

DOI:10.3969/j.issn.1005-202X.2023.08.014

医学信号处理与医学仪器

基于心电长时RR间期序列的心房颤动检测

方东申¹, 叶琪瑶¹, 石少波², 刘涛¹, 李立¹

1. 武汉大学电子信息学院, 湖北 武汉 430072; 2. 武汉大学人民医院, 湖北 武汉 430060

【摘要】为解决当前深度学习模型进行心房颤动检测泛化能力差的问题,提出了一种基于长时RR间期的心房颤动检测算法。基于心电信号的一维时序特性以及心房颤动的特殊RR间期,设计了CNN与LSTM结合的深度学习模型,深度挖掘长时RR序列的时间与空间特征,使得它能够在未知数据集上取得良好的结果。使用MIT-BIH心房颤动数据集的全部可用样本划分训练、验证与盲法测试集(3名个体)。通过10倍交叉验证后在盲法测试集上的准确率为99.11%、敏感性为98.86%、特异性为99.47%、阳性预测率为99.62%、 F_1 分数为99.24%。模型与现有方法进行了对比,证实所提模型用于心房颤动检测的可行性,能够有效识别出未知数据集的心房颤动病例,泛化能力强。

【关键词】深度学习;心房颤动;心电信号;RR间期;卷积神经网络;长短期记忆网络

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2023)08-1009-07

Atrial fibrillation detection based on long-term RR interval sequences of electrocardiogram

FANG Dongshen¹, YE Qiyao¹, SHI Shaobo², LIU Tao¹, LI Li¹

1. School of Electronic Information, Wuhan University, Wuhan 430072, China; 2. Renmin Hospital, Wuhan University, Wuhan 430060, China

Abstract: An atrial fibrillation detection algorithm based on long-time RR interval is proposed to solve the problem of the poor generalization ability of current deep learning models for atrial fibrillation detection. Based on the one-dimensional timing characteristics of electrocardiogram signals and the specific RR interval of atrial fibrillation, a deep learning model combining convolutional neural network and long short-term memory network is designed to deeply mine the temporal and spatial characteristics of long-term RR sequences, which enables the model to perform well on unknown data sets. All available samples of the MIT-BIH atrial fibrillation data set are divided into training, validation, and blindfold detection test sets (3 subjects). After 10-fold cross-validation, the accuracy, sensitivity, specificity, positive prediction rate, and F_1 score on the blind detection test set are 99.11%, 98.86%, 99.47%, 99.62%, and 99.24%, respectively. The comparison with the existing methods confirms the feasibility of the proposed model for atrial fibrillation detection. The proposed method can effectively identify atrial fibrillation cases from unknown data sets and has a high generalization ability.

Keywords: deep learning; atrial fibrillation; electrocardiogram signal; RR interval; convolutional neural network; long short-term memory network

前言

心房颤动是最常见的心律失常,它主要多发于老年人,虽然心房颤动本身很少致命,但是它会增加心房颤动相关并发症如心力衰竭和血栓栓塞的风

险,进而导致发病率与致死率的提高^[1]。据报道,在75岁患者中,心房颤动的患病率通常为6%~8%,全球预计有3 350万人受到影响^[2]。心房颤动也是心脏血栓的常见来源和缺血性中风的常见原因。

对于心房颤动的检测主要分为特征提取与特征分类。早期对于特征提取主要使用传统信号处理方法对ECG信号进行提取,包括主成分分析^[3]、傅里叶变换^[4]、小波变换^[5]等。特征分类首先通过特征提取从而提取所需要的特征,之后将特征输入到机器学习方法中,如随机森林^[6]、SVM^[7]、多层感知机^[8]、神经网络^[9]等。传统信号处理方法具有可解释的优点,但是识别的准确率比较低,同时容易受到噪声与设

【收稿日期】2023-02-16

【基金项目】国家自然科学基金(81800447)

【作者简介】方东申,硕士研究生,研究方向:医学信号处理、深度学习, E-mail: fangdongshen@whu.edu.cn

【通信作者】李立,博士,副教授,研究方向:医学影像大数据与人工智能、医学信号检测、识别、处理与分析, E-mail: LL@whu.edu.cn

备的影响,大多数情况需要人的干预,对于不同人的泛化能力差。

随着人工智能和深度学习的发展,许多学者将深度学习模型应用于心房颤动检测中,以解决传统方法的缺点。深度学习模型不同于传统方法的地方在于,它可以通过多个处理层将原始数据进行逐层抽象,得到更高层次的特征表达,从而大大提高模型的分类精度。相较于传统机器学习算法,深度学习模型可以克服输入输出相互独立的局限性,尤其在有足够充分的训练样本的情况下表现更加优异。心房颤动心电图呈现出以下两个特点:(1)P波消失,代之以不规则的心房颤动波,即f波;(2)RR间期不等,QRS波电压不等,可有心室融合波。因此许多学者的研究围绕这两个特点划分样本集。Ladavich等^[10]使用高斯混合模型对P波提取的特征构建特征空间,以实现心房颤动的分类,取得了良好效果。Maji等^[11]使用检验模态分解方法提取P波分量的高阶统计矩以及其他参数,并在IMF4上取得了良好的灵敏度效果。Babaeizadeh等^[12]利用RR间隔进行心房颤动检测,并结合P波分析提高了算法的准确度。但是心房活动中P波或f波属于微弱信号,检测特征点会比较困难,而且在动态ECG信号中,极易受到噪声干扰的影响。Li等^[13]使用RR间期信息熵、RR间期差概率密度分布和空白窗比率特征进行心房颤动分类,实现了95.30%的灵敏度、96.30%的特异度、95.90%的准确率。Xia等^[14]报道将一维ECG信号通过短时傅里叶变换以及平稳小波变化变成二维信号,分别输入卷积神经网络(CNN)模型,之后再通过全连接层连接,他们提出的方法不需要检测P峰和R峰,就能够准确识别心房颤动。陈志博等^[15]使用多种方法提取RR间期的多种特征,并将这些特征输入SVM实现对心房颤动的自动检测。Fan等^[16]提出一种基于CNN的AF筛选框架(FRM-CNN),使用ECG节律特征与形态特征作为输入。Fujita等^[17]提出8层的CNN模型用于检测心房颤动与扑动,所提出的模型只需要基本的数据归一化即可使用。刘学森等^[18]通过信息熵这种理念,提取出两个方面的特征:RR间期不规则、P波缺失,并融合这两个特征,利用支持向量机以及融合特征完成对心房颤动的自动检测,并在实验中取得了良好的效果。顾佳艳等^[19]通过结合深度残差网络与双向长短时记忆网络进行心电图特征提取,之后通过多头注意力机制提取以及级联多维特征,获得了0.861的心房颤动分类精度。

虽然深度学习已经广泛应用于心房颤动检测中,但是目前市面上出现的关于心房颤动检测的产品却几乎没有,主要原因在于目前提出的模型对于

不同个体识别的泛化能力较差。本文提出了一种基于长时RR间期的CNN与长短时记忆网络(LSTM)结合的心房颤动检测算法,对心房颤动类(AF)、非心房颤动类(N)进行分类,并利用MIT-BIH心房颤动数据库中3名未在训练集中暴露的个体作为测试集,进行盲法检测,测试此模型在未知样本与个体上的效果。

1 相关技术及本研究方法

1.1 CNN

传统神经网络中的每个神经元都连接到相邻层中的每个神经元,因此无法利用数据中呈现的任何空间或时间结构。CNN利用局部连接、权值共享、多核卷积、池化等4个手段大大降低了参数的数目,使得网络的层数可以变得更深,并且能够合理地隐式地提取特征^[20]。

CNN有3个关键概念,分别为感受野、权重分配、池化。在神经网络中,首个隐藏层所有神经元连接的输入神经元仅限于1个小区域,该区域被称为感受野。每个连接都有1个对应的权重,而每个神经元也有1个整体偏差,它们共同作用于感受野内的输入神经元。随后,窗口沿着整个输入序列滑动,使得隐藏层中的每个神经元都能够学习分析输入序列的特定部分。感受野的大小或长度被称为核大小 k_{size} 。相较于传统神经网络,CNN采用一组共享的权重和单个偏置代替为每个神经元学习新的权重和偏置,这被称为权重共享。

CNN模型主要有3种层结构(图1)。(1)卷积层:通过设计特定的滤波器(filter,也称为kernel),与图片进行卷积,可以识别出图片中的某些特征,如边界,从而实现边界检测(edge detection)等功能。滤波器对于原输入图片来说,就是个特征探测器,它的元素的值通过训练得到。(2)池化层:池化又称亚采样或下采样,降低了每个特征映射的维度,但仍保留了最重要的信息,并降低过拟合风险。(3)全连接层:表示上一层的每一个神经元,都与下一层的每一个神经元是相互连接的,使用SoftMax激活函数作为输出层,加入全连接层也是学习特征之间非线性组合的有效办法。

1.2 LSTM

循环神经网络(RNN)源自1982年Hopfield^[21]提出的霍普菲尔德网络。不同于CNN结构由输入到输出端是线性的,节点之间无连接,RNN网络可以记住之前的信息并通过前面的信息影响后面节点的输出,因此RNN一般用于自然语言处理中文本预测,如一段话通过前面的信息预测后面的信息。LSTM是




图1 CNN网络的结构与卷积、感受野、池化特性

Figure 1 CNN network structure and its convolution, receptive field, and pooling characteristics

RNN的一种,于1997年提出,LSTM解决了RNN中长期依赖问题,LSTM被广泛应用于时间序列中^[22]。LSTM的结构如图2所示。




图2 LSTM网络的结构,它包含输入门、输出门和遗忘门

Figure 2 LSTM network containing input, output, and forget gates

LSTM包含单元状态和(1)输入门 i_t :决定当前时刻网络的输入数据有多少需要保存到单元状态;(2)输出门 o_t :控制当前单元状态有多少需要输出到当前的输出值;(3)遗忘门 f_t :决定上一时刻的单元状态有多少需要保留到当前时刻。输入门、输出门、遗忘门是3个sigmoid神经元,其输出为“0”或“1”,表示某项功能的“关闭”或“开启”。与RNN一样,其输入是当前时刻的输入与前一时刻隐藏层输出的整合。它们在时间 t 上的激活函数为:

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

$$i_t = \sigma(W[x_t, h_{t-1}] + b_i) \quad (2)$$

$$o_t = \sigma(W[x_t, h_{t-1}] + b_o) \quad (3)$$

其中, x_t 为时间 t 时刻的输入, h_{t-1} 为时间 t 前一个时刻的输出, C_{t-1} 为时间 t 前一个时刻单元状态, W 为权重向量, b 是偏置向量。 σ 为一个sigmoid函数,决定了时间 t 时有多少个上一时刻的单元状态得到保留。输入门使用tanh函数作为激活函数。其单元状态 C_t 可通过以下等式得到计算:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W[x_t, h_{t-1}] + b_c) \quad (4)$$

最后,输出 h_t 的计算为:

$$h_t = \tanh(C_t) \cdot o_t \quad (5)$$

2 结合CNN与LSTM的早期心房颤动检测算法

2.1 数据来源与数据预处理

本文的数据来自于MIT-BIH心房颤动数据库(MIT-BIH Atrial Fibrillation Database),数据库包括25例心房颤动(阵发性颤动)的受试者的长期ECG记录。其中23例数据包括两个心电图(ECG)信号,每个数据集的持续时间为10 h,包含两个以250 Hz采样的ECG信号,带有AF注释。这些记录还包含由专业临床医生手动执行的搏动注释和节律注释。本文选取23例包括两个ECG信号的数据进行心房颤动的检测。

心脏以有规律的方式收缩,将血液泵送到全身。在心肌收缩时,心脏产生微弱的电流传导至体表,通过测量不同部位电极的电位变化获得ECG。ECG可以显示心跳的异常节律和活动,诊断心脏病、心肌梗死、冠心病、糖尿病、高血压等疾病,并作为冠心病、心血管疾病和充血性心力衰竭的预测指标。早期发现这些疾病可以降低中风和猝死的风险。ECG对预测短期和长期结果都很重要,对于患有心肌梗死的患者,越早发现心律异常,就越有可能避免生命和康复的威胁。ECG具有明显的周期性,一个完整的ECG信号包括P波、之后为QRS波,再经过ST段,到达T波。因为本文主要提取信号中的R峰,因此只需要对信号进行简单的滤波处理即可,对包含噪声的ECG信号进行离散小波变换,小波基选择db5,分解为5级小波系数,去除最低系数与最高系数,对其他系数进行小波重构即可得到预处理后的ECG信号。

此外,在数据的基础上标记R峰,R峰值检测不属于本文的主要内容,因此不做叙述,基于R峰的标记提取RR间期序列,RR间期划分方法为:

$$RRI(n) = \frac{R_{\text{peaks}}(n+1) - R_{\text{peaks}}(n)}{f_s} \quad (6)$$

其中, $R_{\text{peaks}}(n)$ 是样本中第 n 个R峰的位置, f_s 是样本频率(Hz)。1个RRI代表1个RR序列,即1个心跳节

拍。将 100 个节拍的 RR 间期序列作为 1 个样本,如果心搏序列包含 1 个或多个被分类为显示心房颤动体征的心搏,则该心搏序列被标记为 AF,所有其他序列被标记为正常。为了增加数据集的样本数,每个样本与后一个样本使用重叠的 50 拍。其中 20 名患者用于模型训练,3 名患者用于盲法检测,以模拟真实检测场景,判断在未知数据集上面的效果。划分后的数据集样本数如表 1 所示。

表 1 训练集、验证集、测试集的样本分布
Table 1 Sample distributions of the training set, validation set, and test set

数据集	正常样本	心房颤动样本
训练集	7960	6565
验证集	2654	2188
盲法测试集	1318	1842

2.2 结合 CNN 与 LSTM 的深度学习模型

ECG 信号所提取的 RR 间期序列属于一维时序信号,CNN 可以很好地提取一维时序信号的空间特征,并能够简化特征以及提取时间,而本文所提取的 RR 间期又为长时间的 RR 间期,因此存在长时记忆的问题,而 LSTM 专门解决长时记忆中的依赖问题,还能够解决神经网络中常见的梯度爆炸或梯度消失等问题,故本文设计了一种结合 CNN 与 LSTM 优势的深度学习网络。专门针对心房颤动的检测识别,本文设计的深度学习模型如图 3 所示。




图 3 CNN+LSTM 模型结构
Figure 3 Composition of CNN+LSTM model

首先,该模型由卷积层、池化层、多头注意力机制、LSTM 单元和全连接层组成。其数据来源为 MIT-BIH AFDB 数据库的 23 条心电图数据。经过 R 峰值提取和 RR 间期序列计算后,将数据切分为以 100 个 RR 间期序列为 1 个样本的数据集。20 条数据被随机打乱并作为训练集和验证集,3 条数据用于测试集,以测试模型对不同个体的泛化识别能力。将训练集作为模型输入层的输入,其尺寸为 (100, 1)。第一层卷积层由 32 个 3×1 的卷积核组成,用于对 RR 间

期的结构性特征进行深度挖掘以提高特征表达能力。修正线性单元(ReLU)用作激活函数,以增强神经网络的非线性表达能力。此外,ReLU 的计算速度快,有助于加快模型的训练和预测。最大池化层用于筛选出主要特征以减少特征数量,并添加了 Dropout(Dropout=0.2)层以减少过拟合的概率。在 3 个卷积层和池化层后,添加了 1 个多头注意力机制层,以提取时序特征中的关键信息。之后,使用 3 个 LSTM 单元提取 RR 间期序列中的时序性特征,并在 LSTM 的最后一层之前添加了 1 个多头注意力机制层,以对 LSTM 输出的特征进行重要程度计算即权重分配,进而达到提高模型准确率的目的。最后,得到的特征被拉平并输入到全连接层,以汇总不同维度的特征,通过 sigmoid 分类器进行分类并输出结果。模型的详细参数参见表 2。

表 2 CNN 与 LSTM 结合的深度学习模型参数
Table 2 Parameters of the deep learning model combining CNN and LSTM

层数	层类型	滤波器尺寸	滤波器个数	步长	输出维度
1	卷积层	7×1	60	1	100×60
2	池化层	3×1	4	2	50×60
3	卷积层	5×1	80	1	50×80
4	池化层	3×1	4	2	25×80
5	卷积层	3×1	100	1	25×100
6	池化层	3×1	4	2	13×100
7	LSTM	-	-	-	13×200
8	LSTM	-	-	-	13×150
9	LSTM	-	-	-	13×100
10	Flatten	-	-	-	1300
11	全连接层	-	-	-	50
12	Dropout	-	-	-	50
13	sigmoid	-	-	-	1

2.3 评价指标以及实验配置

实验采用的软件平台为 Python3.8.12, Tensorflow2.5.3 版本,计算机内存 16 G,CPU 为英特尔 Core i7-8700@3.2 GH,GPU 为 NVIDIA GeForce GTX 1060。

目前获得广泛应用的有 5 个指标:准确性(Accuracy, Acc)、敏感性(Sensitivity, Sen)、特异性(Specificity, Spe)和阳性预测率(Positive predictive rate, PPV)、F₁ 分数。准确性的定义是正确分类的拍数(心房颤动 TP 和非心房颤动 TN)与分类的总拍数之比。敏感性表示正确识别的心房颤动的比例,等

于TP除以TP和识别错误的非心房颤动(FN)之和。特异性表示测量正确识别的非心房颤动的比例,即TN与TN和错误识别心房颤动(FP)之和的比率。阳性预测率是指所有检测到的心房颤动中正确识别出心房颤动的比例,即TP与TP和FP之和的比值。这5个指标的值越高,表示分类性能越好。具体的计算公式如下所示:

$$Acc = (TP + TN)/(TP + TN + FP + FN) \tag{7}$$

$$Sen = TP/(TP + FN) \tag{8}$$

$$Spe = TN/(TN + FP) \tag{9}$$

$$PPV = TP/(TP + FP) \tag{10}$$

$$F_1 = (2 \times PPV \times Sen)/(PPV + Sen) \tag{11}$$

本实验采用 keras 平台以及基于 GPU 的 TensorFlow 平台训练与测试模型。训练过程采用 Adam 作为优化器,初始学习率设置为 0.01,其中的 dropout 层设置为 0.1,以减少模型的过拟合并改进模型泛化效果。在训练过程期间,产生损失减少的任何网络权重将被保存用于测试。选择二元交叉熵作为模型训练的损失函数,其计算公式如下:

$$Loss = -\frac{1}{N} \sum_{i=1}^N y_i \times \log(p(y_i)) + (1 - y_i) \times \log(1 - p(y_i)) \tag{12}$$

式中y是二元标签0或者1,p(y)是输出属于y标签的概率。二元交叉熵函数比较两个概率分布(真实分布和预测分布的概率分布)以提供关于预测的更多信息。在训练阶段采用训练优化策略,即每次训练都以前一个最优权重作为此次的初始权重,这样能够保证训练不会被中间一些坏的权重破坏,导致模型不佳。采用10倍交叉验证进行模型训练与验证,训练迭代次数设置为200,批处理大小为128。

3 实验结果及分析

3.1 实验结果分析

首先,本文为了验证 CNN+LSTM 模型的优越性,分别搭建了 CNN 模型、LSTM 模型、CNN+LSTM 模型进行心房颤动的检测,用于验证哪种模型能够更好地进行心房颤动的预测。结果如表 3 所示, CNN+LSTM 模型明显优于 CNN 模型与 LSTM 模型,因为 CNN 模型主要针对信号的空间特征,而 LSTM 模型主要针对信号的时间特征,而 CNN+LSTM 模型融合了两个方面的特征,与单个特征相比,融合特征具有更强的分离性和更高的分类精度,使用融合特征的算法可以提取更多信息进行分类,并且对不同主体具有很强的适应性。

之后对本文提出的模型进行了测试,其损失曲线如图 4 所示,可以看到到达 200 个 epoch 后模型基

表 3 CNN 模型、LSTM 模型、CNN+LSTM 模型分类结果对比(%)
Table 3 Comparison of classification results among CNN, LSTM, and CNN+LSTM models (%)

模型	准确率	敏感性	特异性	阳性预测率	F ₁ 分数
CNN	97.13	98.46	95.52	96.39	97.41
LSTM	97.91	97.81	98.00	97.58	97.69
CNN+LSTM	99.11	98.86	99.47	99.62	99.24

本收敛,且没有出现过拟合的现象,测试阶段数据的混淆矩阵如图 5 所示。本文提出的模型在盲法测试集上能够取得 99.11% 的准确度、98.86% 的敏感性、99.47% 的特异性、99.62% 的阳性预测率、99.24% 的 F₁ 评分,可以看出本模型在盲法测试集上取得良好的性能与效果。




图 4 CNN+LSTM 模型训练集与验证集损失曲线

Figure 4 Loss curves of CNN+LSTM model on the training set and validation set




图 5 测试集进行盲法检测后的混淆矩阵

Figure 5 Confusion matrix of blind detection on the test set

3.2 与现有方法比较

表 4 中总结了各种已发表的心房颤动检测算法。

表中所有的实验数据全部基于MIT-BIH心房颤动数据库得出,因此能够利用所得出的实验结果判断本文算法的优越性。本文提出的数据处理结构不需要数据处理,训练数据集中所有的可用信息交给深度学习系统,使得它能够在未知数据上得到良好的结果。从表4可知,Li等^[13]使用空白窗比率、信息熵、RR间期差概率密度分布作为特征,线性支持向量机作为模型,取得了95.90%的准确率。Xia等^[14]则将ECG信号转化为二维图像,使用二维图像的特征并使用CNN进行分类,取得了98.29%的准确率。Andersen^[23]、Wang^[24]、Zhang^[25]等则使用不同模型对ECG一维信号进行分类,分别取得了97.80%、

98.30%、95.28%的准确率。Hirsch等^[26]采用增强树、随机森林、随机子空间特征,使用线性判别分析对心房颤动进行分类,取得了97.60%的准确率。而上述算法得出的结果并没有考虑一些特异性样本或者不同样本之间的差异问题,得出的结果可能与临床结果差别很大。本文提出的算法能够达到99.11%的准确率和99.47%的特异性,且算法考虑到了在不同个体间的差异性,特别使用3个未在训练集中出现过的样本集进行测试,且能够取得很好的效果,因此,本文提出的算法不仅在结果上优于前人的算法,且对于不同个体的泛化能力上也有不错的效果。

表4 所提分类方法性能与过往工作的比较
Table 4 Performance comparison between the proposed method with previous works

文献	特征	准确率/%	敏感性/%	特异性/%	阳性预测率/%	F ₁ 分数/%
Li等 ^[13]	空白窗比率+信息熵+RR间期差概率密度分布	95.90	95.30	96.30	-	-
Xia等 ^[14]	STFT (RGB)+CNN	98.29	98.34	98.24	-	-
	STFT (gray)+CNN	97.74	98.60	97.17	-	-
	SWT+CNN	98.63	98.79	97.87	-	-
Andersen等 ^[23]	CNN+LSTM	97.80	96.95	98.98	-	-
Wang等 ^[24]	CNN+MLP	98.30	97.10	99.30	-	-
Zhang等 ^[25]	LSTM+CNN	95.28	96.46	94.49	-	-
Hirsch等 ^[26]	增强树+随机森林+随机子空间+线性判别分析	97.60	98.00	97.40	-	97.10
本文算法	LSTM+CNN	99.11	98.86	99.47	99.62	99.24

4 结束语

本文使用长时间的RR间期数据作为模型的输入,采用滑动窗口的原理进行数据集扩充,并结合CNN与LSTM设计了一个深度学习模型,在训练阶段,算法可以提取所有可用信息以创建隐含知识,该隐含知识支撑后续决策过程,结果证明所提出的模型具有很高的准确度和鲁棒性。具体而言,该模型在10倍交叉验证下在盲法测试集上达到了99.11%的准确度、98.86%的敏感性、99.47%的特异性、99.62%的阳性预测率、99.24%的F₁评分,结果与其他工作比较有较高的优越性。随着便携式设备的发展,本文模型还能够根据之后在便携式设备上的测量结果不断进行再训练,不断完善训练结果,使得模型更加具有普适性,从而减少临床医生的工作量。由于本文使用的公开数据集的23个样本,使用的样本数量偏少,因此未来的工作考虑要提升数据集的多样性,使模型能够适用于更多的个体,泛化能力进一步加强。

【参考文献】

[1] Jame S, Barnes G. Stroke and thromboembolism prevention in atrial fibrillation[J]. Heart, 2020, 106(1): 10-17.
[2] Turakhia MP, Shafrin J, Bogner K, et al. Estimated prevalence of undiagnosed atrial fibrillation in the United States[J]. PLoS One, 2018, 13(4): e0195088.
[3] Haddi Z, Pons JF, Delliaux S, et al. A robust detection method of short atrial fibrillation episodes[C]//2017 Computing in Cardiology (CinC). IEEE, 2017: 1-4.
[4] Narin A, Isler Y, Ozer M, et al. Early prediction of paroxysmal atrial fibrillation based on short-term heart rate variability[J]. Phys A: Statist Mechan Appl, 2018, 509: 56-65.
[5] Kumar M, Pachori RB, Acharya UR. Automated diagnosis of atrial fibrillation ECG signals using entropy features extracted from flexible analytic wavelet transform[J]. Biocybern Biomed Eng, 2018, 38(3): 564-573.
[6] Gliner V, Yaniv Y. An SVM approach for identifying atrial fibrillation[J]. Physiol Meas, 2018, 39(9): 094007.
[7] Kalidas V, Tamil LS. Detection of atrial fibrillation using discrete-state Markov models and Random Forests[J]. Comput Biol Med, 2019, 113: 103386.
[8] 蔚文婧, 王寻, 张鹏远, 等. 一种基于多层感知器的房颤心电图检测方法[J]. 中国医学物理学杂志, 2020, 37(3): 332-336.
Wei WJ, Wang X, Zhang PY, et al. A method for detecting atrial fibrillation electrocardiograms based on multilayer perceptron[J]. Chinese Journal of Medical Physics, 2020, 37(3): 332-336.
[9] Hsieh CH, Li YS, Hwang BJ, et al. Detection of atrial fibrillation using

- 1D convolutional neural network[J]. Sensors, 2020, 20(7): 2136.
- [10] Ladavich S, Ghoraani B. Rate-independent detection of atrial fibrillation by statistical modeling of atrial activity[J]. Biomed Signal Proc Control, 2015, 18: 274-281.
- [11] Maji U, Mitra M, Pal S. Automatic detection of atrial fibrillation using empirical mode decomposition and statistical approach [J]. Proc Technol, 2013, 10: 45-52.
- [12] Babaeizadeh S, Gregg RE, Helfenbein ED, et al. Improvements in atrial fibrillation detection for real-time monitoring [J]. J Electrocardiol, 2009, 42(6): 522-526.
- [13] Li Y, Tang X, Wang A, et al. Probability density distribution of delta RR intervals: a novel method for the detection of atrial fibrillation[J]. Austral Phys Eng Sci Med, 2017, 40(3): 707-716.
- [14] Xia Y, Wulan N, Wang K, et al. Detecting atrial fibrillation by deep convolutional neural networks[J]. Comput Biol Med, 2018, 93: 84-92
- [15] 陈志博, 李健, 李智, 等. 基于RR间期和多特征值的房颤自动检测分类[J]. 生物医学工程学杂志, 2018, 35(4): 550-556.
- Chen ZB, Li J, Li Z, et al. Automatic detection and classification of atrial fibrillation based on RR interval and multiple eigenvalues[J]. Journal of Biomedical Engineering, 2018, 35(4): 550-556.
- [16] Fan X, Yao Q, Cai Y, et al. Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings[J]. IEEE J Biomed Health Inform, 2018, 22(6): 1744-1753.
- [17] Fujita H, Cimr D. Computer aided detection for fibrillations and flutters using deep convolutional neural network[J]. Inform Sci, 2019, 486: 231-239.
- [18] 刘学森, 张俊仕. 基于多特征融合的阵发性房颤自动检测算法的研究[J]. 生物医学工程, 2020, 39(4): 358-362.
- Liu XC, Zhang ZS. Research on automatic detection algorithm of paroxysmal atrial fibrillation based on multi-feature fusion [J]. Biomedical Engineering, 2020, 39(4): 358-362.
- [19] 顾佳艳, 蒋明峰, 李杨, 等. 基于多头注意力机制的房颤检测方法[J]. 计算机系统应用, 2021, 30(4): 17-24.
- Gu JY, Jang MF, Li Y, et al. Detection of atrial fibrillation based on multi-head attention mechanism[J]. Computer System Application, 2021, 30(4): 17-24.
- [20] Zhou YT, Chellappa R. Computation of optical flow using a neural network[C]//ICNN. 1988: 71-78.
- [21] Hopfield JJ. Neural networks and physical systems with emergent collective computational abilities[J]. Proc National Acad Sci, 1982, 79(8): 2554-2558.
- [22] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Comput, 1997, 9(8): 1735-1780.
- [23] Andersen RS, Peimankar A, Puthusserypady S. A deep learning approach for real-time detection of atrial fibrillation[J]. Expert Syst Appl, 2019, 115: 465-473.
- [24] Wang J. Automated detection of atrial fibrillation and atrial flutter in ECG signals based on convolutional and improved Elman neural network[J]. Knowledge-based Syst, 2020, 193: 105446.
- [25] Zhang X, Li J, Cai Z, et al. Over-fitting suppression training strategies for deep learning-based atrial fibrillation detection[J]. Med Biol Eng Comput, 2021, 59(1): 165-173.
- [26] Hirsch G, Jensen SH, Poulsen ES, et al. Atrial fibrillation detection using heart rate variability and atrial activity: A hybrid approach[J]. Expert Syst Appl, 2021, 169: 114452.

(编辑:黄开颜)