

文章编号: 2096-1618(2022)02-0119-06

# 基于残差-注意力和 LSTM 的心律失常心拍分类方法研究

熊 磊, 何培宇, 方安成, 秦雷亮, 潘 帆

(四川大学电子信息学院, 四川 成都 610065)

**摘要:**长时心电图是长时间连续记录心电状态的一种心电图,心律失常在心电图上的表现为心拍频率不规则或者波形异常,故高效精准地从长时心电图识别心律失常具有重要的临床意义。针对从长时心电图识别不同心律失常类型的问题,提出基于注意力机制的残差和 LSTM 网络的心律失常心拍分类模型。首先利用小波变换对原始长时心电信号进行滤波处理,然后利用 QRS 波检测算法对 R 波波峰进行定位,并以 R 波波峰为基准将原始信号切分成心拍图,最后放入 Residual-Attention 和 LSTM 网络进行特征提取并实现分类。提出的模型对正常心拍、室性早搏心拍及室上性早搏心拍的三分类准确率为 96.09%,比传统的 CNN 网络模型提高了 3.26%;三类心拍的 F1 值分别提高了 2.04%、2.56% 和 5.30%。对比实验表明,提出的基于 Residual-Attention 和 LSTM 的心律失常心拍分类模型,相比传统的 CNN 模型有着更好的分类准确率和 F1 值。

**关键词:**残差网络;注意力机制;长短时记忆;心律失常;心拍分类

**中图分类号:**TP301.6

**文献标志码:**A

**doi:**10.16836/j.cnki.jcuit.2022.02.001

## 0 引言

心律失常是由于窦房结激动异常或激动产生于窦房结以外,激动的传导缓慢、阻滞或经异常通道传导,即心脏活动的起源或传导障碍导致心脏搏动的频率或节律异常<sup>[1]</sup>。心律失常心拍分类是指根据心电信号的形态识别正常和异常的心拍。近年来,基于机器学习的心电信号分类方法取得了良好的效果,影响检测结果的两个主要方面是特征提取技术和分类算法<sup>[2]</sup>。Salem 等<sup>[3]</sup>提出了二维深度 CNN 特征迁移学习的方法,该方法将心拍转化为二维心电图,利用 CNN 对其进行特征提取,并使用 SVM(support vector machine)进行分类,在 4 种不同的心律失常分类中得到 97.23% 的准确率。虽然 SVM 发挥比较好的作用,但是面对大量的样本数据时,效率不高,且对缺失数据和缺失参数敏感。许多学者利用深度学习中的卷积神经网络和循环卷积神经网络用于心律失常识别的研究<sup>[4-8]</sup>。Romdhane 等<sup>[9]</sup>提出了一种基于深度 CNN 和焦点损失的方法并结合残差模块对 ECG 信号进行分类,在 MIT-BIH 心律失常基准数据库上五分类准确率达到 98.41%;Kachuee 等<sup>[10]</sup>开发了一种基于 CNN 和残差模块的心律失常检测深度神经网络,心拍分类准确率为 95.90%;Guo 等<sup>[11]</sup>介绍了融合 CNN 和 GRU 的深度神经网络模型,在实际病人心电数据中的五分类准确率达 93.71%。Izci 等<sup>[12]</sup>提出了利用二维心电图在改进的 CNN 网络模型中进行

分类,在 MIT-BIH 数据库中对房颤心律失常分类的准确率达 97.25%。上述学者所使用的深度神经网络在信息传递的时候,或多或少会存在信息丢失、损耗等问题,同时还可能导致梯度消失或者梯度爆炸,使得很深的网络无法训练,存在着泛化能力较低的问题。

文中提出一种基于残差-注意力(Residual-Attention)和长短时记忆神经网络(long-short term memory, LSTM)的心律失常心拍分类方法。此方法的网络模型是由残差模块与注意力机制模块相结合再与 LSTM 模块连接。残差模块可以缓解深度神经网络中增加深度带来的梯度消失问题。注意力机制能够高效地考虑全局联系和局部联系,进行并行化处理减少模型训练时间,这在大量样本数据中有着效率优势。使用长时心电特点是可以长时间记录受检者在日常活动过程中的心电信号,克服了常规心电图机一般仅记录数分钟心电信号的不足,对一过性心电异常的检出率更高。

首先对原始心电信号进行小波滤波并进行分割处理,将其转换为单个的心电心拍。分割后,将每一个心拍的一维心电信号转换成二维图像作为输入数据进行分类。该模型结合了 Residual-Attention 和 LSTM,对 3 种不同类型(正常、室性早搏、室上性早搏)的二维心电图进行分类,取得了很好的效果。

## 1 模型搭建

### 1.1 Residual-Attention 结构和 LSTM 结构

如图 1 所示,本文所提出的残差(residual)结构是

若干个卷积层残差相连的结构,其中单个卷积层(convolution, Conv)与其对应的 ReLU 是单个卷积层中的激活函数。这种结构很好地解决了深度神经网络退化的问题,残差连接一定程度上可以缓解梯度消失并且可以使信息前后传播更加顺畅。

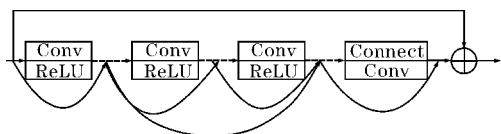


图1 残差模块的结构

如图2所示,本文所提出的注意力机制(attention)结构有区别于传统的 Attention 结构。基于最初的 Attention 的 Encoder-Decoder 思想,将图片数据集进行上采样(up sample)和下采样(down sample),并且在二者中间添加残差模块(residual block),目的是为了减少特征提取时的梯度消失,最后再经过两层卷积层(convolution)。Attention 对输入的每个元素考虑不同的权重参数,从而更加关注与输入元素相似的部分,而抑制其他无用的信息。其最大的优势就是能考虑全局联系和局部联系。

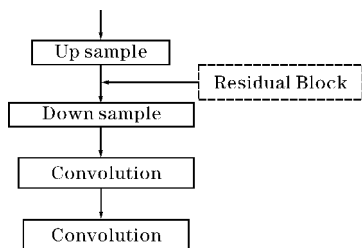


图2 注意力机制模块的结构

长短时记忆网络是由输入门、遗忘门、细胞状态和输出门组成。输入门的功能是用于更新细胞状态表达式。遗忘门则是决定应丢弃或保留的信息。输出门用来确定下一个隐藏态值。细胞状态表示信息传输的路径,让信息能在连续序列中传递。图3为LSTM的示意图。式(1)~(4)分别为输入门、遗忘门、细胞状态和输出门的表达式。其中  $x_t$  是  $t$  时刻的输入,  $h_t$  是  $t$  时刻的输出,  $W$  是权重矩阵,  $b$  是偏置项,  $\sigma$  是 sigmoid 函数。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$\tilde{c} = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$h_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \cdot \tanh(c_t) \quad (4)$$

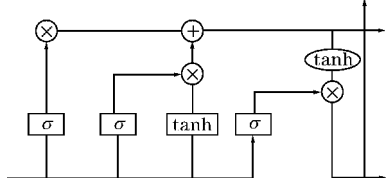


图3 LSTM 结构示意图

## 1.2 整体网络结构

如图4所示,本文整体网络结构由3部分组成。第一部分,将数据集打包成若干个 Batch,依次经过卷积层,批标准化层及使用最大池化进行特征降维,同时提取特征中先响应最大、最强烈的部分。第二部分,在 Residual-Attention 模块中,分别经过 Residual 模块及 Attention 模块,然后通过 Sigmoid 函数将特征融合。此时网络结构比较深,在减少维度的同时,为更有利信息传递到下一个模块进行特征提取,故用平均池化。第三部分,经过 LSTM 层后将数据送入最后的全连接层,由 Softmax 函数对其进行分类最终得到三分类的结果。

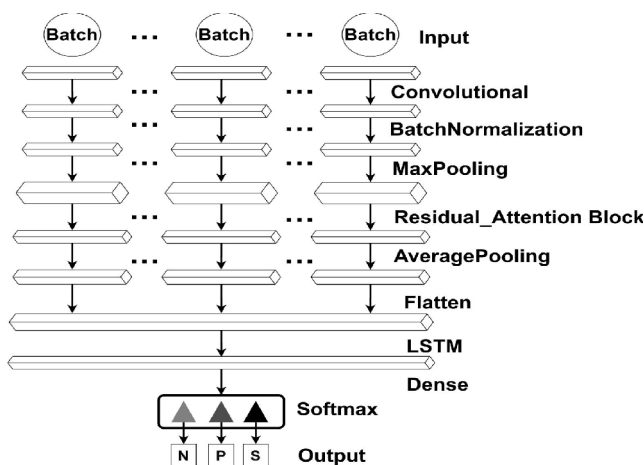


图4 网络结构

卷积模块、批标准化模块和最大池化模块注重对图像特征的提取, Residual-Attention 模块有利于解决因网络加深导致的梯度消失及计算效率问题, LSTM 在分类模型中有良好的性能。数据集首先经过卷积层,然后经过批标准化,再进入最大池化层进行降维。经过降维处理的数据经过三层的 Residual-Attention 后通过 Sigmoid 函数后经过平均池化层,再经过 Flatten 层后并送入 LSTM 层。最后利用全连接层和 Softmax 函数对心电信号进行分类。

## 1.3 激活函数、损失函数和优化器的选择

激活函数对神经网络、理解非线性函数具有十分重要的作用。不同激活函数的选择会导致不同结果,选择一个合适的激活函数需要根据实际情况而定。在卷积层和 Residual-Attention 模块中选择 ReLU 激活函数, ReLU 激活函数会使部分神经元为 0,造成网络的稀疏性,并且减少参数间的相互依赖关系,缓解过拟合问题;在 LSTM 中选择 tanh 激活函数, tanh 激活函数在 LSTM 中可以起防止梯度消失或梯度爆炸的作用;实

现分类则选择 Softmax 作为输出层的激活函数。

损失函数是用来估量模型的预测值与真实值的不一致程度,是一个非负值函数,损失函数越小,模型的鲁棒性越好。本文研究使用交叉熵损失函数作为损失函数。为训练网络达到全局最小,选取 Adam 的学习率自适应优化算法作为优化器,该算法对于超参数的选择鲁棒性较高,学习率初始化为0.0001。

2 心律失常心拍分类实验

2.1 实验数据和预处理

使用的数据来自 CPSC2020Challenge (<http://2020.icbeb.org/CPSC2020>),其中有来自 10 人 10 条约 24 h 长时心电图数据,采样频率为 400 Hz。选取 7 条无房颤的心电数据进行实验。

原始心电信号含有基线漂移和肌电干扰等噪声<sup>[14]</sup>,这些噪声会影响心电图的特征。使用小波函数 Bior2.6 对原始的长时心电信号(图 5 为部分)进行小波分解重构,目的是滤波去除基线漂移及肌电干扰。

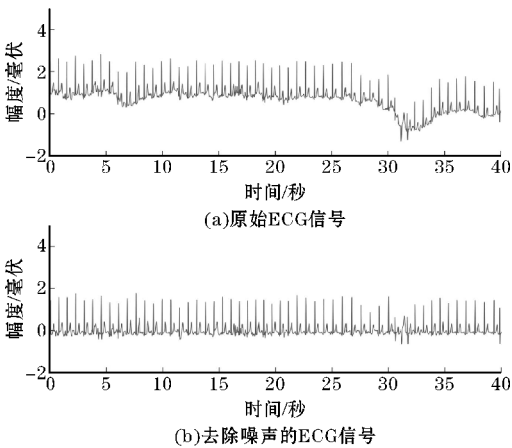


图 5 原始 ECG 信号和去除噪声 ECG 信号

心电信号经过小波变换滤波去除噪声后,再经过 QRS 波检测算法对其进行 R 波波峰定位<sup>[16]</sup>。如图 6 所示,去除噪声的心电信号经过 QRS 波检测算法后,每个心拍被标记 R 波波峰的位置。普通人的正常心率为 60 ~ 100 次/min,一次心跳时间为 0.8 s 左右,以 0.8 s 截取心电信号作为单个心拍,以确保能够包含当前心拍信息。因为本次数据的心电信号采样频率为 400 Hz,按照一个心跳 0.8 s,故一个心拍为 400×0.8 = 320 个点。以 R 波波峰为基准,左边 119 个点右边 220 个点,一共 320 个采样点,大约就是一个完整的心拍。如图 7 所示,以 R 波波峰为基准将长时心电信号切分成单个的心拍。其中单个的心拍有 3 种类型:正常心

拍(N)、室性早搏心拍(V)及室上性早搏心拍(S)。由于正常心拍的数量较多,所以将正常心拍与室性早搏心拍和室上性早搏心拍的比例控制在 2 : 2 : 1 进行分类训练。

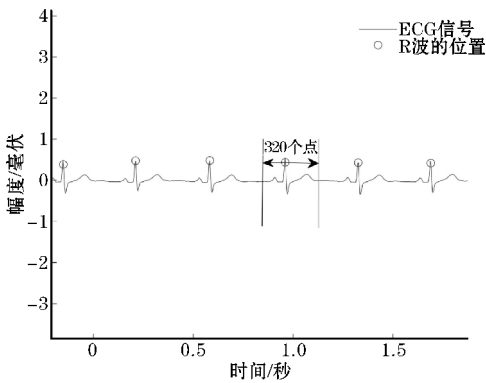


图 6 QRS 波检测定位 R 波位置

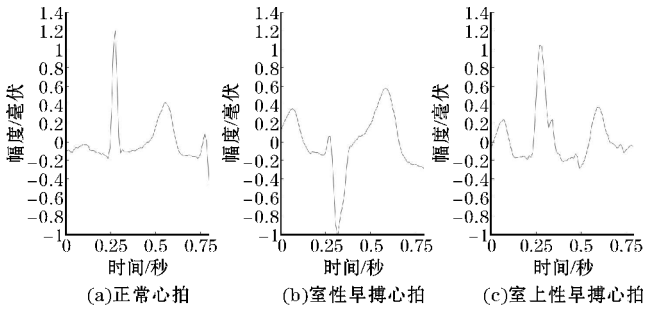


图 7 正常心拍、室性早搏心拍和室上性早搏心拍

2.2 评估方法

为更客观真实验证分类器的结果,使用敏感度 (Se)、精确度 (Pre)、准确率 (Acc) 和 F1 值进行评估<sup>[17]</sup>,式(5) ~ (8)为 4 种评估方法的计算方式。Se 表示正例占总正例的比重,Pre 表示正例占被判定为正例的比重,Acc 表示分类正确样本占总样本的比重,F1 值表示 Se 和 Pre 的调和平均值。软件开发环境为 Tensorflow2.1,实验训练过程在一台搭载 12 GB 显存的 RTX3060 的 GPU,处理器为 AMD Ryzen 5 5600X 6-Core Processor,主频 3.70 GHz。

Se = TP / (TP + FN) (5)

Pre = TP / (FP + TP) (6)

Acc = (TP + TN) / (TP + FP + TN + FN) (7)

F1 = (2 × TP) / (2 × TP + FP + FN) (8)

2.3 实验结果

数据集共 86745 张心拍图,其中正常心拍图有

34923 张,室性早搏心拍图有 34306 张,室上性早搏心拍图有 17480 张,训练集和测试集的比例为4 : 1。分类器的结果在测试集上的混淆矩阵如图 8 所示。由表 1 知,对于正常心拍分类器的精确度、敏感度和 F1 值分别为91.99%、99.16%和95.44%;对于室性早搏心拍分类器的精确度、敏感度和 F1 值分别为99.73%、92.88%和96.19%;对于室上性早搏心拍分类器的精确度、敏感度和 F1 值分别为 96.44%、94.34% 和 95.37%。造成正常心拍分类器的敏感度较另外两个敏感度低的原因是有一部分的室性早搏心拍被误判为正常心拍。由式(7)计算出准确率为96.09%,说明提出的融合分类器整体性能较好。

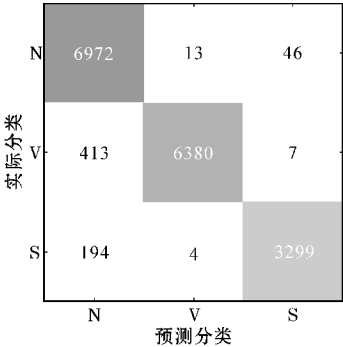


图 8 本文模型的混淆矩阵

表 1 心拍分类结果分析 单位: %

心拍类型	精确度	敏感度	F1 值
正常	91.99	99.16	95.44
室性早搏	99.73	92.88	96.19
室上性早搏	96.44	94.34	95.37

2.4 对比分析

与深度学习神经网络的一种传统 CNN 模型——Vgg16 进行对比。Vgg16 分类器的混淆矩阵如图 9 所示。Vgg16 模型分类器的 Acc 由式(7)计算为 92.83%。提出的分类器的准确率比 Vgg16 模型分类器的准确率高出3.26%。

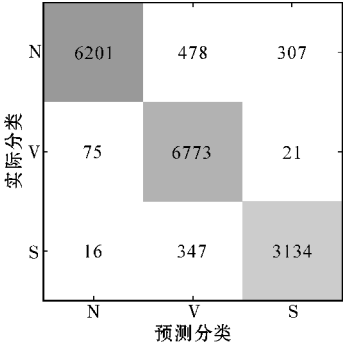


图 9 Vgg16 模型的混淆矩阵

如图 10~12 所示,依次呈现了两个模型三类心拍的敏感度、精确度和 F1 值的对比。从正常心拍来看,Vgg16 模型的敏感度比提出的模型低10.50%,而精确度高4.44%,F1 值相差2.04%。从室性早搏心拍来看,Vgg16 模型的敏感度比提出的模型高5.72%,而精确度低10.59%,F1 值相差2.56%。从室上性早搏心拍来看,Vgg16 模型的敏感度、精确度和 F1 值分别比提出的模型低4.72%、5.91%和5.30%。从整体来看,提出的模型在这次三分类的实验中表现要优于 Vgg16 模型。特别是在 F1 值上的表现,本文的模型都优于 Vgg16 模型。因此,提出的模型在异常心拍分类中,相对传统的 CNN 网络模型具有明显的优势。

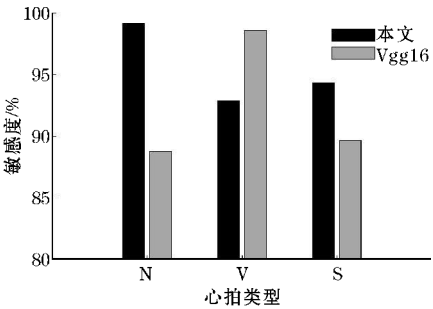


图 10 两个模型的敏感度对比

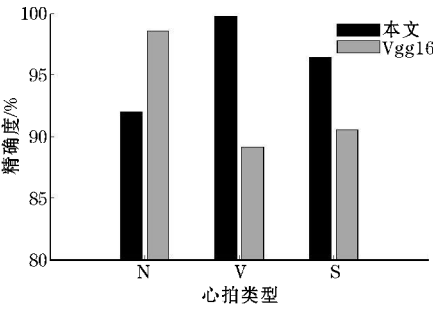


图 11 两个模型的精确度对比

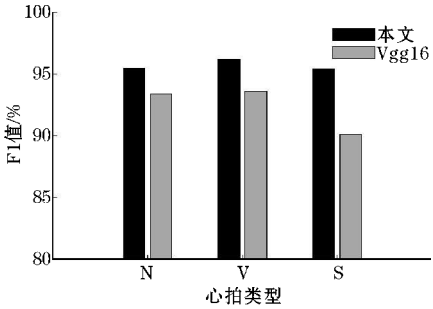


图 12 两个模型的 F1 值对比

3 讨论

提出了基于 Residual-Attention 和 LSTM 的心律失常心拍三分类模型对 3 种心拍进行分类,并且与 Vgg16 模型进行对比分析。在网络模型改进的情况

下,准确率、敏感度、精确度及F1值都有提升。残差模块内部的残差块使用了跳跃连接,缓解了深度神经网络中增加深度带来的梯度消失。直接将输入信息绕道传到输出,保护了信息的完整性,使整个网络只需要学习输入和输出差别的那一部分,简化了学习目标及难度。注意力机制能高效地考虑全局联系和局部联系,并且每一步的计算都不依赖上一步的计算结果,进行并行化处理减少模型训练时间,这在大量样本数据中有着效率优势。本文所使用的数据是长时心电数据,能够记录长时间的心电数据,能在检测时间内对各类心律失常进行检测和分析。

本文的研究方法存在只能进行三分类的局限性,未来会进行更多种类的心拍分类研究。在进一步提升准确率等性能方面,可以从优化网络的角度对准确率等性能进行提升。本文的研究在临床价值方面也有参考意义,可以辅助医生对心律不齐进行诊断,更快地帮助患者进行治疗,有效地预防和治疗因为心律不齐所引起的疾病。

## 4 结束语

提出了基于Residual-Attention和LSTM的心律失常心拍三分类模型,该模型中的残差模块缓解了深度神经网络加深带来的梯度消失,注意力机制模块并行化处理提升了效率,并且与LSTM相结合提高了分类的准确性,证明该模型具有良好的性能。此模型在心电图的分析和心律失常的研究方面具有临床参考价值。实验使用的心电信号被分三大类,未来的工作考虑研究多种类型心电信号的自动分类,进一步提高心电诊断的效率。

## 参考文献:

- [1] Hoekema R, Uijen G J H, Van Oosterom A. Geometrical aspects of the interindividual variability of multilead ECG recordings[J]. IEEE Transactions on Biomedical Engineering, 2001, 48(5): 551–559.
- [2] Yan Z, Zhou J, Wong W F. Energy efficient ECG classification with spiking neural network[J]. Biomedical Signal Processing and Control, 2021, 63: 102170.
- [3] Salem M, Taheri S, Yuan J S. ECG arrhythmia classification using transfer learning from 2-dimensional deep CNN features[C]. 2018 IEEE Biomedical Circuits and Systems Conference (BioCAS). IEEE, 2018: 1–4.
- [4] Li F, Chen K, Ling J, et al. Automatic diagnosis of cardiac arrhythmia in electrocardiograms via multi-granulation computing[J]. Applied Soft Computing, 2019, 80: 400–413.
- [5] Prakash A J, Ari S. A system for automatic cardiac arrhythmia recognition using electrocardiogram signal[M]. England: Woodhead Publishing, 2019: 891–911.
- [6] Ye C, Coimbra M T, Kumar B V K V. Arrhythmia detection and classification using morphological and dynamic features of ECG signals[C]. 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE, 2010: 1918–1921.
- [7] Essa E, Xie X. Multi-model Deep Learning Ensemble for ECG Heartbeat Arrhythmia Classification[C]. 2020 28th European Signal Processing Conference (EUSIPCO). IEEE, 2021: 1085–1089.
- [8] Kanani P, Padole M. ECG Heartbeat Arrhythmia Classification Using Time-Series Augmented Signals and Deep Learning Approach[J]. Procedia Computer Science, 2020, 171: 524–531.
- [9] Romdhane T F, Pr M A. Electrocardiogram heartbeat classification based on a deep convolutional neural network and focal loss[J]. Computers in Biology and Medicine, 2020, 123: 103866.
- [10] Kachuee M, Fazeli S, Sarrafzadeh M. Ecg heartbeat classification: A deep transferable representation[C]. 2018 IEEE International Conference on Healthcare Informatics (ICHI). IEEE, 2018: 443–444.
- [11] Guo L, Sim G, Matuszewski B. Inter-patient ECG classification with convolutional and recurrent neural networks[J]. Biocybernetics and Biomedical Engineering, 2019, 39(3): 868–879.
- [12] Izci E, Ozdemir M A, Degirmenci M, et al. Cardiac arrhythmia detection from 2d ecg images by using deep learning technique[C]. 2019 Medical Technologies Congress (TIPTEKNO). IEEE, 2019: 1–4.
- [13] 杨浩, 黄茂林, 蔡志鹏, 等. 融合CNN和BiLSTM的心律失常心拍分类模型[J]. 中国生物医学工程学报, 2020, 39(6): 719–726.
- [14] Ma C, Wei S, Chen T, et al. Integration of results from convolutional neural network in a support vector machine for the detection of atrial fibrilla-

tion [J]. IEEE Transactions on Instrumentation and Measurement,2020,70:1-10.

[15] 谢佳静,魏守水,江兴娥,等. 基于 CNN 和频率切片小波变换的 T 波形态分类[J]. 中国生物医学工程学报,2021,40(1):1-11.

[16] Mathunjwa B M,Lin Y T,Lin C H,et al. ECG arrhythmia classification by using a recurrence plot and convolutional neural network[J]. Biomedical Signal Processing and Control,2021,64:102262.

Classification of Arrhythmia Beat Model based on Residual-Attention and LSTM

XIONG Lei, HE Peiyu, FANG Ancheng, QIN Leiliang, PAN Fan

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065,China)

**Abstract:** Long term ECG is a kind of ECG that continuously records the ECG state for a long time. Arrhythmia is characterized by irregular beat frequency or abnormal waveform. Therefore, it is of great clinical significance to identify arrhythmia from long-term ECG efficiently and accurately. In order to recognize the problem from arrhythmia beats from long-term ECG, an arrhythmia beat classification model based on Residual-Attention mechanism and LSTM network is proposed. Firstly, long-term ECG signal is filtered by wavelet transform, then QRS wave algorithm is used to find the location of R-wave, and the R-wave is segmented into two-dimensional cardiogram based on the location of the peak of R-wave. Finally, it is put into Residual-Attention and LSTM network for feature extraction and classification. The accuracy of Normal、PVC and SPBclassification is 96.09% , which is 3.26% higher than the traditional Convolutional Neural Networks model. The F1 values of three classes are increased by 2.04% ,2.56% ,5.30% respectively. The comparative experimental results show that the proposed arrhythmia beat classification model based on residual attention and LSTM has better classification accuracy and F1 value than the traditional CNN model.

**Keywords:** residual;attention;long short term memory;arrhythmia;beat classification