

基于希尔伯特黄变换和深度卷积神经网络的房颤检测

郭一楠 邵慧杰 巩敦卫* 李海泉 陈丽

(中国矿业大学人工智能研究院智慧医疗研究中心 徐州 221116)

(中国矿业大学信息与控制工程学院 徐州 221116)

(徐州医科大学第二附属医院呼吸与危重医学科 徐州 221006)

摘要: 房颤是一种常见的心律失常,其发病率会随着年龄增长而升高。因此,从心电(ECG)信号中尽早识别出房颤,有助于降低中风风险和心源性死亡率。为有效提高其检测准确率,该文提出一种基于希尔伯特黄变换(HHT)和深度卷积神经网络的房颤检测方法。1维的时域心电信号通过希尔伯特黄变换,转换为时频域信号,旨在通过时频分析,丰富原始信号的特征。进而,采用DenseNet深度卷积神经网络来处理精细的时频图,并在迭代过程中选出最佳检测模型。该方法获得的最佳检测模型在麻省理工学院-贝斯以色列医院(MIT-BIH)和2017年生理信号竞赛(2017 PhysioNet Challenge)的房颤数据集上分别取得了99.11%和97.25%的检测准确率。此外,该文将希尔伯特黄变换与其他时频分析方法以及稠密网络(DenseNet)与其他卷积神经网络进行了对比。相比于其他检测方法,实验结果表明希尔伯特黄变换和深度卷积神经网络(DCNN)为房颤检测提供了更加准确的识别方式。

关键词: 心电信号; 房颤; 希尔伯特黄变换; 深度卷积神经网络

中图分类号: R540.4+1; TN911.7

文献标识码: A

文章编号: 1009-5896(2022)01-0099-08

DOI: [10.11999/JEIT211171](https://doi.org/10.11999/JEIT211171)

Atrial Fibrillation Detection Based on Hilbert-Huang Transform and Deep Convolutional Neural Network

GUO Yinan SHAO Huijie GONG Dunwei LI Haiquan CHEN Li

(*Research Institute of Artificial Intelligence, China University of Mining and Technology, Xuzhou 221116, China*)

(*School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China*)

(*Department of Respiratory and Critical Care Medicine, Second Affiliated Hospital of Xuzhou Medical University, Xuzhou 221006, China*)

Abstract: Atrial fibrillation is a common arrhythmia and its morbidity increases with age. Thus, stroke risk and cardiogenic mortality can be significantly reduced by early atrial fibrillation detection from ElectroCardioGram (ECG). In order to improve effectively detection accuracy, a novel approach is proposed to detect atrial fibrillation based on Hilbert-Huang Transform(HHT) and deep convolutional neural network. HHT is employed to transform electrocardiogram from time domain to time-frequency domain so as to enrich the feature of original data. Following that, DenseNet is introduced to deal with the detailed graph and the best model is selected during the iteration. The optimal model obtained by the proposed method achieves 99.11% and 97.25% accuracy respectively on the Massachusetts Institute of Technology - Beth Israel Hospital(MIT-BIH) and 2017 PhysioNet Challenge atrial fibrillation databases. In addition, HHT and DenseNet are compared with other time-frequency analysis and convolutional neural networks, respectively. Compared with some existing methods, the results proved that atrial fibrillation detection by HHT and Deep Convolutional Neural Network(DCNN) obtains a high detection performance.

收稿日期: 2021-10-26; 改回日期: 2021-12-24; 网络出版: 2022-01-04

*通信作者: 巩敦卫 dwgong@vip.163.com

基金项目: 国家自然科学基金(61973305), 中国矿业大学中央高校基本科研业务费专项资金(2020ZDPY0302)

Foundation Items: The National Natural Science Foundation of China (61973305), Fundamental Research Funds of China University of Mining and Technology (2020ZDPY0302)

Key words: ElectroCardioGram (ECG); Atrial fibrillation; Hilbert-Huang Transform (HHT); Deep Convolutional Neural Network (DCNN)

1 引言

房颤是一种常见的心律失常,其发病率会在超过60岁以后每10年就增长1倍^[1]。房颤会导致中风、心力衰竭和其他心血管疾病的发病率增加^[2]。房颤会导致女性全因死亡率增加2倍,男性增加1.5倍^[3]。因此,房颤的早期检测对患者尽早获得治疗至关重要。

心电图(ElectroCardioGram, ECG)是一种方便快捷且非侵入式的检测方法,已经广泛应用于临床。12导联的ECG是当前识别房颤的金标准^[4]。大体上,ECG可以分为P波、Q波、R波、S波、T波和U波。不规则的R-R间期和由P波转化成的F波可以有效识别房颤^[5]。然而,常规的12导联ECG在医院中只能记录短时的ECG信号,不一样的身体状况导致该ECG信号不能完全真实地反映患者在医院外的心律失常,导致漏检^[6]。近年来,随着单导联ECG可穿戴设备的快速发展,长时、低成本、实时的心电信号已能在医院外及时获取。由此,迫切需要设计基于单导联ECG信号的房颤检测方法,为患者提供更加及时、准确的病程指导。

针对ECG房颤检测,研究人员通常基于人工提取的特征来进行识别。Ebrahimzadeh等人^[7]采用心律变异性的线性、非线性和时频特征进行房颤检测,分别取得了98.21%, 95.55%, 100%的准确率、特异性和灵敏性。Mohebbi等人^[8]采用2个单谱特征、6个双谱特征和4个非线性特征,取得了96.3%, 93.1%的房颤检测灵敏性和特异性。基于人工提取特征的房颤检测虽然取得较好的检测性能,但是计算相对费时,且特征选择依赖大量的人类经验。此外,可穿戴设备采集的心电信号会被电磁场和运动伪迹干扰,直接影响人工提取的特征,导致显著的检测误差。人与人之间的身体状况差异,也使人工提取的特征往往不具有普适性。

相比于传统的房颤检测方法,基于卷积神经网络(Convolutional Neural Network, CNN)的检测方法具有更强的特征提取能力,并已经广泛应用于信号分类中。Acharya等人^[9]通过CNN自动地区分两秒心电信号的类型,并取得了92.5%, 98.09%, 93.13%的准确率、灵敏性和特异性。蒋芳芳等人^[10]在不同长度的心电片段和不同深度的CNN中寻找最佳组合,显著提高了识别准确率。为进一步提升CNN的表达能力, Petmezas等人^[11]将CNN和长短期记忆神经网络(Long Short-Term Memory, LSTM)构

成的混合网络,结合焦点损失函数处理心电数据的不平衡问题,将灵敏性和特异性提升到97.87%和99.29%。杨萍等人^[12]、顾佳艳等人^[13]先后提出集成CNN-LSTM网络和由残差网络、双向LSTM与多头注意力层构成的混合网络,用于实时房颤检测。Fan等人^[14]则利用具有不同卷积核的两路CNN提取不同尺寸特征,取得了98.13%, 93.77%和98.77%的准确率、灵敏性和特异性。

在设计不同模型结构的同时,研究人员还引入时频分析,通过丰富原始信号的信息来改善房颤检测算法的性能。Lai等人^[5]将RR序列和F波频谱相结合作为CNN的输入,显著提高了检测准确性。Xia等人^[15]则采用短时傅里叶变换(Short-Time Fourier Transform, STFT)和标准小波变换(Wavelet Transform, WT)将1维的心电信号转换为2维的时频信号。Ma等人^[16]引入改进的频率切片WT,结合人工提取特征来训练CNN和支持向量机混合模型,提高模型的泛化能力和鲁棒性。杨淑莹等人^[17]利用小波分解和1维谷歌网络(GoogLeNet),缓解了计算效率低、收敛困难和模型退化的问题。然而,在设计模型架构和引入时频分析时,现有的房颤检测算法仍然存在以下不足:

(1) 传统的时频分析方法通常基于积分变换,如STFT或WT等。这类时频分析方法容易产生频谱泄漏,无法很好地刻画局部细节。

(2) 对1维信号进行时频转换,虽然可以丰富其特征,但是也会形成高维度特征空间,需要采用更加复杂的神经网络模型提取其特征,从而容易产生梯度消失,导致训练过程难以收敛。

基于以上原因,本文结合希尔伯特黄变换(Hilbert-Huang Transform, HHT)^[18]和深度卷积神经网络(Deep Convolutional Neural Network, DCNN),构建了一种新型房颤检测模型。HHT将1维的时域心电信号转换为2维的时频矩阵。传统的基于积分变换时频分析方法(如STFT和WT)会受到时间分辨率和频率分辨率的限制,容易导致伪影产生。与之不同, HHT能获得瞬时频率和幅度,获得的时频矩阵更加精细且不会发生频谱泄漏。因此, HHT可以更有效地描述ECG的局部细节。基于此,引入 DenseNet^[19]卷积神经网络来处理高精度的时频矩阵,可以有效缓解梯度消失、进行特征复用,并且所提算法在未被使用的验证集上经过了检验。

2 结合希尔伯特黄变换和深度卷积神经网络的房颤检测

2.1 希尔伯特黄变换

存在房颤的心电信号中，F波可能存在不同的振幅、形态和频率^[20]。此外，在运动伪迹的影响下，心电信号的基线也会随时间发生改变^[21]。因此，心电信号可以看作一类非平稳时间序列。采用传统的频域分析方法处理心电信号时，难以提取到该类信号的有效特征。而HHT结合了经验模态分解(Empirical Mode Decomposition, EMD)和希尔伯特变换(Hilbert Transform, HT)，可以计算瞬时频率和幅度，适合处理心电信号这一类非平稳时间序列。因此，本文采用HHT将只包含时域信息的原始ECG信号转换为包含时域和频域对应关系的时频图。首先，采用EMD将多模态心电信号分解为若干个单一模态的信号；其次，通过HT计算出每个模态的瞬时频率和幅度；最后，综合所有模态信息，获得心电信号的时频图。

2.1.1 经验模态分解

原始信号 $x(t)$ 通过EMD可以得到若干个本征模态函数(Intrinsic Mode Function, IMF)，每个IMF必须满足两个限制：(1)极值点和零点的数量之差不超过1；(2)在任意时刻点，局部最大值的包络线和局部最小值的包络线之间的均值为0。对原始信号 $x(t)$ 的EMD计算过程如表1所示。

EMD分解的结果为

$$x(t) = \sum_i^N \text{IMF}_i(t) + r(t) \quad (1)$$

其中， N 表示可以从原始信号分解出来的IMF数量， $\text{IMF}_i(t)$ 代表了第 i 个IMF， $r(t)$ 为无法被继续分解的残余分量。

2.1.2 希尔伯特变换

在经过EMD分解后，HT被用来对每一个IMF计算瞬时频率和幅度。记HT的脉冲响应为

$$h(t) = \frac{1}{\pi t} \quad (2)$$

第 i 个IMF的HT表示为

$$H(\text{IMF}_i(t)) = h(t) * \text{IMF}_i(t) \quad (3)$$

其中， $H(\cdot)$ 作为HT的函数， $*$ 为卷积计算。由此可知

$$Z_i(t) = \text{IMF}_i(t) + jH(\text{IMF}_i(t)) = a_i(t)e^{j\theta_i(t)} \quad (4)$$

其中

$$a_i(t) = \sqrt{\text{IMF}_i^2(t) + H^2(\text{IMF}_i(t))} \quad (5)$$

$$\theta_i(t) = \arctan \frac{H(\text{IMF}_i(t))}{\text{IMF}_i(t)} \quad (6)$$

因此，瞬时频率可以表示为

$$F_i(t) = \frac{d\theta_i(t)}{dt} \quad (7)$$

第 i 个IMF的瞬时频率和幅度分别为 $F_i(t)$ 和 $a_i(t)$ 。结合所有IMF的瞬时频率和幅度，可以得到一个2维的时频图。

2.2 深度卷积神经网络

本文利用DenseNet来处理具有高精度的时频图。DenseNet由大量的稠密块组成。在稠密块中，每层网络都会和其他层之间通过前馈方式连接，如图1所示。DenseNet通过不同层之间的跳连接可以缓解梯度消失并使网络设计更深。另一个方面，DenseNet将不同通道的特征连接起来实现特

表 1 EMD算法步骤

步骤 1	$r(t) = x(t)$
步骤 2	$s(t) = r(t)$
步骤 3	求 $s(t)$ 的极大值和极小值。
步骤 4	根据极大极小值分别计算上包络线 $e_{\max}(t)$ 和下包络线 $e_{\min}(t)$ 。
步骤 5	计算两个包络线的均线 $m(t) = [e_{\max}(t) + e_{\min}(t)]/2$ 。
步骤 6	计算 $h(t) = r(t) - m(t)$ 。如果 $h(t)$ 满足上述两个限制，则 $h(t)$ 为其中一个IMF，否则令 $s(t) = r(t) - h(t)$ 返回步骤3。
步骤 7	计算 $r(t) = r(t) - s(t)$ ，如果 $r(t)$ 有超过两个极值点，返回步骤2去计算另一个IMF，否则分解结束。

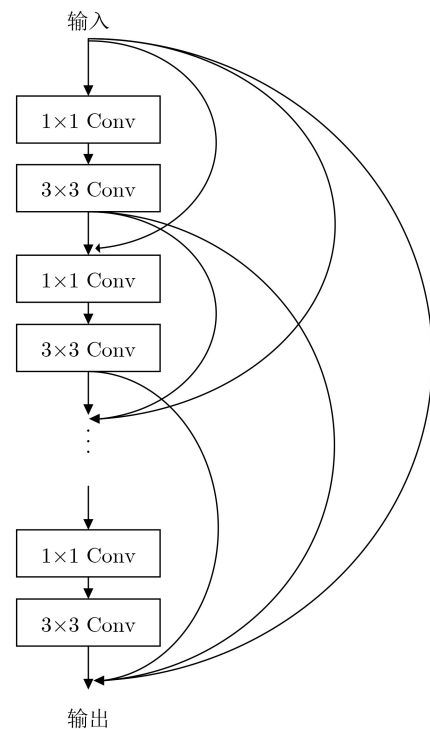


图 1 稠密块结构

征复用。这两个方面可以让DenseNet获得强大的特征提取能力。本文采用的DenseNet结构如表2所示。

表2 DenseNet结构

层	输出特征图	结构
Conv1	48×623	7×7 conv, 64, stride=2, padding=1
Pool1	24×312	2×2 max pool
Dense Block1	24×312	$\left[\begin{array}{c} 1 \times 1 \text{ conv, } 128 \\ 3 \times 3 \text{ conv, } 32, \text{ padding} = 1 \end{array} \right] \times 6$
Conv2	24×312	1×1 conv, 128
Pool2	12×156	2×2 avg pool
Dense Block2	12×156	$\left[\begin{array}{c} 1 \times 1 \text{ conv, } 128 \\ 3 \times 3 \text{ conv, } 32, \text{ padding} = 1 \end{array} \right] \times 12$
Conv3	12×156	1×1 conv, 256
Pool3	6×78	2×2 avg pool
Dense Block3	6×78	$\left[\begin{array}{c} 1 \times 1 \text{ conv, } 128 \\ 3 \times 3 \text{ conv, } 32, \text{ padding} = 1 \end{array} \right] \times 32$
Conv4	6×78	1×1 conv, 640
Pool4	3×39	2×2 avg pool
Dense Block4	3×39	$\left[\begin{array}{c} 1 \times 1 \text{ conv, } 128 \\ 3 \times 3 \text{ conv, } 32, \text{ padding} = 1 \end{array} \right] \times 32$
Pool1	1×1	3×39 avg pool
flatten	1×1664	
Fully connected layer	1×2	

3 实验结果与分析

本文分别采用了MIT-BIH房颤数据集(MIT-BIH Atrial Fibrillation DataBase, AFDB)^[22,23]和2017 PhysioNet Challenge 房颤数据集来验证提出方法的有效性。其中, AFDB数据集包括23个长时的ECG, 大多数ECG来自阵发性房颤患者。每个ECG包含两通道且以250 Hz的采样率采集。在本文中, 只采用标记为房颤和窦性心律的第一导联ECG, 并将ECG以每1250个采样点进行分割。2017 PhysioNet Challenge数据集总共包含8528个

30~60 s长度的ECG片段, 其中包括5154个窦性节律、771个房颤、2557个其他节律以及46个噪声片段。每段ECG的采样频率均为300 Hz。本文仅使用窦性节律和房颤的ECG, 并将ECG以1250个采样点进行分割。数据集的具体构成如表3和表4所示, 图2展示了窦性节律和房颤的ECG片段。

表3 AFDB数据集

	训练集	验证集	测试集	总计
房颤	24413	3052	3051	30516
窦性节律	56224	7028	7028	70280
总计	80637	10080	10079	100796

表4 2017 PhysioNet Challenge数据集

	训练集	验证集	测试集	总计
房颤	4383	548	548	5479
窦性节律	30012	3752	3751	37515
总计	34395	4300	4299	42994

为合理评价模型性能, 本文采用准确率(Accuracy, ACC)、灵敏性(Sensitivity, SE)和特异性(Specificity, SP)3个性能指标。记真正例为TP(True Positive)、假正例为FP(False Positive)、假反例为FN(False Negative)和真反例为TN(True Negative), 上述3个性能指标定义为

$$ACC = (TP + TN)/(TP + TN + FP + FN) \quad (8)$$

$$SE = TP/(TP + FN) \quad (9)$$

$$SP = TN/(TN + FP) \quad (10)$$

面向两类数据集, 分别采用STFT, WT和HHT, 将1维心电信号转换为时频图, 如图3所示。可见, 相比于STFT和WT, 本文所采用HHT生成的100×1250 2维时频矩阵具有更清晰的局部细节, 不会产生由频谱泄露导致的伪影。分别基于上述3种时频分析方法和传统1维(1 Dimensional, 1-D)心电, 采用DenseNet对两类数据集获得的识




图2 ECG片段

别准确率，如图4所示。显然，所提方法可以获得最好的房颤识别性能，这是因为通过HHT时频转换能够更清晰地反映局部特征。

可穿戴设备采集的ECG信号可能会受到电磁和运动伪迹的干扰。如图5(a)所示，当人体运动后，ECG信号幅度会在短时间发生剧烈变化，在人体恢复静止时，ECG会慢慢地回复到正常状态。在此期间，ECG信号的方差、均值等手动提取特征会严重失真。此外，如图5(b)所示，电磁干扰会导致ECG信号出现细小的毛刺，影响到信号熵的计算。本文在AFDB数据集上分别选取了53段受运动伪迹影响和279段受电磁干扰影响的ECG片

段作为数据集，单独进行实验来验证模型的鲁棒性，实验结果见表5和表6。对比算法包括随机森林、支持向量机和Adaboost，它们都采用模糊熵、样本熵、符号序列熵、基本尺度熵，以及R-R间期的均值和方差作为特征，实施模型训练。当心电信号存在运动伪迹和电磁干扰时，与传统基于手动提取特征的方法相比，本文所提方法在准确率上提升了15.14%和3.94%，特异性提高了23.08%和4.58%，灵敏性改善了7.41%和3.18%。结果表明，基于深度学习算法的房颤检测在信号出现异常时更具有鲁棒性。

为了验证DenseNet对时频图的处理能力，引




图3 不同变换方法的时频图

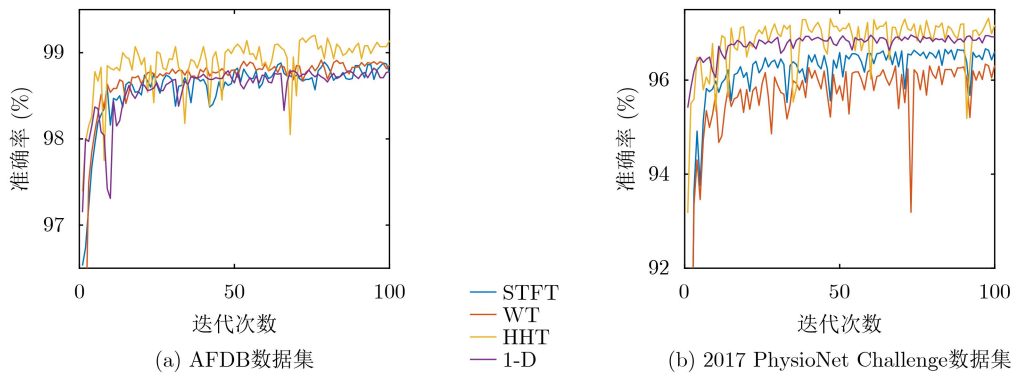


图4 3种时频分析和1维心电在验证集上的准确率曲线




图5 受干扰的ECG片段

表5 运动伪迹时模型鲁棒性验证(%)

对比算法	ACC	SP	SE
本文	77.40	84.62	70.37
随机森林	60.38	57.69	62.96
支持向量机	56.60	53.85	59.26
Adaboost	62.26	61.54	62.96

表6 电磁干扰时模型鲁棒性验证(%)

对比算法	ACC	SP	SE
本文	97.85	98.04	97.62
随机森林	93.91	93.46	94.44
支持向量机	87.81	89.29	86.33
Adaboost	91.40	92.86	89.93

入常用的VGG^[24]和ResNet^[25]进行对比。VGG, ResNet和DenseNet分别在两个数据集上的准确率如图6所示。可见DenseNet的正确率曲线大体高于另外两种。在AFDB数据集上,最佳模型是经过76次迭代的DenseNet,取得了99.2%的准确率、98.57%的

灵敏性和99.47%的特异性。在2017 PhysioNet Challenge数据集上,最佳模型是迭代了98次的DenseNet,取得了97.32%的准确率、81.75%的灵敏性和99.64%的特异性。

为避免过拟合,模型在测试集上检验真实性能并和其他算法进行比较。表7对比了所提方法和其他常用算法的识别性能。可见,本文所提方法在AFDB和2017 PhysioNet Challenge数据集都具有最佳的识别准确性、特异性和次优的灵敏性。在对比算法中, Xia等人^[15]和Ebrahimzadeh等人^[7]分别采用WT生成的时频图和手动提取的心律变异性特征,对房颤加以检测;其他方法均基于1维心电信号,采用神经网络实现房颤识别。而本文将HHT和DenseNet相结合,取得了最好的综合识别性能。特别是,本文采用的HHT和Xia等人^[15]采用的WT通过时频分析丰富了原始信号,有效提高了识别正确率。而Ebrahimzadeh等人^[7]手动提取特征,从而使识别正确率受限。此外, Jin等人^[27]采用ResNet缓解梯度消失,实现房颤检测,取得了

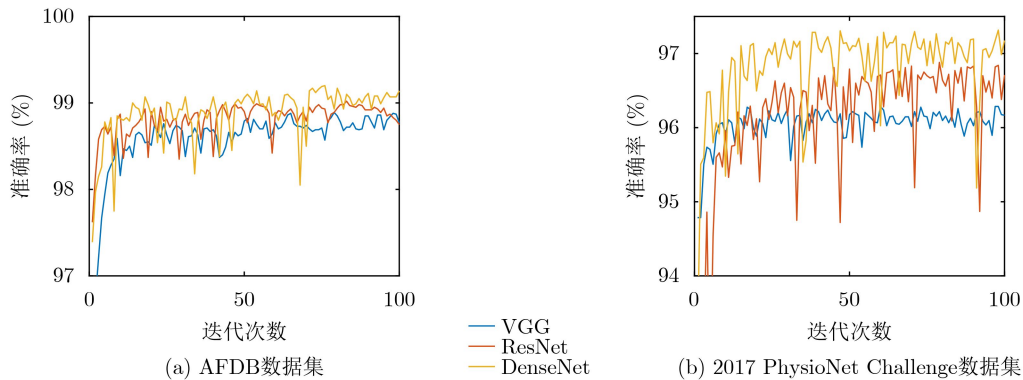


图6 VGG, ResNet和DenseNet在验证集上的准确率曲线

表7 不同算法的性能比较(%)

数据集	文献	ACC	SP	SE
AFDB	文献[11]	-	99.29	97.87
	文献[15]	98.79	97.87	98.63
	文献[26]	98.51	98.76	98.14
	文献[27]	98.84	98.75	98.97
	文献[28]	98.51	98.67	98.32
	文献[7]	98.21	95.55	100
	文献[29]	97.21	97.08	97.34
	文献[30]	97.1	96.29	98.17
	本文	99.11	99.29	98.69
2017 PhysioNet Challenge	文献[31]	96.99	98.42	81.97
	文献[32]	-	98.6	72.7
	文献[14]	97.19	98.84	80.26
	本文	97.25	99.68	80.66

相对较好的正确率。相比而言, DenseNet不仅可以缓解梯度消失, 还可以更有效地利用特征, 并且图6所示实验结果表明DenseNet性能优于ResNet。综上所述, 本文所提方法具有最优的综合性能。虽然所提方法通过HHT的时频图提供更加精细的信号信息, 但是也导致模型训练时需要较大的算力。

4 结束语

本文采用HHT将1维ECG信号转换为2维时频矩阵, 进而采用DenseNet实现房颤识别, 从而深入挖掘原始信号中的时间和频率信息。通过在两类数据集上的实验对比可见, 所提方法在房颤检测中具有最好的识别性能, 具有一定的临床应用潜力。然而, 相比而言, 所提方法需要相对较大的算力。为进一步提高所提时频分析方法的性能, DenseNet网络的最优结构搜索将是我们未来的研究工作。

参考文献

- [1] YOUNG M. Atrial fibrillation[J]. *Critical Care Nursing Clinics of North America*, 2019, 31(1): 77–90. doi: [10.1016/j.cnc.2018.11.005](https://doi.org/10.1016/j.cnc.2018.11.005).
- [2] HENDRIKS J M L and HEIDBÜCHEL H. The management of atrial fibrillation: An integrated team approach—insights of the 2016 European Society of Cardiology guidelines for the management of atrial fibrillation for nurses and allied health professionals[J]. *European Journal of Cardiovascular Nursing*, 2019, 18(2): 88–95. doi: [10.1177/1474515118804480](https://doi.org/10.1177/1474515118804480).
- [3] KIRCHHOF P, BENUSSI S, KOTECHEA D, et al. 2016 ESC Guidelines for the management of atrial fibrillation developed in collaboration with EACTS[J]. *Kardiol Pol*, 2016, 74(12): 1359–1469. doi: [10.5603/KP.2016.0172](https://doi.org/10.5603/KP.2016.0172).
- [4] FREEDMAN B, CAMM J, CALKINS H, et al. Screening for atrial fibrillation: A report of the AF-SCREEN international collaboration[J]. *Circulation*, 2017, 135(19): 1851–1867. doi: [10.1161/CIRCULATIONAHA.116.026693](https://doi.org/10.1161/CIRCULATIONAHA.116.026693).
- [5] LAI Dakun, ZHANG Xinshu, ZHANG Yifei, et al. Convolutional neural network based detection of atrial fibrillation combing R-R intervals and F-wave frequency spectrum[C]. The 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Berlin, Germany, 2019: 4897–4900. doi: [10.1109/EMBC.2019.8856342](https://doi.org/10.1109/EMBC.2019.8856342).
- [6] DUNCKER D, DING W Y, ETHERIDGE S, et al. Smart wearables for cardiac monitoring—real-world use beyond atrial fibrillation[J]. *Sensors*, 2021, 21(7): 2539. doi: [10.3390/s21072539](https://doi.org/10.3390/s21072539).
- [7] EBRAHIMZADEH E, KALANTARI M, JOULANI M, et al. Prediction of paroxysmal Atrial Fibrillation: A machine learning based approach using combined feature vector and mixture of expert classification on HRV signal[J]. *Computer Methods and Programs in Biomedicine*, 2018, 165: 53–67. doi: [10.1016/j.cmpb.2018.07.014](https://doi.org/10.1016/j.cmpb.2018.07.014).
- [8] MOHEBBI M and GHASSEMIAN H. Prediction of paroxysmal atrial fibrillation based on non-linear analysis and spectrum and bispectrum features of the heart rate variability signal[J]. *Computer Methods and Programs in Biomedicine*, 2012, 105(1): 40–49. doi: [10.1016/j.cmpb.2010.07.011](https://doi.org/10.1016/j.cmpb.2010.07.011).
- [9] ACHARYA U R, FUJITA H, LIH O S, et al. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network[J]. *Information Sciences*, 2017, 405: 81–90. doi: [10.1016/j.ins.2017.04.012](https://doi.org/10.1016/j.ins.2017.04.012).
- [10] 蒋芳芳, 徐敬傲, 李任, 等. 基于CNN的心冲击信号阵发性房颤自动检测方法[J]. 东北大学学报:自然科学版, 2019, 40(11): 1539–1542,1548. doi: [10.12068/j.issn.1005-3026.2019.11.004](https://doi.org/10.12068/j.issn.1005-3026.2019.11.004).
JIANG Fangfang, XU Jing'ao, LI Ren, et al. Automatic detection method of paroxysmal atrial fibrillation for ballistocardiogram based on CNN[J]. *Journal of Northeastern University: Natural Science*, 2019, 40(11): 1539–1542,1548. doi: [10.12068/j.issn.1005-3026.2019.11.004](https://doi.org/10.12068/j.issn.1005-3026.2019.11.004).
- [11] PETMEZAS G, HARIS K, STEFANOPOULOS L, et al. Automated atrial fibrillation detection using a hybrid CNN-LSTM network on imbalanced ECG datasets[J]. *Biomedical Signal Processing and Control*, 2021, 63: 102194. doi: [10.1016/j.bspc.2020.102194](https://doi.org/10.1016/j.bspc.2020.102194).
- [12] 杨萍, 王丹, 康子健, 等. 基于模式识别和集成CNN-LSTM的阵发性房颤预测模型[J]. 浙江大学学报:工学版, 2020, 54(5): 1039–1048. doi: [10.3785/j.issn.1008-973X.2020.05.023](https://doi.org/10.3785/j.issn.1008-973X.2020.05.023).
YANG Ping, WANG Dan, KANG Zijian, et al. Prediction model of paroxysmal atrial fibrillation based on pattern recognition and ensemble CNN-LSTM[J]. *Journal of Zhejiang University: Engineering Science*, 2020, 54(5): 1039–1048. doi: [10.3785/j.issn.1008-973X.2020.05.023](https://doi.org/10.3785/j.issn.1008-973X.2020.05.023).
- [13] 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. doi: [10.15888/j.cnki.csa.007885](https://doi.org/10.15888/j.cnki.csa.007885).
GU Jiayan, JIANG Mingfeng, LI Yang, et al. Atrial fibrillation detection using multi-head attention mechanism[J]. *Computer Systems & Applications*, 2021, 30(4): 17–24. doi: [10.15888/j.cnki.csa.007885](https://doi.org/10.15888/j.cnki.csa.007885).
- [14] FAN Xiaomao, YAO Qihang, CAI Yunpeng, et al. Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings[J]. *IEEE Journal of Biomedical and Health Informatics*, 2018, 22(6): 1744–1753. doi: [10.1109/JBHI.2018.2858789](https://doi.org/10.1109/JBHI.2018.2858789).
- [15] XIA Yong, WULAN Naren, WANG Kuanquan, et al. Detecting atrial fibrillation by deep convolutional neural

- networks[J]. *Computers in Biology and Medicine*, 2018, 93: 84–92. doi: [10.1016/j.combiomed.2017.12.007](https://doi.org/10.1016/j.combiomed.2017.12.007).
- [16] MA Caiyun, WEI Shoushui, CHEN Tongshuai, *et al.* Integration of results from convolutional neural network in a support vector machine for the detection of atrial fibrillation[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 2504610. doi: [10.1109/TIM.2020.3044718](https://doi.org/10.1109/TIM.2020.3044718).
- [17] 杨淑莹, 桂彬彬, 陈胜勇. 基于小波分解和1D-GoogLeNet的心律失常检测[J]. *电子与信息学报*, 2021, 43(10): 3018–3027. doi: [10.11999/JEIT200774](https://doi.org/10.11999/JEIT200774).
YANG Shuying, GUI Binbin, and CHEN Shengyong. Arrhythmia detection based on wavelet decomposition and 1D-GoogLeNet[J]. *Journal of Electronics & Information Technology*, 2021, 43(10): 3018–3027. doi: [10.11999/JEIT200774](https://doi.org/10.11999/JEIT200774).
- [18] HUANG N E, SHEN Zheng, LONG S R, *et al.* The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings of the Royal Society A:Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903–995. doi: [10.1098/rspa.1998.0193](https://doi.org/10.1098/rspa.1998.0193).
- [19] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, *et al.* Densely connected convolutional networks[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, New York, USA, 2017: 2261–2269. doi: [10.1109/CVPR.2017.243](https://doi.org/10.1109/CVPR.2017.243).
- [20] 杨永春, 廖红英, 尹晓妹. 远程心电监测系统在阵发性房颤监测中的应用价值[J]. *检验医学与临床*, 2021, 18(19): 2824–2826. doi: [10.3969/j.issn.1672-9455.2021.19.010](https://doi.org/10.3969/j.issn.1672-9455.2021.19.010).
YANG Yongchun, LIAO Hongying, and YIN Xiaoshu. Application value of remote ECG monitoring system in monitoring paroxysmal atrial fibrillation[J]. *Laboratory Medicine and Clinic*, 2021, 18(19): 2824–2826. doi: [10.3969/j.issn.1672-9455.2021.19.010](https://doi.org/10.3969/j.issn.1672-9455.2021.19.010).
- [21] 胡振原, 刘澄玉, 李建清. 一种可消除运动伪迹的可穿戴心电监测系统[J]. *电子测量技术*, 2020, 43(15): 72–78. doi: [10.19651/j.cnki.emt.2004492](https://doi.org/10.19651/j.cnki.emt.2004492).
HU Zhenyuan, LIU Chengyu, and LI Jianqing. Wearable ECG detection system for eliminating motion artifacts[J]. *Electronic Measurement Technology*, 2020, 43(15): 72–78. doi: [10.19651/j.cnki.emt.2004492](https://doi.org/10.19651/j.cnki.emt.2004492).
- [22] MOODY G B and MARK R R. A new method for detecting atrial fibrillation using R-R intervals[J]. *Computers in Cardiology*, 1983, 10: 227–230.
- [23] GOLDBERGER A L, AMARAL L A N, GLASS L, *et al.* PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): e215–e220. doi: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215).
- [24] SIMONYAN K and ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. The 3rd International Conference on Learning Representations, San Diego, USA, 2015.
- [25] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [26] JIN Yanrui, QIN Chengjin, HUANG Yixiang, *et al.* Multi-domain modeling of atrial fibrillation detection with twin attentional convolutional long short-term memory neural networks[J]. *Knowledge-Based Systems*, 2020, 193: 105460. doi: [10.1016/j.knsys.2019.105460](https://doi.org/10.1016/j.knsys.2019.105460).
- [27] JIN Yanrui, QIN Chengjin, LIU Jinlei, *et al.* A novel domain adaptive residual network for automatic atrial fibrillation detection[J]. *Knowledge-Based Systems*, 2020, 203: 106122. doi: [10.1016/j.knsys.2020.106122](https://doi.org/10.1016/j.knsys.2020.106122).
- [28] FAUST O, SHENFIELD A, KAREEM M, *et al.* Automated detection of atrial fibrillation using long short-term memory network with RR interval signals[J]. *Computers in Biology and Medicine*, 2018, 102: 327–335. doi: [10.1016/j.combiomed.2018.07.001](https://doi.org/10.1016/j.combiomed.2018.07.001).
- [29] MA Fengying, ZHANG Jingyao, CHEN Wei, *et al.* An automatic system for atrial fibrillation by using a CNN-LSTM Model[J]. *Discrete Dynamics in Nature and Society*, 2020, 2020: 3198783. doi: [10.1155/2020/3198783](https://doi.org/10.1155/2020/3198783).
- [30] ANDERSEN R S, PEIMANKAR A, and PUTHUSSERYPADY S. A deep learning approach for real-time detection of atrial fibrillation[J]. *Expert Systems with Applications*, 2019, 115: 465–473. doi: [10.1016/j.eswa.2018.08.011](https://doi.org/10.1016/j.eswa.2018.08.011).
- [31] BEHAR J A, ROSENBERG A A, YANIV Y, *et al.* Rhythm and quality classification from short ECGs recorded using a mobile device[C]. 2017 Computing in Cardiology (CinC), Rennes, France, 2017, doi: [10.22489/CinC.2017.165-056](https://doi.org/10.22489/CinC.2017.165-056).
- [32] LIMAM M and PRECIOSO F. Atrial fibrillation detection and ECG classification based on convolutional recurrent neural network[C]. 2017 Computing in Cardiology (CinC), Rennes, France, 2017, doi: [10.22489/CinC.2017.171-325](https://doi.org/10.22489/CinC.2017.171-325).
- 郭一楠: 女, 1975年生, 教授, 研究方向为智能数据感知与分析、群智优化与控制。
- 邵慧杰: 男, 1997年生, 硕士生, 研究方向为模式识别与心电信号处理。
- 巩敦卫: 男, 1970年生, 教授, 研究方向为智能优化与控制。
- 李海泉: 男, 1978年生, 主任医师, 研究方向为呼吸系统疾病的诊断与治疗。
- 陈 丽: 女, 1969年生, 主任医师, 研究方向为职业性尘肺的诊断治疗及呼吸系统疾病的诊断治疗。