

DOI:10.3969/j.issn.1005-202X.2023.01.015

医学信号处理与医学仪器

## 基于空洞卷积神经网络的心律失常分类算法

秦默然<sup>1</sup>, 李宙童<sup>2</sup>, 翟月英<sup>3</sup>, 史纪广<sup>1</sup>, 纪洁维<sup>1</sup>, 常胜<sup>1</sup>, 王豪<sup>1</sup>, 何进<sup>1</sup>, 黄启俊<sup>1</sup>

1. 武汉大学物理科学与技术学院, 湖北 武汉 430072; 2. 上海交通大学医学院附属第九人民医院黄浦分院心血管内科, 上海 200011; 3. 武汉晴川学院电子信息工程系, 湖北 武汉 430204

**【摘要】**本文提出了一种基于卷积网络的心电信号分类算法,设计了空洞卷积池化金字塔模块,通过不同尺寸的空洞卷积提取信息,再将各通道的信息聚合,在增强网络的特征提取能力的同时可以降低参数量。本文聚焦于窦性心律、房性早搏、心动过速以及心动过缓4种分类,使用的心电图数据集来自医院的实测数据,数据集包含75 000名不同检测者的心电记录。经过测试,本文提出的模型在该数据集上取得了0.89的F1值,另外在CinC2017数据集上也达到了0.87的F1值。实验结果表明该分类算法具有优秀的特征提取和分类能力,在心电信号的实时分类中具备应用前景。

**【关键词】**心律不齐;神经网络;心电图;深度学习

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2023)01-0087-08

## Arrhythmia detection algorithm based on dilated convolutional neural network

QIN Moran<sup>1</sup>, LI Zhoutong<sup>2</sup>, ZHAI Yueying<sup>3</sup>, SHI Jiguang<sup>1</sup>, JI Jiwei<sup>1</sup>, CHANG Sheng<sup>1</sup>, WANG Hao<sup>1</sup>, HE Jin<sup>1</sup>, HUANG Qijun<sup>1</sup>

1. School of Physics and Technology, Wuhan University, Wuhan 430072, China; 2. Department of Cardiology, Huangpu Branch of Shanghai Ninth People's Hospital, Shanghai Jiaotong University School of Medicine, Shanghai 200011, China; 3. Department of Electronic Information Engineering, Wuhan Qingchuan University, Wuhan 430204, China

**Abstract:** An electrocardiogram (ECG) signal classification algorithm based on convolutional network is proposed. The algorithm adopts an atrous spatial pooling pyramid module to extract information through atrous convolution of different sizes, and aggregates the information of each channel for enhancing the ability of feature extraction and reducing the number of parameters. The study focuses on the categories of sinus rhythm, premature atrial contraction, tachycardia and bradycardia, and a real ECG data set from a hospital which contains ECG records of 75 000 different subjects is used for experiment. The results reveal that the proposed model reaches an F1 score of 0.89 on the real ECG data set, and also achieved an F1 score of 0.87 on the CinC2017 data set, which indicates that the classification algorithm has excellent feature extraction and classification capabilities, and has application prospects in the real-time classification of ECG signals.

**Keywords:** arrhythmia; neural network; electrocardiogram; deep learning

### 前言

近年来,由于脑力劳动比例提高导致的体力劳动缺乏,以及不健康的饮食习惯等造成了心血管疾病发病率的提升;此外,遗传因素也是造成心血管疾病发病的重要原因之一。据统计,心血管疾病是我国居民死亡的首要原因,我国居民死亡原因中40%

源于心血管疾病<sup>[1]</sup>。因此,心血管疾病的提前预防对于保护居民的生命健康具有重要意义。

心电图(Electrocardiogram, ECG)是一种能够反映心脏活动的生物电信号,心室和心房的生理活动会通过心电信号进行反映,如图1所示,心电信号的典型波形包含P波、QRS波以及T波,分别对应着心房除极、心室去极化、心室复极化的过程。P波:代表心房的去极化过程,是由左右心房激动造成的。波形正常情况下为圆钝的凸起。一般P波宽度小于0.11 s,其振幅最大为0.15 mV。P波消失是诊断房性颤动的关键指标<sup>[2]</sup>。QRS复合波群:一般称为QRS波,由迅速起伏的3个波形即Q波、R波、S波组成,代表心室的去极化。QRS波群是心电波形中波动最大

**【收稿日期】**2022-08-10

**【基金项目】**国家自然科学基金(81971702, 61874079, 61774113)

**【作者简介】**秦默然,硕士,研究方向:基于深度学习的ECG信号处理与分类,E-mail: qinmrmr@whu.edu.cn

**【通信作者】**黄启俊,教授,研究方向:医学信号处理及微电子系统设计,E-mail: huangqj@whu.edu.cn

的波形,形态变化很大,即使是在没有发生心脏病变的正常情况下,也可能发生任一波形消失<sup>[3]</sup>。QRS波间期较为稳定,持续时间一般为0.06~0.10 s<sup>[4]</sup>。影响QRS波群形态的原因除了疾病类型之外,还有导联位置等因素。QRS波形的异常是诊断室性早搏,心肌梗塞等疾病的关键指标<sup>[3]</sup>。T波:代表着心室的复极化。出现在QRS波后,特点为波形宽大、幅度不高。其振幅一般为0.10~0.80 mV。T波的形态、方向、高度是诊断的重要指标。与T波表现相关的疾病有早期的心梗等。由此可见,异常心电图与正常心电图呈现出不同的形态特征,广泛用于心脏疾病的防治与诊断。




图1 典型的心电信号波形

Figure 1 Typical ECG waveform

通常,心电图检测需要到医院用专业的心电图仪进行采集。随着智能可穿戴设备技术的发展,实时采集心电信号成为可能,但是心电信号的实时判别成为问题,如果送往医院经专业的医生进行诊断,无疑增大了医生的工作量,延缓了疾病的诊断。因此,对心电信号进行实时自动判别和诊断成为近年来研究的热点。

心律不齐是很多严重的心血管疾病的前兆,心律不齐检测可以实现心血管疾病的早预防、早发现 and 早治疗。心律不齐的识别算法主要分为两种。一种是传统的基于人工选择特征分类的方法,例如将R-R间期<sup>[5]</sup>、小波特征<sup>[6]</sup>等人工特征作为判别依据输入分类器(如支持向量机、随机森林等)进行分类。第二种是利用神经网络自主学习的特点,由神经网络自动提取特征,进而完成对心电信号的分类<sup>[7-10]</sup>。Chen等<sup>[7]</sup>构建了一个大型的多通道多尺度卷积神经网络作为特征提取器,提取出的特征通过长短时记忆网络(Long Short Term Memory, LSTM)处理时序信息作为分类依据输出到分类器<sup>[10]</sup>。Wang等<sup>[8]</sup>建立了一个配备了全局注意力(Global Attention)模块的残差神经网络(ResNet)<sup>[11]</sup>,以避免忽略输入信号的全局时序特征,在PTB-XL数据集上取得了0.85的F1

值,F1值是一种常用的分类任务精确度评价指标,它同时兼顾了分类模型的精确率和召回率。Rajpurkar等<sup>[9]</sup>建立了一个34层的单通道残差神经网络用于单导联心电信号的心律不齐分类,使用了超规模数据量的心电信号数据集训练这个网络。在心律不齐十分分类任务中,该模型表现出了超过专家人工诊断的准确率。Rubin等<sup>[12]</sup>在针对房颤的4分类任务中设置了分步分类算法,先使用信号质量评估算法(Signal Quality Assessment, SQA)将最难分离的噪声类别识别出来以降低神经网络学习的难度,再将ECG信号利用快速傅里叶变换转化到频域作为卷积网络的输入。

本文设计了一种基于ResNet的卷积神经网络,其主要特点是加入了空洞卷积池化金字塔模块(Atrous Spatial Pooling Pyramid, ASPP)<sup>[13]</sup>,模块设置了多个具有不同扩张率的通道,每个通道的卷积操作具有不同尺度的感受野,因而可以提取多个不同尺度的特征进行聚合。考虑到心律不齐在时序上与窦性心律的显著差异,如P波的提前以及P-R间期的延长,模型使用双向长短时记忆网络(Bi-LSTM)来处理 and 判别ECG信号时域上的特征<sup>[14]</sup>,最后引入了批量归一化(Batch Normalization)来促使网络在训练时平滑收敛<sup>[15]</sup>。该模型的训练与测试均在医院实测的心电信号数据集上进行,心电信号数据采样率为1 000 Hz,包含超过七万名被检测者的ECG数据,有46种不同诊断结果作为标签,如窦性心律、房颤、房性早搏等。在本文的分类任务中,考虑到实际需求与病例数比例,笔者选择了窦性心律、房性早搏、心动过速以及心动过缓作为心律不齐分类的目标类别。图2是这4种类别的典型心电图波形。观察图2可知,房性早搏的特点主要在于QRS波群内部的特征,如P波提前发生,P波形态不同于窦性心律等。而心动过速、心动过缓则主要体现在节律上,心动过速的T波与下一个心拍的P波几乎无间隔,而心动过缓表现为心拍之间间隔非常远。

## 1 模型结构与实验方法

### 1.1 数据库

使用的第1个心电信号数据库来自于上海某医院,包含了75 000名被检测者的ECG数据,数据包含了全部12个导联,约50 000个患者的心电数据带有注释,标明了该数据所属的疾病类型,表1给出了数据库中一些典型的标签类型以及带有该标签的患者数量,本文实验所使用的数据均来自于该数据库中的I导联,图3是该数据库中的一个实例片段。第二个数据库是开源数据库CinC2017,该数据库只包含




图2 4个目标类别的典型波形

Figure 2 Typical ECG waveforms of 4 target categories

了I导联的数据,共有约8 500个心电信号片段,采样率为300 Hz。片段与被检测者一一对应,信号长度为30~60 s。这是一个以4分类为目标数据库,包括窦性心律、房颤、其他心率以及噪声4种标签。

表1 某医院数据库部分标签及对应数量

Table 1 Some labels from a hospital database and the corresponding quantities

编号	类型	数量	编号	类型	数量
1	窦性心律	47 672	11	ST段抬高	4 244
2	ST-T改变	34 188	12	室性早搏	3 761
3	右心房扩大	26 733	13	窦性心律不齐	3 702
4	左心室肥大	17 190	14	心动过缓	1 502
5	QT间期延长	11 545	15	心动过速	1 402
6	异常心电图	10 613	16	心房颤动	716
7	左心室高血压	10 217	17	显著心电图右偏	540
8	房性早搏	6 066	18	左心房肥大	489
9	I度房室传导阻滞	5 358	19	右心室肥大	448
10	轻度心电图左偏	5 198	20	成对室性期前收缩	339

1.2 数据预处理

未经处理的实测ECG数据包含多种噪声<sup>[16]</sup>,这些噪声严重时会掩盖ECG信号的重要形态特征导致对心血管疾病的误判,所以要对数据进行预处理,本

文使用了0.5~150 Hz的带通滤波去除噪声<sup>[17]</sup>。因为心电信号来自多个不同的被检测者,不同的心电信号幅度差异比较大,所以对所有数据进行了归一化,计算方式如公式(1)所示:





图3 12导联心电信号示意图  
Figure 3 Schematic diagram of 12-lead ECG signal

$$\text{sign}[i] = \frac{\text{sig}[i] - \text{mean}(\text{sig})}{\text{std}(\text{sig})} \tag{1}$$

其中,  $\text{sig}[i]$ 表示归一化前某一心电数据的第*i*个采样点的取值,  $\text{sign}[i]$ 表示归一化之后该数据的第*i*个点的取值,  $\text{mean}(\text{sig})$ 与  $\text{std}(\text{sig})$ 分别代表该记录的均值与标准差。

由于每条心电数据的时长不尽相同,所以有必




图4 模型结构示意图  
Figure 4 Schematic diagram of model structure

表2 模型训练超参数  
Table 2 Hyperparameters for model training

参数	取值
优化器	Adam optimizer, beta1=0.9, beta2=0.999
学习率	0.001
损失函数	交叉熵函数(Cross entropy)
训练轮数(epoch)	200
批量大小(batch size)	128

ResNet是一种在卷积神经网络基础上发展出来的网络结构,其主要特点是引入了包含卷积层和直连通道的残差模块,结构如图5所示。这种直连支路结构能够解决随着网络层数的加深而产生的准确率退化问题,通过引入一个额外的全等映射,在增加网络深度时并不会造成准确率退化,由于学习的目标

要将每条记录分割成不重叠的、长度相同的片段,每个片段包含9 000个样本点,其时间长度为9 s。数据划分采用了Inter-patient的形式<sup>[18]</sup>,即先将8 528名病人的记录划分为训练集、测试集与验证集,再对每个记录进行去噪、切分、上采样等预处理。这些经过了滤波、归一化以及分割之后的心电数据片段就是神经网络模型的输入数据。

1.3 网络模型结构

模型主要由ResNet的残差模块、ASPP模块、Bi-LSTM模块以及全连接分类层组成。其整体结构如图4所示,图中的卷积模块包括卷积层、BN层以及激活层;分类层由全局平均池化层和全连接层组成<sup>[19]</sup>;除最后一层全连接层的激活函数采用softmax函数作为分类器以外,其它层均使用relu函数作为激活函数<sup>[20]</sup>。神经网络的部分超参数由表2给出。训练过程中使用了Adam自适应学习率优化器<sup>[21]</sup>,该优化器可以根据训练数据动态地调整学习率,有利于模型快速收敛。训练模型时选用了交叉熵函数<sup>[22]</sup>,它是常用的分类任务损失函数。

由映射  $F(x)$  转变为残差  $F(x) - x$ ,使得学习任务更加简单,进一步提升了特征提取的效果。




图5 残差块结构示意图  
Figure 5 Residual block structure diagram

ASPP模块由多支路不同尺度的空洞卷积构成<sup>[23]</sup>,相比普通的卷积,它能够在尺度卷积操作下显著降低卷积核参数数量,同时可以保证卷积操作的特征提取能力。因为心率不齐涉及多个心拍,故

大尺度特征的提取对于心律不齐的分类具有至关重要的作用。本文构建的ASPP模块如图6所示,多通道空洞卷积层的卷积核尺寸为3×1,膨胀率分别为0、6、12;聚合层之后的两个卷积层卷积核尺寸分别为15×1、7×1;输出层之前的池化层选用了平均池化,其步长为4×1。在聚合各通道的特征图之后,使用一个残差块来引入全等映射,保证了多通道空洞卷积层所学习到的不同尺度特征能够保留并传输到后层。

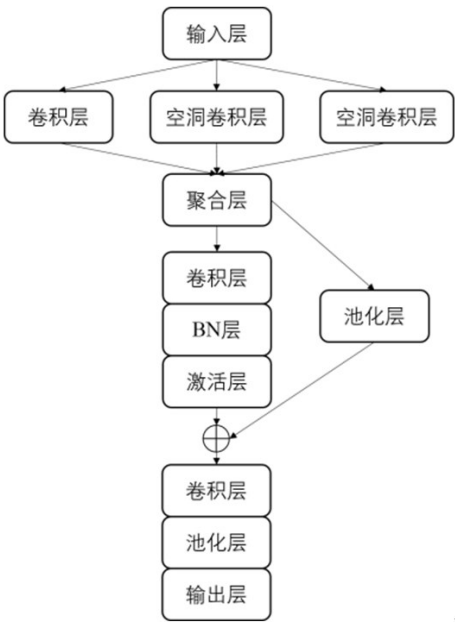


图6 ASPP模块结构示意图  
Figure 6 ASPP module structure diagram

Bi-LSTM是一种处理带有时序特征信息的神经网络,相比于普通的循环神经网络,它采用了“门”结构来控制某些信息需要被保留并作为当前时刻的输入,而另一些信息则被抛弃。通过这样的结构,网络实现了对长期时间信息的提取和保存能力。

2 实验结果和讨论

2.1 模型性能的评估参数

模型的训练和测试在Python3.6环境下进行,使用tensorflow 2.0以及Keras框架。为验证模型的稳定性,进行了十折交叉验证,即将数据集随机平均分成10份,每次取其中一份作为测试集,另9份作为训练和验证集,实验结果取10次交叉验证的均值。

模型分类的性能由F1值表示,F1值与准确率(Precision)和召回率(Recall)相关,计算公式如下所示:

precision = TP / (TP + FP) (2)

recall = TP / (TP + FN) (3)

F1 = (2 \* precision \* recall) / (precision + recall) (4)

其中,TP代表真正例,即被模型正确预测为正例的样本数量;FP代表假正例,即被模型预测为正例但实际是反例的样本数;FN代表假反例,即被模型预测为反例而实际上是正例的样本数。准确率表示样本中被模型正确判定为该类别的识别比例,召回率则表示测试集中该类别被模型正确识别出的比例。通常情况下这两个量是一对矛盾的度量,因此使用两者调和平均数即F1值作为性能指标。

2.2 结果分析

首先,本文模型在开源的Computing in Cardiology Challenge 2017 dataset(CinC 2017)上进行训练和验证,跟相关研究结果作比较。该数据集的标签包括房颤(Atrial Fibrillation)、窦性心律(Sinus rhythm)、其他心律(Other rhythm)以及噪声(Noisy),与本文模型的4分类任务吻合。因为该数据集采样率只有300 Hz,所以进行了上采样操作使输入信号的采样率与本文所使用的医院实测数据库一致,即1 000 Hz。

图7和图8是训练集与验证集的准确率与损失值曲线。由图7和图8可知,模型训练到150轮时收敛,此时模型在训练集与验证集上的准确率分别为0.92和0.88。考虑到所用的ECG数据划分采用了Inter-patient的形式,即训练集与验证集来自于不同的被检测者,而每个被检测者的心电数据带有其个人特征,说明模型的泛化能力很好,即对不同病人具有适应性。




图7 训练集与验证集准确率曲线  
Figure 7 Accuracy on training set and validation set

表3是基于该数据库训练之后本文模型的分类效果与其它工作的对比。可以发现,本文方法在F1值指标上超过了VGG16,而与8CSL以及MLP的差距很小。8CSL全部采用ResNet结构,相同深度下其参数量远多于空洞卷积模块,不利于网络的轻量化。如搭载在可




图 8 训练集与验证集损失值曲线  
Figure 8 Loss on training set and validation set

穿戴设备上,本文的模型更有优势。但是MLP方法的R波检测算法属于人工提取特征,其流程非常复杂,且需要降采样、滤波等多个操作,会极大地影响分类速度,破坏ECG信号心律不齐分类的实时性。

表 3 本文方法与其他方法的对比  
Table 3 Comparison of F1 scores between the proposed method and other methods

方法	数据库	F1 值
VGG16 <sup>[24]</sup>	CinC2017	0.720 0
8CSL <sup>[25]</sup>	CinC2017	0.895 5
R 波检测+MLP <sup>[26]</sup>	CinC2017	0.900 9
本文方法	CinC2017	0.873 5

为了验证本文模型的实际应用效果,用上海医院的实测 ECG 数据库进行了训练和测试。图 9、图 10 是训练过程中训练集与验证集的准确率曲线和损失值曲线。可以看出模型在训练到第 50 轮时开始收敛,此时训练集的准确率达到 0.99,而在验证集上准确率达到 0.87。医院实测 ECG 数据集也采用了 Inter-patient 的划分方式,故图 9 也显示了验证集与训练集在准确率上的差距。




图 9 训练集与验证集准确率趋势  
Figure 9 Accuracy on training set and validation set




图 10 训练集与验证集损失值趋势  
Figure 10 Loss on training set and validation set

为验证模型的优势,构造了同样深度的ResNet+Bi-LSTM在相同数据集上进行了训练和测试以进行对比。表 4 给出了本文方法与 ResNet+Bi-LSTM 在测试集上 4 个目标种类的分类准确率、召回率以及 F1 值。由表 4 可知,本文方法在医院实测数据库上进行的 4 分类任务在测试集上的平均 F1 值(4 种类别的 F1 值取平均数)达到了 0.889 8,而常规的 ResNet+Bi-LSTM 在测试集上的平均 F1 值只有 0.817 7。图 11 给出了直观的混淆矩阵对比,可以观察到,本文模型与 ResNet+Bi-LSTM 组合网络在对房性早搏类别的分类效果差异造成了平均 F1 值的差距。房性早搏的分类效果不如其他类别的原因是其 3 个类别主要区别在于节律,这导致训练后的网络更倾向于利用节律特征进行分类判定,而房性早搏的节律特征与窦性心律类似,故房性早搏易被分为窦性心律。这是一种广义的类别不平衡效应,可利用一些经典的针对类别不平衡的方法加以解决,如引入 focal loss<sup>[27]</sup>,它给予易错分的样本(即房性早搏类别的样本)更高的权重,从而训练网络不仅关注节律信息,同时也关注 QRS 波群的形态信息。由该对比实验可以得出结论,采用了 ASPP 模块的本文模型分类效果显著高于常规的 ResNet+Bi-LSTM 组合网络,证明本文模型在心律不齐分类任务上的优越性。

表 4 两种方法的准确率、召回率及 F1 值对比  
Table 4 Comparison of precision, recall and F1 score between two methods

方法		准确率	召回率	平均 F1 值
ResNet+Bi-LSTM	窦性心律	0.838 5	0.756 1	0.817 7
	房性早搏	0.577 7	0.757 7	
	心动过速	1.000 0	1.000 0	
	心动过缓	0.877 1	0.769 6	
本文方法	窦性心律	0.873 5	0.865 1	0.889 8
	房性早搏	0.785 9	0.845 4	
	心动过速	1.000 0	1.000 0	
	心动过缓	0.921 8	0.942 8	






图 11 本文模型与 ResNet+Bi-LSTM 在测试集上预测的混淆矩阵对比

Figure 11 Comparison of the confusion matrix predicted by the proposed model and ResNet+Bi-LSTM on test set

3 结 论

随着人工智能的发展,ECG 信号的疾病分类自动判别正成为现实。本文提出了一种基于神经网络的心电信号心律不齐智能识别算法。通过多通道多尺度的空洞卷积神经设计,实现了对心电信号不同尺度的特征提取,同时可降低神经网络的参数量,使模型有轻量化的特点,易于硬件移植,可以实现心律不齐的实时诊断和预防。通过开源心电数据库 Cin C2017 与医院实测数据,模型取得了很好的分类效果,验证了模型的有效性和实用性。与其它几种流行的深度学习方法进行分类效果对比,本文提出的模型具有较强的鲁棒性。

基于此项研究,有望在可穿戴设备上对实时采集到的 ECG 进行有效的分类,实现对心血管疾病的提前发现和实时监控,从而降低因心血管疾病致死的风险,维护我国居民的生命健康。更进一步的研究可以聚焦于精确度的提升、更多标签的分类以及网络模型的轻量化等方面。

【参考文献】

[1] 中国心血管健康与疾病报告编写组,胡盛寿. 中国心血管健康与疾病报告 2020 概要[J]. 中国循环杂志, 2021, 36(6): 521-545.  
The Writing Committee of the Report on Cardiovascular Health and Diseases in China, Hu SS. Report on cardiovascular health and diseases burden in China: an updated summary of 2020[J]. Chinese Circulation Journal, 2021, 36(6): 521-545.

[2] Razzaq N, Sheikh SA, Zaidi T, et al. Automated differentiation between normal sinus rhythm, atrial tachycardia, atrial flutter and atrial fibrillation during electrophysiology [C]//2017 IEEE 17th International Conference on Bioinformatics and Bioengineering (BIBE). IEEE, 2017: 266-272.

[3] 陈新, 黄宛. 临床心电图学[M]. 第 6 版. 北京: 人民卫生出版社, 2009: 1-69.  
Chen X, Huang W. Clinical electrocardiography[M]. 6th edition. Beijing: People's Medical Publishing House, 2009: 1-69.

[4] 卢尔滨, 王凌燕. 心电图阅读入门[M]. 北京: 化学工业出版社, 2008: 13-23.

Lu EB, Wang LY. Getting started with ECG reading[M]. Beijing: Chemical Industry Press, 2008: 13-23.

[5] Jagdeep R, Marpe S, Dev SL, et al. An improved cardiac arrhythmia classification using an RR interval-based approach[J]. Biocybernetics and Biomedical Engineering, 2021, 41(2): 656-666.

[6] 冯蓓. 基于小波变换和神经网络的心律不齐分类方法研究[D]. 成都: 电子科技大学, 2019.  
Feng B. Research on classification of arrhythmia based on wavelet transform and neural network[D]. Chengdu: University of Electronic Science and Technology of China, 2019.

[7] Chen YC, Lin YT, Lee SJ, et al. Automated ECG classification based on 1D deep learning network[J]. Methods, 2022, 202: 127-135.

[8] Wang JK, Qiao X, Liu C, et al. Automated ECG classification using a non-local convolutional block attention module[J]. Comput Methods Programs Biomed, 2021, 203(7): 106006.

[9] Rajpurkar P, Hannun AY, Haghpanahi M, et al. Cardiologist-level arrhythmia detection with convolutional neural networks[J]. arXiv preprint arXiv: 1707. 018362017, 2017.

[10] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[11] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.

[12] Rubin J, Parvaneh S, Rahman A, et al. Densely connected convolutional networks for detection of atrial fibrillation from short single-lead ECG recordings [J]. J Electrocardiol, 2018, 51 (6S): S18-S21.

[13] He KM, Zhang XY, Ren SQ, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Trans Pattern Anal Mach Intell, 2014, 37(9): 1904-1916.

[14] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Netw, 2005, 18(5-6): 602-610.

[15] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[J]. arXiv preprint arXiv: 1502.03167, 2015.

[16] Kaplan Berkaya S, Uysal AK, Sora Gunal E, et al. A survey on ECG analysis[J]. Biomed Signal Proces, 2018, 43: 216-235.

[17] Kligfield P, Gettes L, Bailey JJ, et al. Recommendations for the standardization and interpretation of the electrocardiogram: part I: the electrocardiogram and its technology a scientific statement from the American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology; the American College of Cardiology Foundation; and the Heart Rhythm Society. Endorsed by the International Society for Computerized Electrocardiology [J]. Heart Rhythm, 2007, 4(3): 394-412.

[18] De Chazal P, O'Dwyer M, Reilly RB. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Trans Biomed Eng, 2004, 51(7): 1196-1206.

- [19] Lin M, Chen Q, Yan S. Network in network[J]. arXiv preprint arXiv: 1312.4400, 2014.
- [20] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks [J]. J Mach Learn Res, 2011, 15: 315-323.
- [21] Kingma D, Ba J. Adam: a method for stochastic optimization[J]. arXiv preprint arXiv: 1412.6980, 2015.
- [22] Spiring FA. The reflected normal loss function[J]. Can J Stat, 1993, 21(3): 321-330.
- [23] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [J]. arXiv preprint arXiv: 1511. 07122, 2016.
- [24] Cho J, Kim Y, Lee M. Prediction to atrial fibrillation using deep convolutional neural networks [C]//PRIME 2018: Predictive Intelligence in Medicine , 2018: 164-171.
- [25] Ping YJ, Chen C, Wu L, et al. Automatic detection of atrial fibrillation based on CNN-LSTM and shortcut connection[J]. Healthcare, 2020, 8(2): 139.
- [26] 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 electrocardiogram based on multilayer perceptron [J]. Chinese Journal of Medical Physics, 2020, 37(3): 332-336.
- [27] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection [J]. IEEE Trans Pattern Anal, 2018, 42(2): 318-327.

(编辑:薛泽玲)