

DOI:10.19651/j.cnki.cmt.2107797

具有自动抗噪功能的心电信号分类算法

雷宇 刘少儒 徐寅林

(南京师范大学 计算机与电子信息学院/人工智能学院 南京 210023)

摘要: 心电图(ECG)检测是心脏疾病最常用的诊断方法。但是在心电信号采集过程中往往会受到噪声干扰,从而使心电信号分类诊断的正确率受到很大影响。为提高分类诊断的准确率和抗噪能力,改进设计了一种用深度残差收缩网络(DRSN)实现自动抗噪、全局平均池化(GAP)整合空间信息的 ECG 分类诊断模型。在 MIT-BIH 心律失常数据集上验证了模型的性能,并将其与普通的卷积神经网络(CNN)模型进行了抗噪性能分析比较。实验结果表明,设计的 DRSN+GAP 诊断模型基于 AAMI 标准的分类正确率高达 99.3%,对不同强度的工频及高斯两种噪声其抗噪性能均优于普通的 CNN 模型。

关键词: ECG;深度学习;自动抗噪

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2060

ECG classification algorithm with automatic anti noise function

Lei Yu Liu Shaoru Xu Yinlin

(School of Computer and Electronic Information/School of Artificial Intelligence, Nanjing Normal University, Nanjing 210023, China)

Abstract: Electrocardiogram (ECG) detection is the most commonly used diagnostic method of heart disease. However, in the process of ECG signal acquisition, it is often disturbed by noise, which greatly affects the accuracy of ECG signal classification and diagnosis. In order to improve the accuracy and anti noise ability of classification diagnosis, this paper improves and designs an ECG classification and diagnosis model which use deep residual shrinkage network (DRSN) to resist noise automatically and integrate spatial information by global average pooling (GAP). The classification performance of the model is verified on MIT-BIH arrhythmia data set, and its anti noise performance is analyzed and compared with the ordinary convolutional neural network (CNN) model. The experimental results show that the classification accuracy of the designed DRSN+GAP diagnostic model based on AAMI standard is up to 99.3%, and its anti noise performance is better than ordinary CNN model for power frequency and Gaussian noise with different intensity.

Keywords: ECG; deep learning; automatic anti noise

0 引言

近年来,基于神经网络的深度学习技术发展迅速,将深度学习技术应用到心电图(electrocardiogram, ECG)诊断中是日前生物医学电子学领域的研究热点^[1-7]。ECG 诊断分类技术一般包括信号预处理、特征提取、自动分类 3 个步骤,其中对 ECG 信号的特征提取部分研究最多。这些研究中提出的信号特征提取模型大部分都是基于卷积神经网络(convolutional neural network, CNN)构建而成,比较有代表性的例如 Acharya 等^[1]用 9 层一维 CNN 和 3 层全连接层(dense layer)实现 ECG 的特征提取和自动分类。Kiranyaz 等^[2]提出基于一维 CNN 的带有患者特性的 ECG 分类算法。刘光达等^[3]利用前馈神经网络检测 R 波位置

并在此基础上制作包含 2 个 RR 间期的样本,利用一维 CNN 在分类问题上获得较好的跨患者特性。此类研究往往通过加深 CNN 的层数以获得较好的特征提取能力,但也容易带来梯度退化^[4]的问题, Brito 等^[5]利用 3 个残差块组成残差网络作为特征提取网络,将 MIT-BIH 心律失常数据集分为 4 类,提高了网络的泛化能力。Han 等^[6]提出 12 层残差网络诊断心肌梗塞,并将多导联的特征融合,取得了优秀的分类准确率。除此之外,一些研究考虑了 ECG 信号的时间特性,如柯丽等^[7]用长短期记忆网络(long short-term memory, LSTM)发掘 CNN 压缩过后的 ECG 信号更深层的联系。杨浩等^[8]分别用 CNN 和 BiLSTM 处理不同尺度的心电片段,兼顾了 ECG 的形态和动态特征。

收稿日期:2021-09-06

值得注意的是,由外界或生理带来的噪声会造成波形突变从而对特征点产生严重影响^[9],故上述研究工作在训练、预测前大多对原始数据集的 ECG 信号进行了降噪预处理,例如利用常规数字滤波器或小波变换进行去噪^[1,5-7,10-12]等。如何选择合适的降噪滤波器同时又不影响 ECG 信号有用的特征信息,这对研究者是一个较大的挑战。另一方面,对于文献[7-8]所使用的 LSTM 和 BiLSTM,在处理短时间小尺度的单一心拍 ECG 信号时实际并不能体现其优越性^[13],而且本研究还发现其对噪声的鲁棒性较弱。

2020 年 7 月出现的深度残差收缩网络(deep residual shrinkage network,DRSN)最初是用于处理带有噪声的振动信号^[14]。该网络实际是模拟一种噪声滤波器,相关的滤波器结构及参数由实际的含噪数据集训练自动获取。因此利用深度学习自动进行噪声消除模型的建立是一种非常有前途的方法。

本文在已有的 CNN 心电信号分类诊断模型基础上提出了一个改进的深度残差收缩网络(DRSN)特征提取模块,并结合全局平均池化(global average pooling,GAP)整合空间信息构建了一个 ECG 自动分类诊断模型。该模型既继承了残差网络在 ECG 特征提取方面高泛化性能和高正确率的特点,又具有很强的自动抗噪功能。用 MIT-BIH 心律失常数据集训练本文提出的模型,按照美国医疗器械促进协会(Association for the Advancement of Medical Instrumentation,AAMI)5 分类标准测试,准确率可达到 99.3%,已达到同类研究的先进水平。为评估改进的 DRSN+GAP 的抗噪性能,对测试数据集进行了模拟噪声污染处理,并与普通 CNN+GAP 模型进行抗噪对比实验,结果表明提出的模型对-9~12 dB 宽信噪比范围的含噪 ECG 信号具有较强的抗噪声能力。为进一步提升改进模型的抗多种强噪声性能,对训练数据进行混合噪声增强处理后再次训练该模型,结果表明改进后模型在宽信噪比范围内对心电信号的分类准确率得到了进一步的显著提高,完全能够自适应实现具有各类噪声的 ECG 信号的分类诊断功能。

1 模型设计

大部分的 ECG 分类诊断模型如图 1 所示。影响 ECG 分类诊断模型性能最重要部分的分别是特征提取部分和分类部分。对于特征提取部分,其内部主要由多个卷积、池化层构成,近年来出现的许多模型主要就是对这样的结构进行各种改进变异,以追求分类性能的不断提高,但其基本结构实际并没有本质变化。

本文从提高 ECG 分类诊断模型的性能以及自动抗噪声干扰两方面需求出发,对特征提取部分做了改进,构建了具有自动抗噪功能的 DRSN 心电信号分类诊断模型。

1.1 DRSN 分类诊断模型的设计

图 2 为改进后的深度残差收缩网络分类诊断模型框




图 1 ECG 分类诊断模型

图。归一化后的 ECG 信号首先经过一个由卷积核大小为 9 的一维卷积层和激活层共同组成的起始卷积层以扩展网络宽度,随后经过由 3 个残差模块级联组成的特征提取部分提取特征,最后由 GAP 和 2 个全连接层级联组成的分类部分得到分类结果。图 3 为特征提取部分中单个由 DRSN 构成的残差块的内部结构,表 1 提供了其详细描述。




图 2 算法基本框图

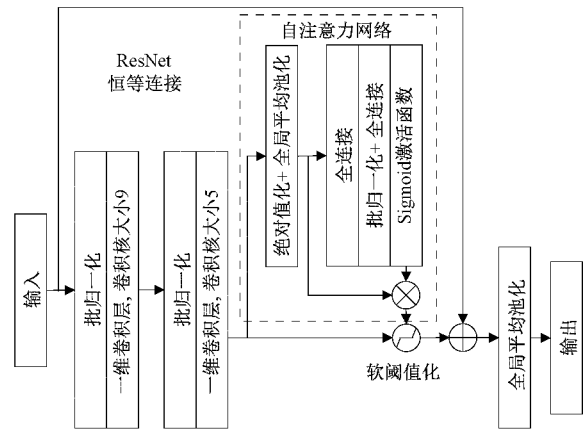


图 3 DRSN 残差块内部结构

表 1 DRSN 残差块的细节参数

结构	组件	输出长度	通道数
残差块	BN+1-D Convolution+Mish	300/75/18	32/64/128
	BN+1-D Convolution+Mish	300/75/18	32/64/128
	白注意力子网络		
	Absolute+GAP	32/64/128	
下采样	FC+BN+Mish	8/16/32	
	FC+Sigmoid	32/64/128	
1/2/3	Average Pooling	75/18/4	32/64/128

由表 1 可知,用于特征提取的 DRSN 残差块的基础部件包含卷积层、批归一化层和激活层。一般来说越大的卷积核获取的全局特征越好,但也伴随着计算量成比例上升

的问题。综合样本的数据点数和训练时间,设计每一个残差块由 2 个卷积层、2 个批归一化层、2 个激活层组成,卷积核大小为 9 和 5 并采用零填充保持卷积前后长度相等。

在模型的特征提取部分,本文做出的改进从模型结构上看,主要包含如下几点。

1) 特征提取模块采用了残差结构,防止梯度退化,提高泛化能力。

2) 残差块第 2 个卷积层之后加有 1 个自注意力子网络用来削弱冗余信息(与 ECG 信号分类特征无关的噪声信息),以提升网络对非噪声成分的注意力。

3) 每个残差模块后使用大小为 4 且跨距不重叠的平均池化,进行下采样以简化网络结构。

自注意力子网络是 DRSN 可以实现 ECG 自动降噪的主要原因,它的作用是训练得到一组简化通道信息的阈值。DRSN 将输入数据进行软阈值操作以抑制噪声。软阈值操作如图 4 和式(1)所示。




图 4 软阈值操作图示

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases} \quad (1)$$

其中, x 是输入向量; y 是输出向量; τ 是训练出的阈值,软阈值的导数非 0 即 1,这可以防止梯度爆炸和梯度消失。软阈值化是信号降噪领域里一个非常常见的概念,它将一段信号的值,朝着“0”的方向进行收缩。在 DRSN 特征提取模块中,经反复训练后,与分类有关的特征权重得到了不断增强,而与分类无关的、但与噪声相关的特征权重得到了较大地抑制,再通过软阈值的非线性变换可以将噪声的影响收缩为 0。

本文做出的第 2 个改进是采用 Mish^[15]作为激活函数。尽管 ReLU 激活函数已得到广泛应用,但是近年来提出的 Mish 激活函数因有着平滑的曲线,使得网络更容易优化,泛化性能更容易得到提升。与此同时,Mish 函数随着输入的增大没有上限,这也使之能有效防止梯度消失。考虑到这些优越性,本文在模型中使用 Mish 作为激活函数。Mish 激活函数如图 5 和式(2)所示。

$$f(x) = x \cdot \tanh(\ln(1 + e^x)) \quad (2)$$

综上所述,特征提取部分采用 DRSN,激活函数采用




图 5 Mish 激活函数图示

Mish 函数后,模型既强化了特征提取能力又具备了自动抗噪的功能。

1.2 分类部分设计

在模型的分类部分,本文做出的改进是用 1 个全局平均池化层和 2 个全连接层共同实现特征空间到样本标记空间的映射。根据表 1 可知,经过最后一个残差块的下采样操作后,数据由最初 $[1 \times 300]$ 的向量变为 $[\text{批大小}, \text{通道数}, \text{长度}] = [32, 128, 4]$ 的特征矩阵。GAP 操作通过通道上的平均让每个特征图的长度缩小到 1,以整合整体空间信息,从而简化全连接层的输入。相比将特征矩阵铺平后直接使用全连接层进行分类,引入 GAP 会减小全连接层将特征映射到类别的压力,同时防止模型过拟合。GAP 之后再采用连续两层全连接将长度为 128 点的特征向量映射到长度为 5 点的类别概率,实现对 ECG 样本的分类诊断。

2 实验与结果

2.1 ECG 数据处理

MIT-BIH 心律失常数据集是国际公认的标准 ECG 数据集,也是相关领域研究者最常使用的数据集^[16]。其包含了 48 条记录,每条记录长 30 min,采样率为 360 Hz。目前大多数 ECG 分类研究都是以一个心拍为单位,即以 R 波波峰为中心,左右各取一定数量的采样点所组成的数据序列。本文采用 Pan-Tompkins^[17]提出的实时 QRS 检测算法检测 R 波位置,再取 R 波波峰前后各 150 点共 300 个点作为一个样本(单个心拍时间约为 0.83 s),并按照 AAMI 的分类标准共得到 5 大类 109 160 个样本,数据分布情况如表 2 所示,且不再进行滤波处理。

表 2 ECG 类别分布

心拍类型	样本数
室上性异位搏动 Supraventricular (S)	2 789
室性异位搏动 Ventricular (V)	8 104
融合搏动 Fusion (F)	803
未知搏动 Unknown (Q)	8 036
非异位搏动 Normal beats(N)	89 428
共计 Total	109 160

2.2 实验设计

为检验提出的网络模型在 ECG 分类诊断以及抗噪两方面的性能,本文采用 MIT-BIH 心律不齐数据集直接获取的数据进行 AAMI 标准下的 5 分类实验进行验证。实验运行在配备有 Intel(R) Xeon(R) Silver 4214 CPU@2.20 GHz, GeForce RTX 2080 TI, 64 GB RAM 高性能电脑上。整个模型运行环境为 Pytorch 1.5.0 框架。随机选取数据集中的 20% 作为测试集,另外 80% 作为训练集。训练集被随机分为 5 个互斥的子集以满足 5 折交叉验证,每次训练有一个子集用来验证(16%),其余 4 个子集用来训练(64%),相同的操作总共进行 5 次,通过多次观察验证集的结果来微调超参数以达到最好的效果,同时观察网络是否出现过拟合,最后通过测试集表现分类性能。

1) 过拟合处理

随着模型的复杂程度加深,往往出现过拟合问题。为防止过拟合的发生,本文引入了批归一化(batch normalization, BN),BN 会将每个隐藏层的输入调整为均值为 0 方差为 1 的标准正态分布,之后再经过一个可训练的步骤将特征调整到理想的分布,使得非线性变换的输入值落入非线性函数对输入比较敏感的区域,加快收敛速度。

2) 损失函数和优化器


对于多分类问题一般使用交叉熵(cross entropy)函数作为损失函数,即用一个熵值量化系统的不确定性,训练的的目的就是根据这个熵值不断调整策略,最终实现熵值的最小化。实验采用 SGD 优化器,初始学习率设置为 0.01,在第 20 个训练轮次(epoch)之后,学习率每过 10 个 epoch 缩小 1/10。图 6 所示为 SGD 优化器下训练集和验证集的准确率和损失随 epoch 的变化,曲线在 epoch=50 之后平稳不变,故确定训练轮次为 50 个。

2.3 实验结果


多分类任务的模型评估通常使用准确率(Accuracy)、精确度(Precision)、灵敏度(Sensitive)、特异性(Specificity) 4 个指标。表 3 所示为 DRSN+GAP 模型对标准数据集的分类性能。由表 3 可知,DRSN+GAP 结构可以在标准数据集中达到 99.29% 的分类准确率,对于样本数量占比较小的融合搏动(F)类的精确度可以达到 89.82%,灵敏度可以达到 88.76%,证明模型的泛化能力良好。

表 4 自动分类算法在 MIT-BIH 上的比较

作者	方法	新拍划分	分类性能/%
Acharya 等 ^[1]	CNN	AAMI Total(109 449)	Acc: 94.03, Sen: 96.71 Spe: 91.54, Pre: 97.86
Kiranyaz 等 ^[2]	CNN	AAMI Total(83 831)	VEB: Acc: 99.0 SVEB: Acc: 97.6
柯丽等 ^[7]	CNN+LSTM	AAMI Total(100 700)	Acc: 99.23, Sen: 91.26 Spe: 99.57, Pre: 95.44
OH 等 ^[18]	CNN+LSTM	Normal, LBBB, RBBB, APB, PVC Total(16 601)	Acc: 98.1, Sen: 97.5 Spe: 98.7
本文提出的改进模型	DRSN+GAP	AAMI(Intra-patient) Total(109 160)	Acc: 99.29, Sen: 95.56 Spe: 99.57, Pre: 96.40



(a) 准确率随轮次数变化曲线



(b) 损失值随轮次数变化曲线

图 6 采用 SGD 优化器的准确率/损失变化曲线

表 3 DRSN+GAP 对 MIT-BIH 心律不齐数据的分类性能

性能指标	N	S	V	F	Q
Acc	99.44	99.65	99.70	99.84	99.96
Pre	99.62	95.27	97.47	89.82	99.81
Sen	99.69	91.29	98.44	88.76	99.63
Spe	98.29	99.88	99.80	99.92	99.99
Total	Acc=99.29, Pre=96.40, Sen=95.56, Spe=99.57				

表 4 所示为本文模型与已有的相关研究在 MIT-BIH 心律失常数据集上的性能比较数据,由表 4 可知提出的改进模型拥有相较更高的准确率,这主要得益于:1) 残差结构可以防止梯度退化,并且提高模型的泛化性能,自注意力网络和软阈值化处理削弱了与分类无关的冗余信息,强化了有效特征;2) Mish 激活函数使网络更容易优化;3) GAP 操作减轻全连接层的映射压力,防止模型过拟合。

3 抗噪性能分析

上述分析的是基于对原始数据集的训练和测试的实验结果。在实际信号采集过程中,心电信号往往包含多种强干扰噪声,容易影响模型对数据分布的学习与预测,从而降低模型对实际应用中信号分类的鲁棒性。为检验DRSN+GAP自适应降噪的性能,本文以引言中所述的多个深度学习 ECG 信号分类诊断模型为基础,综合形成了一个能体现这些模型共性的 CNN 网络作为抗噪性能的参照比较对象,细节参数如表 5 所示,并保持 CNN+GAP 的总体模型结构不变。


表 5 CNN 特征提取模块的细节参数

结构	组件	输出长度	通道数
卷积块	BN+1-D Convolution+Mish	300/75/1832/64/128	1/2/3
下采样	Average Pooling	75/18/4	32/64/128


3.1 噪声模拟

首先保持训练集不变,对测试集进行模拟加噪处理,以分析本文改进提出的与综合形成的两种模型抗噪能力。


对 ECG 信号影响最大的是工频噪声,其次是其他肌电、运动等产生的噪声。图 7(a)所示为来自于 MIT-BIH 心律失常数据集的 100.dat,是一条正常无疾病的 ECG 记录。信号采集地美国的工频干扰频率为 60 Hz。工频干扰



(a) 原始数据集信号



(b) 含工频噪声信号(SNR=3 dB)



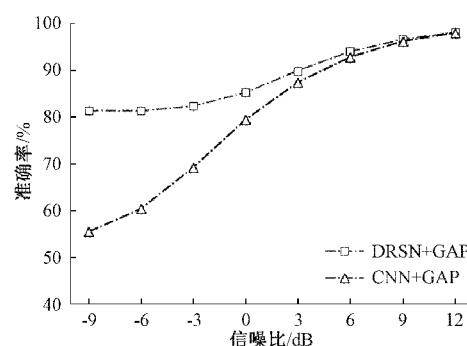
(c) 含高斯噪声信号(SNR=3 dB)

图 7 原始信号和被噪声污染的信号

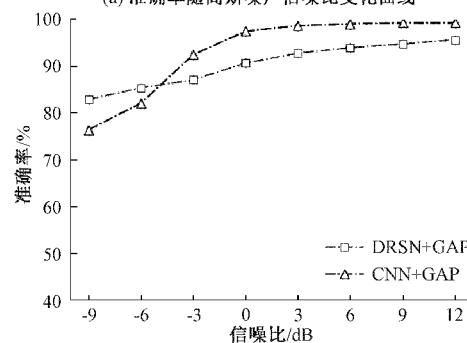
的增强方法是放大信号频谱中 60 Hz 频点处的幅度并保持频点相位不变,如图 7(b)所示。对于肌电、运动一类噪声,由于其频率分布广的特性,用增加高斯白噪声模拟^[19],如图 7(c)所示。

3.2 模型对不同噪声的抗噪能力

两种模型对加噪信号的抗噪性能如图 8 所示。图中横坐标表示对原始数据进行噪声污染后的测试集信噪比,纵坐标表示在该信噪比噪声污染的测试集上的分类准确率。模型用原始训练集训练。对于工频噪声,DRSN+GAP 的抗噪能力在噪声较小时虽然不及 CNN+GAP,但是整体变化曲线相对平稳,且随着噪声的增强,准确率逐渐高于 CNN+GAP。对于高斯噪声,DRSN+GAP 的抗噪能力则明显优于 CNN+GAP。实验结果证明 DRSN+GAP 对含噪信号的泛化能力高于 CNN+GAP。



(a) 准确率随高斯噪声信噪比变化曲线



(b) 准确率随工频噪声信噪比变化曲线

图 8 模型对两种含噪信号的抗噪性能(基于原始数据集训练)

3.3 噪声增强进一步提高模型性能

虽然 DRSN+GAP 对含噪信号的泛化能力很强,尤其是噪声信号比较强时,DRSN 特征提取部分对噪声成分的识别更加准确,相比一般 CNN 结构在抗噪方面更有优势。但是对于工频噪声污染的测试集在高信噪比下分类准确率仍然不够理想。另外,在实际应用场景中,信号往往不会只包含一类噪声信号且噪声的大小也不相同。为进一步提高 DRSN+GAP 的实用性,随机赋予训练集 $-9\sim 12$ dB 的工频及高斯混合噪声,用噪声增强后的训练集重新训练模型,然后分别在各种信噪比噪声污染的测试集上再次测试。如图 9 所示为混合噪声增强处理下训练本文提出的模型其分类准确率变化情况。由图 9 可知,训练集噪声增强后重新训练得到的 DRSN+GAP 模型对工频噪声和高斯噪声的抗噪能力得到了进一步提升,工频噪声的影响完全消除,高斯噪声也被更好地抑制,在 $-6\sim 12$ dB 加噪范围内分类准确率可达到 90% 以上。完全可以满足实际情况下采集到的信号受各种噪声影响的诊断场景。

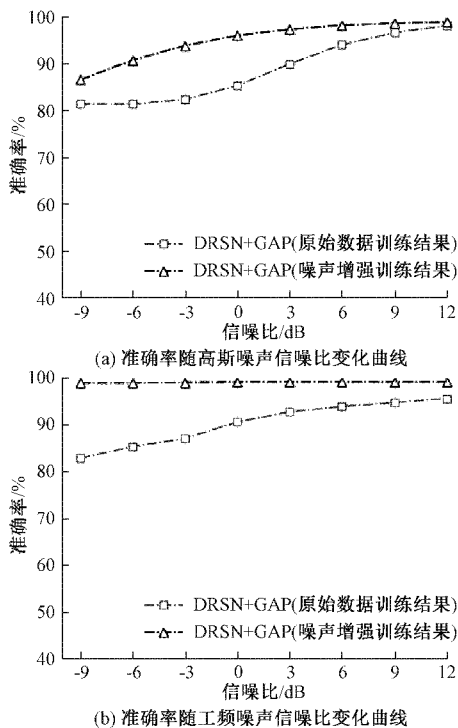


图 9 噪声增强前后模型抗噪性能对比

4 结 论

本文提出了一种能自动抗噪的高性能 ECG 分类检测网络模型。该模型由 DRSN 与 GAP 组合而成,其中 DRSN 用于特征提取,GAP 用于整合空间信息并将其经后续的全连接层进行分类。该模型对 MIT-BIH 的标准数据集分类准确率达到 99.3%,且对工频、高斯噪声具有很强的抗噪能力。对训练集进行噪声增强后,再次训练得到的该模型对于 $-6\sim 12$ dB 的宽信噪比范围下的心电信号分

类准确率均可达到 90% 以上,进一步提升了模型在宽信噪比范围下的分类诊断性能。本文不足之处在于:实验分析的仅是模拟出的噪声干扰数据,而真实场景下采集到的信号往往包含各种噪声成分且强度不同,所以今后的工作是从医院获取真实含噪的心电信号加以验证,再根据结果做进一步调整和优化。

参考文献

- [1] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats[J]. Computers in Biology and Medicine, 2017, 89: 389-396.
- [2] KIRANYAZ S, INCE T, GABBOUJ M. Real-time patient-specific ECG classification by 1-D convolutional neural networks[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(3): 664-75.
- [3] 刘光达,周葛,董梦坤,等.基于 FFNN 和 1D-CNN 的实时心律失常诊断系统与算法[J].电子测量与仪器学报, 2021, 35(3):35-42.
- [4] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Conference on Computer Vision and Pattern Recognition, IEEE, 2016: 770-778.
- [5] BRITO C, MACHADO A, SOUSA A. Electrocardiogram beat-classification based on a ResNet network [J]. Studies in Health Technology and Informatics, 2019, 264: 55-59.
- [6] HAN C, SHI L. ML-ResNet: A novel network to detect and locate myocardial infarction using 12 leads ECG [J]. Computer Methods and Programs in Biomedicine, 2020, DOI: 10.1016/j.cmpb.2019.105138.
- [7] 柯丽,王丹妮,杜强,等.基于卷积长短期记忆网络的心律失常分类方法[J].电子与信息学报, 2020, 42: 1990-1998.
- [8] 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.
- [9] SANDEEP R, KAILASH C R. ECG signal analysis using DCT-based DOST and PSO Optimized SVM[J]. IEEE Trans. Instrum. Meas., 2017, 66(3):470-480.
- [10] 李端,张洪欣,刘知青,等.电信号心律不齐识别[J].生物医学工程学报, 2019, 36(2):189-198.
- [11] ISIN A, OZDALILI S. Cardiac arrhythmia detection using deep learning[J]. Procedia Computer Science, 2017, 120: 268-275.
- [12] 梁盛德,王寻,梁金福.基于卷积神经网络和心电 QRS 波群的身份识别[J].电子测量与仪器学报, 2020, 32(4):1-10.
- [13] HANNUN A, 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.
- [14] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(7): 4681-4690.
- [15] MISRA D. Mish: A self regularized non-monotonic neural activation function[J]. *ArXiv Preprint*, 2019. ArXiv:1908.08681.
- [16] MURAT F, YILDIRIM O, TALO M, et al. Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review[J]. *Computers in Biology and Medicine*, 2020, DOI: 10.1016/j.compbiomed.2020.103726.
- [17] PAN J, TOMPKINS W J. A real-time QRS detection algorithm [J]. *IEEE Transactions on Biomedical Engineering*, 1985, BME-32(3): 230-236.
- [18] OH S L, NG E, TAN R S, et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats[J]. *Computers in Biology and Medicine*, 2018, 102: 278-287.
- [19] 刘春, 谢皓, 肖奕霖, 等. EWT 算法在 ECG 信号滤波中的研究[J]. *电子测量与仪器学报*, 2017, 31(11): 1835-1842.

作者简介

雷宇, 硕士研究生, 研究方向为模式识别、生物医学电子学。

E-mail: wytzx0540@163.com

徐寅林, 博士, 教授, 研究方向为生物医学电子学。

E-mail: xuyinlin@njnu.edu.cn