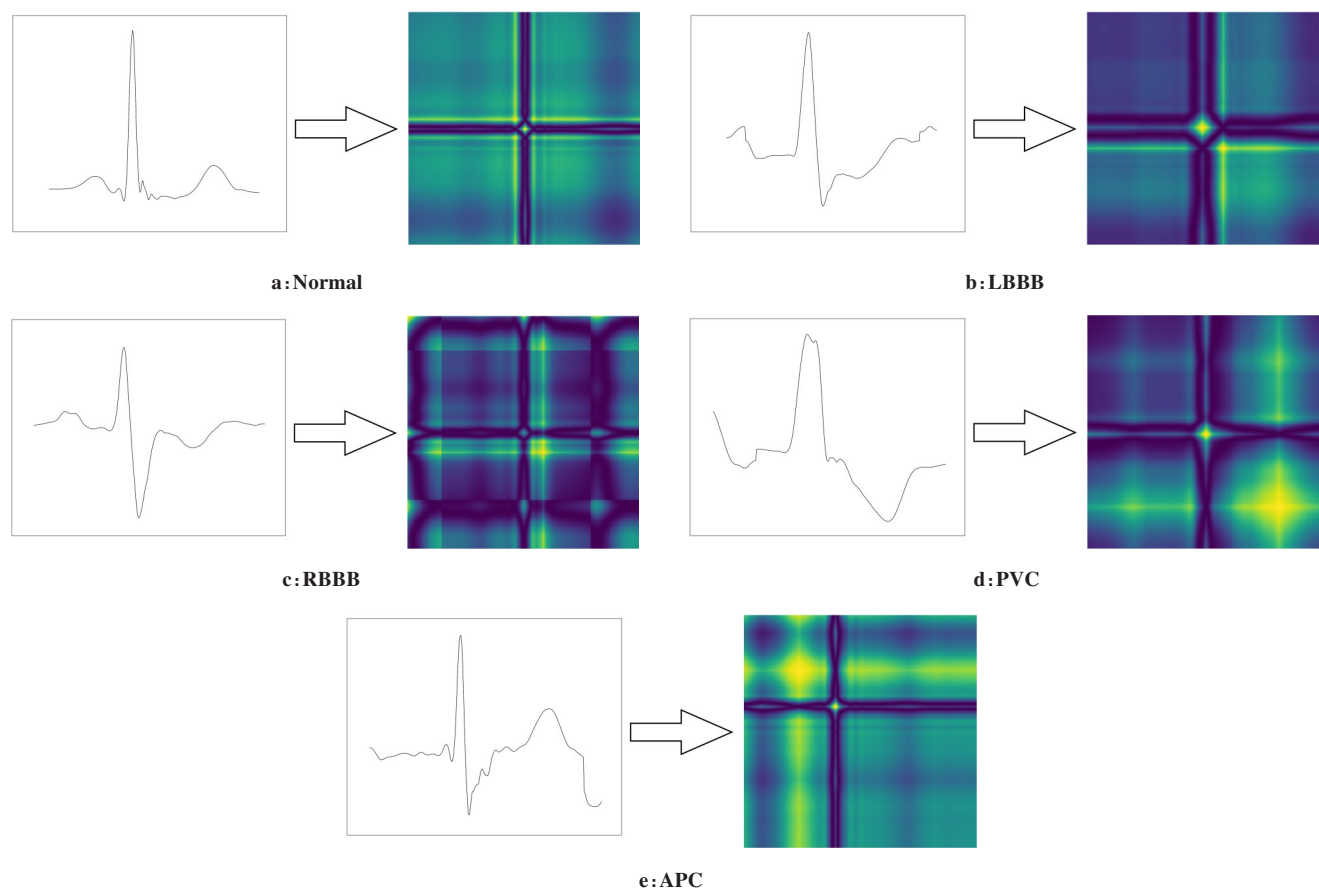


图9 5种心拍的2D转换图

Figure 9 Converting 5 kinds of heartbeats to 2D maps

表1 数据集划分方案				
Table 1 Data distributions of different datasets				
类别	原始总数	训练集		测试集
		扩充前	扩充后	
Normal	74 513	16 000	16 000	14 902
APC	2 546	2 037	16 000	509
LBBB	8 072	6 458	16 000	1 614
RBBB	7 255	5 804	16 000	1 451
PVC	6 902	5 522	16 000	1 380

95%, FLOPs 和 MAdd 均下降 91%, 显著地降低了模型的复杂程度。RLANet 和 RLNet 对比可以发现 Params、FLOPs 和 MAdd 保持一致, 说明在 RLNet 中嵌入 RLA 模块后, 在 Params、FLOPs 和 MAdd 上的影响可以忽略不计。

表 3 所示为改进前后模型性能的相关评价指标, 可以看到 RLANet 的准确率、精确率、召回率和 F1 值均达到最优。RLNet 与 ResNet34 相比性能略有下降。但 RLANet 与 RLNet 相比, 准确率和 F1 分数分别提升 0.21% 和 0.86%, 结果说明只是单纯轻量化可以

表2 改进前后模型复杂度对比			
Table 2 Comparison of model complexity before and after modification			
模型	Params/M	FLOPs/G	MAdd/G
ResNet34	21.29	3.67	7.34
RLNet	1.11	0.32	0.63
RLANet	1.11	0.32	0.63

降低模型复杂度, 但不能保证模型的性能, 在嵌入 RLA 模块后可以使模型性能得到回升。与 ResNet34 相比, RLANet 在保持轻量化的同时达到了最优性能。

表3 消融实验各指标对比(%)				
Table 3 Comparison of indexes in ablation experiment (%)				
模型	准确率	精确率	召回率	F1 分数
ResNet34	99.64	98.45	99.08	98.76
RLNet	99.57	98.63	98.48	98.55
RLANet	99.78	99.45	99.37	99.41

图 10 所示为改进前后模型的准确率曲线,从图 10 可以看出 RLNet 相较于 ResNet34 会有较大的波动;RLANet 相较于 RLNet 其准确率曲线变得更平稳且收敛效果更佳,收敛后其准确率略高于原始的

ResNet34 网络。结合表 2、表 3 和图 10 可以看出与 ResNet34 和 RLNet 相比,RLANet 在低参数量、低计算复杂度的前提下做到了最高准确率,同时具有良好的收敛性和稳定性。




图 10 消融实验准确率曲线对比  
Figure 10 Comparison of accuracy in ablation experiments

3.5 模型性能比较

本文将 RLANet 和 LeNet<sup>[24]</sup>、AlexNet<sup>[25]</sup>、VGG16<sup>[26]</sup>、GoogLeNet<sup>[27]</sup> 4 个经典的网络模型进行比较,为了保证实验的公平性,将实验所需超参数设置均保持一致。表 4 为各个模型的训练结果,从表 4 中可以看出 RLANet 的准确率、精确率、召回率、F1 分数均优于其他 4 个经典网络模型,在此基础上 Params 仅

有 1.11 M 保持最低。RLANet 在 FLOPs 和 MAdd 这两项指标结果为 0.32 G 和 0.63 G,与 AlexNet 接近, LeNet 保持最低。相比之下,LeNet 和 AlexNet 表现效果较差,其中 LeNet 表现效果最差,其准确率仅有 99.15%。VGG16 和 GoogLeNet 准确率相近,但是与所提出模型相比,准确率分别低了 0.27% 和 0.29%,其中 VGG16 的 Params、FLOPs 和 MAdd 最高。

表 4 与经典网络的各指标对比  
Table 4 Comparison of various indicators with other classical networks

模型	准确率/%	精确率/%	召回率/%	F1 分数/%	Params/M	FLOPs/G	MAdd/G
LeNet	99.15	96.79	97.45	97.12	10.81	0.21	0.43
AlexNet	99.35	97.88	97.75	97.81	14.60	0.31	0.62
VGG16	99.51	98.21	98.07	98.14	134.30	15.50	30.95
GoogLeNet	99.49	98.53	98.01	98.26	5.98	1.59	3.18
RLANet	99.78	99.45	99.37	99.41	1.11	0.32	0.63

图 11 所示为 RLANet 和各经典模型的准确率曲线对比,从图 11 中可以明显看出 RLANet 的准确率保持最高,同时曲线具有良好的稳定性。LeNet 和 AlexNet 的准确率曲线处于最下方。GoogLeNet 和 AlexNet 曲线具有较大的波动。VGG16 的准确率曲线在收敛后相对而言较为稳定且更加贴近 RLANet 的曲线,但是 VGG16 的模型复杂度远大于 RLANet。

同时本文也将所提模型与 5 种现有的方法进行对比,所有这些方法均以 2D 数据作为输入,表 5 描述了准确率、精确率、召回率和 F1 分数的对比结果,图

12 记录了 Params、FLOPs、MAdd 和准确率的分布关系。从表 5 中可以看出本文方法获得了第二好的结果,准确率仅低于 Rashed-al-mahfuz 等<sup>[14]</sup>方法 0.12%,但从图 12 中可以明显看到 Rashed-al-mahfuz 等<sup>[14]</sup>方法的 Params、FLOPs 和 MAdd 均远高于本文模型,同时在图 12 中可以看到本文方法均处于左上角,表明本文方法能够在低复杂度的前提下保持高性能,在网络复杂度和准确率之间达到了良好的平衡。结合表 5 和图 12 可以看出本文所提 RLANet 模型的整体性能在一定程度上优于以前的方法。






图 11 与经典网络的准确率曲线对比

Figure 11 Comparison of the accuracy curves with the classical networks

表 5 与现有方法的对比

Table 5 Comparison with the existing methods

方法	数据库	输入类型	方法	类别数	准确率/%	精确率/%	召回率/%	F1 值/%
Huang 等 <sup>[11]</sup>	MITDB	2D	STFT+2D CNN	5	99.00	-	-	-
Liu 等 <sup>[12]</sup>	MITDB	2D	2D CNN	5	99.41	96.50	99.64	98.04
Rashed-al-mahfuz 等 <sup>[14]</sup>	MITDB	2D	CWT+VGG	5	99.90	-	99.90	-
Ma 等 <sup>[13]</sup>	MITDB	2D	ResNet+CBAM	5	99.23	99.13	97.50	98.29
Mohonta 等 <sup>[15]</sup>	MITDB	2D	CWT+2D CNN	5	99.65	-	98.87	-
本文方法	MITDB	2D	ResNet+ShuffleNetV2+ECA	5	99.78	99.45	99.37	99.41

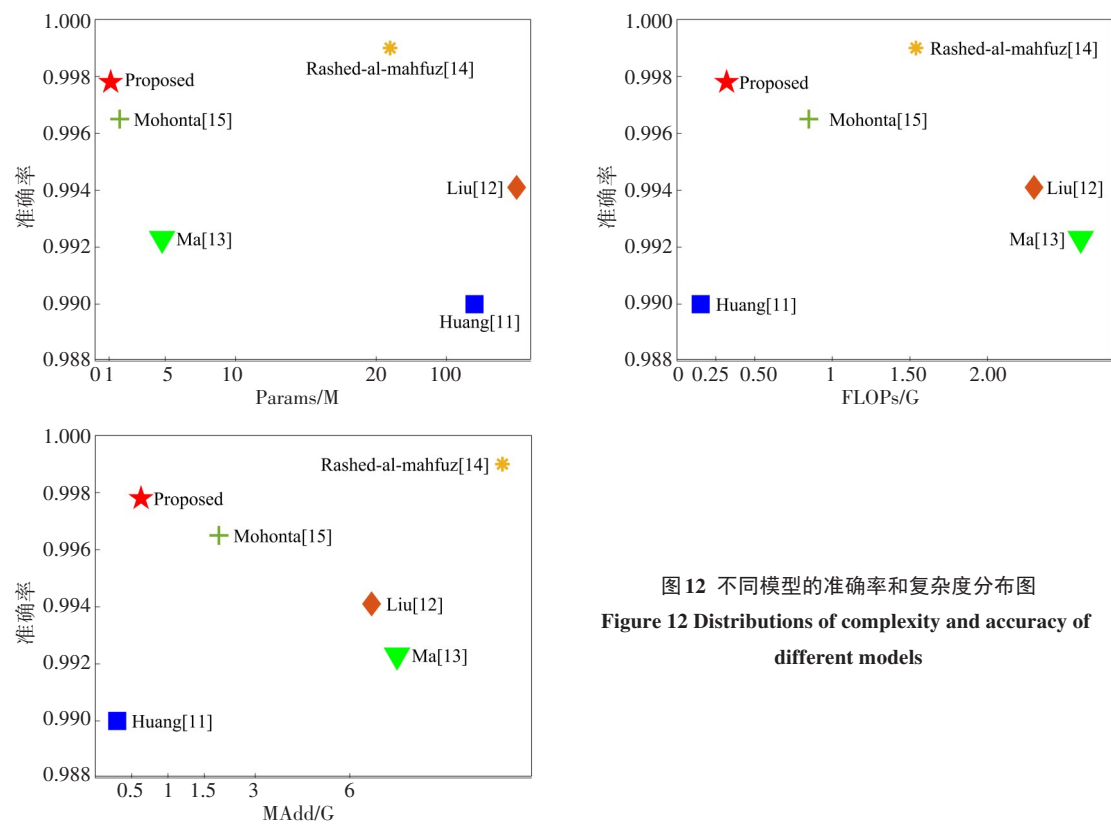


图 12 不同模型的准确率和复杂度分布图

Figure 12 Distributions of complexity and accuracy of different models



## 4 总结与展望

本研究提出一种2D轻量级残差网络RLANet用于心律失常分类。RLANet利用残差结构保证了网络的深度,利用轻量化单元减少了网络的复杂度,最后结合注意力机制使模型专注于重要特征区域进而提升模型的准确率。在MITBIH心律失常数据库上实现了99.78%的准确率,与传统ResNet34模型相比,Params减少95%,FLOPs和MAdd均降低91%,与经典网络和现有方法的对比更是凸显了RLANet的优势。该模型的亮点在于:运用GASF将1D心电信号转换成图像作为输入信号,保证了心电信号的时序相关性和时间依赖性;网络结构设计合理,将深度网络和轻量级网络的优势深度融合,其中深度网络结构结合注意力机制确保了心律失常分类的准确性,而轻量级网络结构的使用降低了网络复杂性。在未来的研究中,将在更多不同的心律失常数据库中去验证模型的普适性,同时也将考虑到个体差异性带来的影响并且专注于更多心率失常类别的分类,最后通过相关编程语言将模型加载到移动端或者嵌入式设备中以实现心律失常的实时检测。

## 【参考文献】

- [1] Mc NK, Alzubaidi H, Jackson JK. Cardiovascular disease as a leading cause of death: how are pharmacists getting involved? [J]. Integr Pharm Res Pract, 2019, 8(1): 1-11.
- [2] Tyagi PK, Rathore N, Parashar D, et al. A review of automated diagnosis of ECG arrhythmia using deep learning methods[J]. AI-Enabl Smart Healthc Bio Signals, 2022, 3(3): 98-111.
- [3] Khan AH, Hussain M, Malik MK. Arrhythmia classification techniques using deep neural network[J]. Complexity, 2021(2): 1-10.
- [4] Liu X, Wang H, Li Z, et al. Deep learning in ECG diagnosis: a review [J]. Knowl-Based Syst, 2021, 227(5): 107187.
- [5] 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.  
Qin MR, Li ZT, Zhai YY, et al. Arrhythmia detection algorithm based on dilated convolutional neural network [J]. Chinese Journal of Medical Physics, 2023, 40(1): 87-94.
- [6] Sannino G, De PG. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection[J]. Future Gener Comp Sy, 2018, 86(9): 446-455.
- [7] Wu M, Lu Y, Yang W, et al. A study on arrhythmia via ECG signal classification using the convolutional neural network [J]. Front Comput Neurosci, 2021, 14(1): 564015.
- [8] Cui J, Wang L, He X, et al. Deep learning-based multidimensional feature fusion for classification of ECG arrhythmia[J]. Neural Comput Appl, 2021, 29(3): 1-15.
- [9] Jun TJ, Nguyen HM, Kang D, et al. ECG arrhythmia classification using a 2D convolutional neural network[J]. arXiv preprint arXiv: 1804. 06812, 2018.
- [10] Ullah A, Anwar SM, Bilal M, et al. Classification of arrhythmia by using deep learning with 2D ECG spectral image representation[J]. Remote Sens, 2020, 12(10): 1685.
- [11] Huang J, Chen B, Yao B, et al. ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network[J]. IEEE Access, 2019, 7(7): 92871-92880.
- [12] Liu Y, Jin Y, Liu J, et al. Precise and efficient heartbeat classification using a novel lightweight-modified method[J]. Biomed Signal Process Control, 2021, 68(4): 102771.
- [13] Ma K, Zhan CA, Yang F. Multi-classification of arrhythmias using ResNet with CBAM on CWGAN-GP augmented ECG gramian angular summation field[J]. Biomed Signal Process Control, 2022, 77(4): 103684.
- [14] Rashed-al-mahfuz M, Moni MA, Lio P, et al. Deep convolutional neural networks based ECG beats classification to diagnose cardiovascular conditions[J]. Biomed Eng Lett, 2021, 11(1): 147-162.
- [15] Mohonta SC, Motin MA, Kumar DK. Electrocardiogram based arrhythmia classification using wavelet transform with deep learning model[J]. Sens Biosensing Res, 2022, 37(4): 100502.
- [16] Zhao C, Yao W, Yi M, et al. Arrhythmia classification algorithm based on a two-dimensional image and modified efficient Net[J]. Comput Intell Neurosci, 2022, 2022(4): 8683855.
- [17] Anbarasi A, Ravi T, Manjula VS, et al. A modified deep learning framework for arrhythmia disease analysis in medical imaging using electrocardiogram signal[J]. Biomed Res Int, 2022, 2022(4): 5203401.
- [18] Wang Z, Oates T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C]// Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2015: 40-46.
- [19] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [20] Ma N, Zhang X, Zheng HT, et al. Shufflenet V2: practical guidelines for efficient cnn architecture design [C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 116-131.
- [21] Zhang X, Zhou X, Lin M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 6848-6856.
- [22] Wang Q, Wu B, Zhu P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 13-19.
- [23] Moody GB, Mark RG. The impact of the MIT-BIH arrhythmia database [J]. IEEE Eng Med Biol Mag, 2001, 20(3): 45-50.
- [24] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proc IEEE, 1998, 86(11): 2278-2324.
- [25] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks[J]. Commun ACM, 2017, 60(6): 84-90.
- [26] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. arXiv preprint arXiv:1409.1556, 2014.
- [27] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1-9.

(编辑:陈丽霞)