

DOI: 10.13382/j.jemi.B2407254

使用多特征融合的心律失常分类方法*

梁国祥¹ 韩亮^{1,2}

(1. 重庆大学微电子与通信工程学院 重庆 401331; 2. 生物感知与多模态智能信息处理重庆市重点实验室 重庆 401331)

摘要: 心律失常是一种常见的心血管疾病, 它会严重影响患者的生活质量和生命安全。利用心电信号 (ECG) 进行心律失常自动分类对于其及时诊断与防治具有重要意义。为此, 提出一种使用多特征融合的心律失常分类方法。首先从去噪后的心电信号中分别提取短时傅里叶 (STFT) 特征和小波 (WT) 特征。然后将 STFT 特征输入分支聚合残差网络 (BCAR-NET) 进行特征提取, 获得其深度 STFT 特征; 将 WT 特征输入 1D-CNN 网络, 获得其深度 WT 特征; 将原始 ECG 输入 LSTM 网络, 获得其深度 ECG 特征。最后使用全连接网络将 3 种深度特征进行拼接和融合, 进而实现心律失常分类。使用 MIT-BIH 心律失常数据库进行实验, 所提出的使用多特征融合的心律失常分类方法的准确率为 98.66%, F_1 分数的宏平均为 94.22%, 优于传统心律失常分类方法。实验结果表明, 所构建的多特征融合网络有效利用了深度 STFT 特征、WT 特征和 ECG 特征之间的互补性, 提升了心律失常的分类性能。

关键词: 心律失常; 多特征融合; 分支聚合残差网络; 短时傅里叶变换; 小波变换

中图分类号: TP391; TN911.72 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Method on arrhythmia classification utilizing multi-feature fusion

Liang Guoxiang¹ Han Liang^{1,2}(1. School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 401331, China;
2. Chongqing Key Lab of Bio-perception & Multimodal Intelligent Information Processing, Chongqing 401331, China)

Abstract: Arrhythmias is a common cardiovascular disease, which seriously affects the quality of life and safety of patients. The automatic classification of arrhythmia utilizing electrocardiogram (ECG) is of great significance for timely diagnosis and prevention. An arrhythmia classification method using multi-feature fusion is proposed. Firstly, the short time Fourier transform (STFT) features and wavelet transform (WT) features are respectively extracted from denoised ECG. Then, its deep STFT features is obtained by the branch aggregated residual network (BCAR-NET) with STFT features as input, and its deep WT features is obtained by the 1D-CNN with WT features as input. Moreover, the LSTM is used to extract deep ECG features. Finally, a fully connected network is used to concatenate and fuse the three deep features, then arrhythmia classification is realized. The proposed arrhythmia classification method is evaluated on the MIT-BIH arrhythmia dataset. The accuracy of the proposed method is 98.66%, and the macro-average F_1 score is 94.22%, which is better than traditional arrhythmia classification methods. The experimental results show that the constructed multi-feature fusion network improves the classification performance of arrhythmia by effectively exploiting the complementarity between deep STFT features, WT features, and ECG features.

Keywords: arrhythmia; multi-feature fusion; BCAR-NET; short time Fourier transform; wavelet transformation

0 引言

心血管疾病是威胁人类健康的重要疾病^[1]。心电图通过测量心脏的电活动来监测和识别心律失常^[2],具有非侵入性的特点,故不会对身体造成损害,可反复进行,便于长时间持续监测。若通过医生人工分析心电信号(electrocardiogram, ECG)来判断病人是否有心律失常,则会耗时费力,且还有一定概率误诊。而通过人工智能方法进行心律失常自动识别,不仅准确率高,而且速度快,省时省力。

心律失常有两大类常用分类方法,分别为机器学习和深度学习。机器学习包括特征提取和构建分类器两个阶段。其常见特征包括统计特征、时频域特征、形态学特征、变换域特征等。常用特征提取方法有形态特征^[3]、小波变换(wavelet transformation, WT)^[4]和高阶特征统计^[5]等。K近邻(K-nearest neighbor, KNN)^[6]、随机森林(random forest, RF)^[7]、决策树^[8]和支持向量机(support vector machine, SVM)^[9]等机器学习方法均已被用于构建 ECG 分类器。尽管传统机器学习方法在心律失常自动分类中显示出较为理想的结果,且特征可解释性好,但其分类结果很大程度上取决于所选择的特征,且特征需要手动设计和提取,具有一定的局限性。

近年来,由于其强大的自学习能力和泛化能力,深度学习在图像识别、自然语言处理和计算机辅助医疗等各个领域得到了广泛应用。众多基于深度学习的心律失常分类方法被提出,如一维卷积神经网络(1D-CNN)^[10]、长短期记忆网络(long short-term memory, LSTM)^[11]、残差网络^[12],以及 CNN 与 LSTM 组合^[13]、CNN 与 Transformer 结合^[14]等,均取得了良好的分类结果。将时序信号变换为二维图像,能反映原始信号更多潜在的特征,常用方法有短时傅里叶变换(short time Fourier transform, STFT)、递归图(recurrence plot, RP)、格拉米角场和马尔科夫变迁场等,将 ECG 使用不同方法转换为二维图像并结合 2D-CNN 的方法已成功实现心律失常分类^[15]。

现有心律失常分类方法常使用 ECG 的某一种特征,而心电信号复杂多变,单一特征难以完全描述其特性且抗干扰能力差。多特征融合方法能够综合利用各种信息之间的互补性,有效提升分类效果。将数据用不同方法进行变换可以使其包含不同的特征信息,不同特征提取网络能够提取不同的深度特征。本文构建的多特征融合网络将 ECG 进行 STFT 和 WT 后分别用不同的深度网络提取得到深度 STFT 特征和 WT 特征,再使用 LSTM 提取深度 ECG 特征,最后使用全连接网络将 3 种深度特征进行融合,实现心律失常分类。

1 多特征融合网络

由于心电图中反映各种病症的结构复杂多变,单一领域的特征很难完全反映出其中的变化,因此在对心律失常进行分类时,使用多特征融合往往可以取得更佳的效果。为此,本文提出了如图 1 所示的多特征融合网络,对 ECG 去噪后分别进行 STFT 和 WT,获得其 WT 特征和 STFT 特征;将 STFT 特征和 WT 特征分别输入分支聚合残差网络(BCAR-NET)和 1D-CNN 网络进行特征提取;将去噪后的原始 ECG 输入 LSTM 网络进行特征提取。然后对提取出来的 3 种特征拼接后,再通过一个 Dropout 层和两个全连接层进行融合,最后利用 Softmax 层进行心律失常分类。

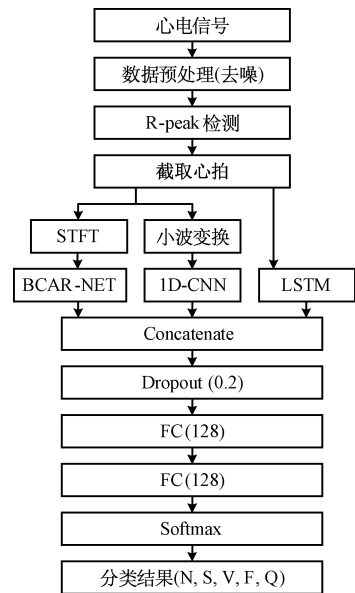


图 1 多特征融合网络

Fig. 1 Multi-feature fusion network

1.1 基于 STFT 的分支聚合残差网络

STFT 通过在时域引入窗函数,将整个时域信号分解为多个时段信号。STFT 频谱图计算公式如式(1)所示。

$$|STFT(t, \omega)|^2 = \left| \int_{-\infty}^{+\infty} S(\tau)g(\tau - t)e^{-j\omega\tau} d\tau \right|^2 \quad (1)$$

式中: $s(t)$ 表示信号, $g(t)$ 表示窗函数, t 和表示时刻 $g(\tau - t)$ 表示中心位于时刻 t 的窗函数, ω 表示频率。

残差网络中的残差结构阻止了梯度消失,使得残差网络在训练过程中能更好地传播梯度,从而提高模型的性能。为此,本文构建一种具有残差结构的分支聚合残差网络(BCAR-NET),如图 2 所示。

作为一种改进的增强型 CNN,它由两个主要部分组成:并行路径和 BCAR 模块。首先对信号进行 STFT,变

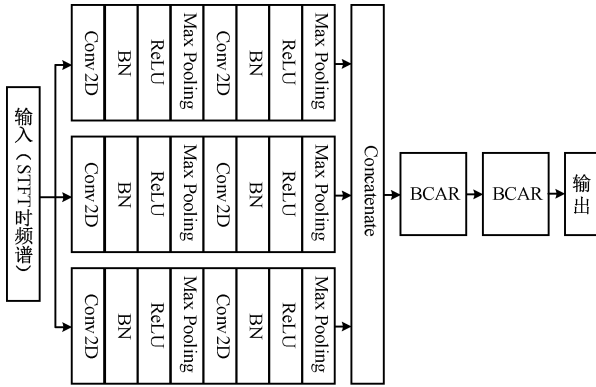


图 2 分支聚合残差网络

Fig. 2 BCAR-NET

换后的每一列表示一个窗下的频域信号,每一行表示在窗滑动过程中不同时间下相似频率能量的变化情况,行列联合起来的二维矩阵包含着其时频特征。因此,设计了 3 条并行路径来分别处理这 3 种特征。这 3 条路径都通过卷积、激活函数和最大池化来实现特征提取。唯一的区别是卷积核的大小,分别用 5×1 和 1×5 来提取每列和每行的特征, 5×5 的对称卷积核来提取时频特征。并行路径网络参数如表 1 所示。

在使用并行路径提取特征后,将获得的高级特征连接起来,然后输入到网络的 BCAR 模块。BCAR 模块是 BCAR-NET 的主要组成部分,如图 3 所示。

与传统残差模块不同,该模块用 3 个平行的相同拓扑结构代替残差模块的单路径卷积。整个模块形成了一个

表 1 BCAR-NET 并行路径网络参数

Table 1 Parallel path network parameters of BCAR-NET

支路 1			支路 2			支路 3		
层	核大小	通道数	层	核大小	通道数	层	核大小	通道数
Conv	5×1	64	Conv	1×5	64	Conv	5×5	64
BN			BN			BN		
ReLU			ReLU			ReLU		
Max-pool	2×2		Max-pool	2×2		Max-pool	2×2	
Conv	5×1	64	Conv	1×5	64	Conv	5×5	64
BN			BN			BN		
ReLU			ReLU			ReLU		
Max-pool	2×2		Max-pool	2×2		Max-pool	2×2	

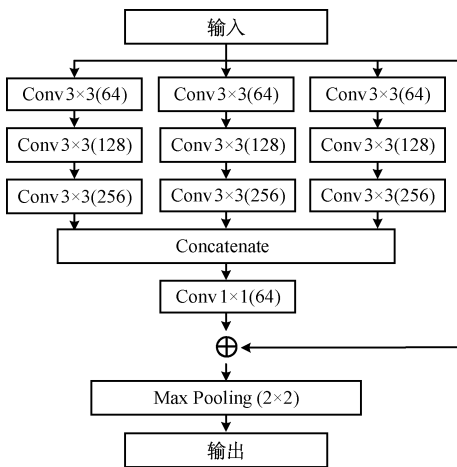


图 3 BCAR 模块

Fig. 3 BCAR model

学习特征。在聚合时,将每个子空间的特征合并。这允许网络从不同的子空间获得特征信息,并从多个角度理解特征。

1.2 基于 WT 的 CNN 特征提取网络

WT 是最常用的时频分析工具^[16],常被用于心电信号分析,它使用一系列小波基函数对信号进行分解,获得一系列的小波系数,包含其时频域信息。给定某时刻 t 的信号 $x(t)$, WT 表示为:

$$C_a(b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \varphi\left(\frac{t-b}{a}\right) dt \quad (2)$$

其中, a 为尺度参数; b 为平移参数; $C_a(b)$ 为信号 $x(t)$ 的 WT 变换; $\varphi(t)$ 为小波基函数。

本文将 WT 后得到的小波系数作为 WT 特征输入 1D-CNN 网络进行特征提取,其网络模型如图 4 所示,网络参数如表 2 所示。




图 4 1D-CNN 特征提取网络

Fig. 4 1D-CNN feature extraction network

拆分-卷积-聚合的体系结构。高级特征信息在输入到 BCAR 块后被划分为 3 个特征子空间,然后通过一系列深度逐渐增加的卷积层来实现特征学习。之后,输出将被聚合后进行下一步处理。BCAR 模块继承了残差块可以避免网络退化的优点。分割时,将原始特征空间划分为 3 个子空间。每条路径都在自己的子空间中

表 2 1D-CNN 特征提取网络参数

Table 2 1D-CNN feature extraction network parameters

网络层	核大小	通道数
Conv	5	64
ReLU		
Maxpool	2	
Conv	3	64
ReLU		
Maxpool	2	
Conv	3	64
ReLU		
Maxpool	2	
Conv	3	64
ReLU		
Maxpool	2	

1.3 基于 ECG 的 LSTM 网络

LSTM 是循环神经网络的变体,能防止梯度消失或梯度爆炸的问题,比 RNN 更能捕捉到序列中的依赖关系。为了有效提取出 ECG 中的特征,本文用两个连续的 LSTM 层对其进行特征提取。其中每个 LSTM 层包含 32 个神经元,如图 5 所示。




图 5 LSTM 特征提取网络

Fig. 5 LSTM feature extraction network

2 实验结果与分析

2.1 实验数据

本文实验数据来源于 MIT-BIH^[17] 心律失常数据库,其采样频率为 360 Hz。它包括 47 名受试者的 48 次双导联记录。每个记录包含 650 000 个采样点。在本文中总共使用了 44 个心电图记录,其余 4 个记录由于受试者佩戴起搏器可能对实验产生影响而被丢弃。

根据美国医疗器械进步协会制定的 AAMI 标准将心律失常信号划分为 5 类:非异位搏动(N)、室上异位搏动(S)、室性异位搏动(V)、融合搏动(F)和未知搏动(Q)。本文选取两个导联中样本数量较多且被使用较多的 MLII 导联进行实验,对每类心拍,均按照相同比例划分训练集、验证集和测试集,其统计信息如表 3 所示。

表 3 实验数据

Table 3 Experimental data

类别	训练集	验证集	测试集
N	24 560	6 141	13 158
S	1 006	252	539
V	3 449	862	1 848
F	445	111	239
Q	2 166	541	1 160
合计	31 626	7 907	16 944

本文所有实验采用的计算机的 CPU 为 Intel(R) Xeon(R) CPU E5-4650 v3@2.10 GHz 处理器,内存为 32 G,显卡为 NVIDIA GeForce RTX 3060,显存为 12 GB,操作系统为 Window10,编程工具为 Python,深度学习框架为 TensorFlow。

2.2 性能评价方法

本论文采用精确率(precision, PRE)、召回率(recall, REC)和 F_1 分数评价单个类别分类性能^[18];使用准确率(accuracy, ACC),精确率的算数宏平均值 PRE_M , 召回率的算数宏平均值 REC_M 和 F_1 分数的算数宏平均值 F_{1M} 评价整体分类性能^[2]。

2.3 本文方法的实验结果与分析

1) 消融实验

本文选择如图 1 所示的 3 支路特征融合的方法进行心电信号分类,为了进一步评估本文方法的有效性,本文对多特征融合的多条特征支路选择不同支路进行了消融实验,采用 2.2 节所述方法进行分类性能评价,其实验结果如表 4 所示,其中 I、II、III 分别代表 LSTM 支路、1D-CNN 支路和 BCAR-NET 支路。

表 4 消融实验结果

Table 4 Ablation experiment results

特征数据	ACC	F_{1M}	REC_M	PRE_M
I	0.979 1	0.918 4	0.888 1	0.956 7
II	0.977 5	0.913 4	0.890 8	0.943 4
III	0.984 1	0.935 1	0.907 7	0.969 4
I+II	0.981 8	0.924 8	0.897 1	0.958 2
I+III	0.984 4	0.934 1	0.906 5	0.967 2
II+III	0.983 3	0.936 9	0.925 3	0.949 6
I+II+III	0.986 6	0.942 2	0.923 7	0.963 4

从表 4 可知,3 条支路特征融合的方法其准确率和 F_{1M} 优于其他单支路或任意两支路融合,且 F_{1M} 提升较多,这说明本文方法是有效的,不同类型的特征具有一定的互补性。本文方法能有效提升心律失常分类性能。

2) 转换方法对比实验及二维分类网络对比实验

为了验证本文提出的 BCAR-NET 的有效性,并选择出最优的二维变换方法和二维特征提取网络,本文做了如下两组对比实验。

第 1 组:分别用 STFT、RP、格拉米角场(GAF)和马尔

科夫变迁场(MTF)4种方法将一维心拍信号变换为二维信号,再使用BCAR-NET进行特征提取后用softmax进行分类。采用2.2节所述方法进行分类性能评价,其实验结果如表5所示。

表5 一维到二维转换方法对比实验结果

Table 5 Comparison of different 1D to 2D transformation method

方法	ACC	F_{1M}	REC_M	PRE_M
STFT+BCAR-NET	0.984 1	0.935 1	0.907 7	0.969 4
RP+BCAR-NET	0.982 5	0.925 0	0.890 1	0.971 7
MTF+BCAR-NET	0.978 5	0.915 3	0.891 9	0.945 0
GAF+BCAR-NET	0.978 7	0.914 2	0.893 4	0.938 3

第2组:选择第1组实验中表现最好的一种转换方法将心拍信号转为二维信号,然后分别用BCAR-NET、2D-CNN、ResNet34及DenseNet进行特征提取和分类,采用2.2节所述方法进行分类性能评价,其实验结果如表6所示。

表6 二维分类网络对比实验结果

Table 6 Comparison of different 2D classification network

方法	ACC	F_{1M}	REC_M	PRE_M
STFT+2D-CNN	0.98 11	0.921 0	0.884 1	0.968 7
STFT+ResNet34	0.982 1	0.930 1	0.898 3	0.969 8
STFT+DenseNet	0.983 1	0.928 7	0.913 0	0.950 9
STFT+BCAR-NET	0.984 1	0.935 1	0.907 7	0.969 4

从表5的结果可以看出在STFT、RP、MTF和GAF4种转换方法中,STFT+BCAR-NET的ACC、 REC_M 、 F_{1M} 和 PRE_M 指标均高于其他3种方法,分类综合效果最好。从表6的实验结果中可以看出STFT+BCAR-NET的ACC、 PRE_M 和 F_{1M} 指标均高于其他3种方法,分类效果优于其他3种二维分类方法。故选择STFT+BCAR-NET作为二维特征提取支路。

3) 小波基与小波级数的选取

使用不同小波和不同分解级数,会得到不同的分类结果。为了选出最优小波基函数和分解尺度,本文选择多个小波基进行不同尺度的变换。将获得的小波系数作为数据输入图4的CNN特征提取及分类网络进行分类,分解级数为1~4级,性能评价方法为2.2节中描述的整体分类性能评价指标,其实验结果表7所示。

从表7结果中可以看出,在不同的小波基和不同的分解尺度下,其分类性能也有所不同。其中,选择Db4小波进行2尺度分解后其ACC,和 F_{1M} 指标均达到最高,其分类综合效果最好。故后续实验均选择Db4小波进行2尺度分解得到WT特征。

4) 一维心拍信号分类常用方法对比实验

为了选择出提取一维心拍信号时域特征的有效方

表7 小波基与分解级数对比实验结果

Table 7 Comparison of different wavelet base and decomposition level

小波基	分解级数	ACC	F_{1M}	REC_M	PRE_M
bior4.4	1	0.972 9	0.896 8	0.860 3	0.945 6
	2	0.977 4	0.907 6	0.879 0	0.943 0
	3	0.971 5	0.891 5	0.858 3	0.934 8
	4	0.976 6	0.891 8	0.840 3	0.975 9
Coif8	1	0.974 9	0.897 0	0.876 4	0.922 9
	2	0.975 5	0.901 3	0.874 2	0.935 2
	3	0.975 9	0.900 8	0.872 7	0.937 2
	4	0.973 1	0.891 7	0.852 2	0.946 9
Sym8	1	0.975 6	0.893 8	0.857 8	0.947 8
	2	0.976 9	0.906 1	0.880 6	0.943 8
	3	0.975 6	0.895 7	0.849 1	0.965 6
	4	0.975 7	0.896 6	0.851 5	0.963 9
Db4	1	0.976 2	0.908 4	0.892 3	0.926 7
	2	0.977 5	0.913 4	0.890 8	0.943 4
	3	0.977 3	0.905 8	0.861 3	0.967 2
	4	0.976 9	0.900 0	0.857 7	0.961 3

法,本文选择常用的1D-CNN、LSTM和1D-CNN和LSTM结合的方法进行对比实验,采用2.2节所述方法进行性能评价,其实验结果如表8所示。

表8 一维心拍信号分类常用方法对比实验结果

Table 8 Comparison of different 1D heartbeat classification method

分类方法	Acc	F_{1M}	REC_M	PRE_M
1D-CNN	0.973 9	0.893 3	0.855 8	0.943 1
LSTM	0.979 1	0.918 4	0.888 1	0.956 7
1DCNN+LSTM	0.976 8	0.911 2	0.883 6	0.944 5

从表8可知,LSTM对心拍信号分类的各项评价指标均高于另外两种方法,故后续实验选择LSTM来对一维心拍信号进行特征提取。

5) 与常用方法对比实验

为了进一步评价本文提出的多特征融合网络用于心电信号分类的先进性,本文进行如下对比实验。

方法1:分别使用SVM^[9]、1D-CNN^[10]、LSTM^[11]直接对去噪后的一维心拍信号进行分类。

方法2:参照文献[19],利用多支路1D-CNN对心拍信号进行分类。

方法3:参照文献[20],先使用STFT得到心拍信号的时频谱,再使用2D-CNN对其进行分类。

方法4:参照文献[2],用WT和递归图变换得到小波递归图,然后用VIT进行分类。

采用2.2节所述方法进行性能评价,其实验结果如表9所示。

从表9的结果中可以看出,本文提出的多特征融合

表 9 心电信号分类方法性能对比

Table 9 Comparison of different ECG classification method

方法	ACC	F_{1M}	REC_M	PRE_M
SVM ^[9]	0.965 7	0.866 9	0.822 3	0.932 4
1D-CNN ^[10]	0.973 9	0.893 3	0.855 8	0.943 1
LSTM ^[11]	0.979 1	0.918 4	0.888 1	0.956 7
Wang ^[19]	0.980 5	0.918 0	0.903 5	0.934 3
STFT+2D-CNN ^[20]	0.981 1	0.921 0	0.884 1	0.968 7
小波递归图+VIT ^[2]	0.984 7	0.933 6	0.915 6	0.954 8
本文方法	0.986 6	0.942 2	0.923 7	0.963 4

网络的 ACC , F_{1M} , REC_M 和 PRE_M 均明显高于 SVM、1D-CNN 和 LSTM3 种常用方法, ACC 、 F_{1M} 、 REC_M 明显高于 STFT+2D-CNN 和 Wang 的多支路 1D-CNN 方法, 略微高于小波递归图+VIT 方法。说明本文提出的多特征融合网络能有效的进行心律失常分类, 且优于常用方法。STFT+2D-CNN 和小波递归图+VIT 得到的 ACC 、 F_{1M} 、 REC_M 和 PRE_M 明显高于 1D-CNN, 说明将一维时序信号变换为二维时频域信号能反映出信号所具有的更多潜在的特征, 更利于后续信号的分类。本文的多特征融合方法相较于单特征分类方法, 有效利用了多种特征之间的互补性, 提升了分类效果。

3 结 论

本文提出一种基于多特征融合的心律失常分类方法, 通过不同的网络模型自动学习多种 ECG 特征并进行心律失常分类。针对 MIT-BIH 心律失常数据库中的五种心律失常类型分类, 该方法的准确率为 98.66%, 其 F_1 分数的算数宏平均值为 94.22%, 能有效识别心律失常类型, 其性能明显优于 SVM、1D-CNN 和 LSTM 等传统心电信号分类方法, 也优于 STFT+2D-CNN 和小波递归图+VIT 方法。综上所述, 本文构建的多特征融合网络能有效利用各种特征之间的互补性, 提升分类效果, 对心律失常进行有效分类。

参考文献

[1] MCNAMARA K, ALZUBAID H, JACJON J K. Cardiovascular disease as a leading cause of death: How are pharmacists getting involved? [J]. Integrated Pharmacy Research and Practice, 2019, 8:1-11.

[2] 韩亮, 罗统军, 蒲秀娟, 等. 使用多尺度递归图和视觉转换器的心律失常分类[J]. 仪器仪表学报, 2022, 43(12): 149-157.

HAN L, LUO T J, PU X J, et al. Arrhythmia classification using multiscale recurrence maps and visual converters[J]. Chinese Journal of Scientific Instrument, 2022, 43(12):149-157.

[3] MOGHADAM S, ASL B. Automatic diagnosis and localization of myocardial infarction using morphological features of ECG signal[J]. Biomedical Signal Processing and Control, 2023, 83:104671.

[4] BOUJNOUNI E, HAROUCHI B, TALI A, et al. Automatic diagnosis of cardiovascular diseases using wavelet feature extraction and convolutional capsule network[J]. Biomedical Signal Processing and Control, 2023, 81: 104497.

[5] CHAUHAN C, TRIPATHY, M. Patient specific higher order tensor based approach for the detection and localization of myocardial infarction using 12-lead ECG[J]. Biomedical Signal Processing and Control, 2023, 83: 104701.

[6] YU J, WANG X, CHEN X, et al. Automatic premature ventricular contraction detection using deep metric learning and KNN[J]. Biosensors, 2021, 69:1-22.

[7] LI R, ZHANG W, SHEN S, et al. An intelligent heartbeat classification system based on attributable features with AdaBoost + Randomforest algorithm [J]. Journal of Healthcare Engineering, 2021: 9913127.

[8] KUMARI L, SAI Y P. Classification of ECG beats using optimized decision tree and adaptive boosted optimized decision tree [J]. Signal Image and Video Process, 2022, 16 (3): 695-703.

[9] REDOUANE L, ZIDELMALA Z, ABDESLAM D O. Optimized time-frequency features and semi-supervised SVM to heartbeat classification [J]. Signal Image and Video Processing, 2020, 14(12):1471-1478.

[10] HANNUN A Y, RAJPURKAR P, HAGHPANAHI M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network [J]. Nature Medicine, 2019, 25(1): 65-69.

[11] GAO J, ZHANG H, LU P, et al. An effective LSTM recurrent network to detect arrhythmia on imbalanced ECG dataset [J]. Journal of Healthcare Engineering, 2019: 6320651.

[12] LI Z, ZHOU D, WAN L, et al. Heartbeat classification using deep residual convolutional neural network from 2-lead electrocardiogram[J]. Journal of Electrocardiology, 2020, 58: 105-112.

[13] CHEN C, HUA Z, ZHANG R, et al. Automated arrhythmia classification based on a combination network of CNN and LSTM[J]. Biomedical Signal Processing and Control, 2020, 57: 101819.

[14] XIA Y, XIONG Y Q, WANG K. A transformer model blended with CNN and denoising autoencoder for inter-

patient ECG arrhythmia classification [J]. Biomedical Signal Processing and Control, 2023, 86:105271.

- [15] ZEESHAN A, ANIKA T, LING G, et al. ECG heartbeat classification using multimodal fusion[J]. IEEE Access, 2021, 9: 100615-100626.
- [16] 王东庆, 周建华, 伏云发. EWT算法在单通道脑电信号眼电伪迹自动去除中的研究[J]. 电子测量与仪器学报, 2023, 37(2): 121-129.
WANG D Q, ZHOU J H, FU Y F. Empirical wavelet transform algorithm for automatic removal of EOG artifacts from single-channel EEG signals [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 121-129.
- [17] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. IEEE Engineering in Medicine and Biology Magazine, 2001, 20(3): 45-50.
- [18] BAHRAMI M, FOROUZANFAR M. Sleep apnea detection from single-lead ECG; A comprehensive analysis of machine learning and deep learning algorithms [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 4003011.
- [19] WANG H R, SHI H T, CHEN X J, et al. An improved convolutional neural network based approach for automated heartbeat classification[J]. Journal of Medical Systems, 2020, 44:35.
- [20] ULLAH A, ANWAR S M, BILAL M, et al. Classification of arrhythmia by using deep learning with 2D ECG spectral image representation [J]. Remote Sensing, 2020, 12(10): 1685-1699.

作者简介



梁国祥, 2021年于重庆大学获得学士学位, 现为重庆大学微电子与通信工程学院硕士研究生, 主要研究方向为生物医学信号处理。

E-mail: 202112021053t@stu.cqu.edu.cn

Liang Guoxiang received his B. Sc. degree in 2021 from Chongqing University. Now he is a M. Sc. candidate in the School of Microelectronics and Communication Engineering at Chongqing University. His main research interest includes biomedical signal processing.



韩亮(通信作者), 分别于1997年、2004年、2008年于重庆大学获得学士学位、硕士学位和博士学位, 2013年7月至2015年7月于美国宾夕法尼亚州立大学磁共振研究中心做访问学者, 现为生物感知与多模态智能信息处理重庆市重点实验室副主任, 重庆大学副教授, 主要研究方向为信号处理和图像处理。

E-mail: hanliangaa@cqu.edu.cn

Han Liang (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Chongqing University in 1997, 2004 and 2008, respectively. He worked as visting scholar in NMR research center, Penn State University, USA from July 2013 to July 2015. Now he is the vice director of Chongqing Key Lab of Bio-Perception & Multimodal Intelligent Information Processing and an associate professor in Chongqing University. His main research interests include signal processing and image processing.