



(12)发明专利申请

(10)申请公布号 CN 110840402 A

(43)申请公布日 2020.02.28

(21)申请号 201911133626.9

(22)申请日 2019.11.19

(71)申请人 山东大学

地址 250061 山东省济南市历下区经十路
17923号

(72)发明人 魏守水 马彩云 陈永超

(74)专利代理机构 济南圣达知识产权代理有限公司 37221

代理人 黄海丽

(51)Int.Cl.

A61B 5/00(2006.01)

A61B 5/0402(2006.01)

G06K 9/00(2006.01)

G06K 9/62(2006.01)

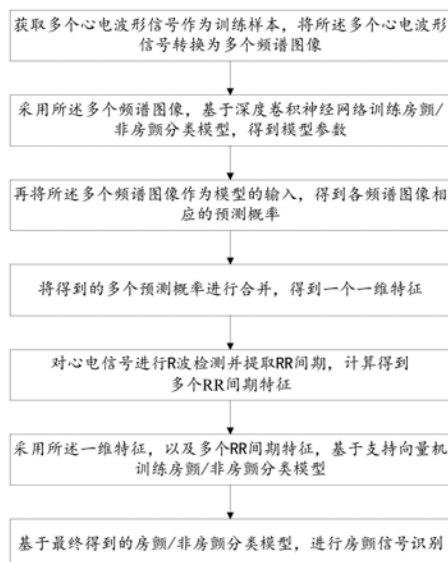
权利要求书2页 说明书8页 附图4页

(54)发明名称

一种基于机器学习的房颤信号识别方法及系统

(57)摘要

本发明公开了一种基于机器学习的房颤信号识别方法,包括以下步骤:获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;将得到的多个预测概率进行合并,得到一个一维特征;对心电信号进行R波检测并提取RR间期,计算得到多个RR间期特征;采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型,基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。本发明基于频谱图像作为特征数据,将卷积神经网络的输出作为支持向量机的一个特征,有效提高了识别精度。



1. 一种基于机器学习的房颤信号识别方法,其特征在于,包括以下步骤:

获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;

采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;

将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

将得到的多个预测概率进行合并,得到一个一维特征;

对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型;

基于最终的房颤/非房颤分类模型,进行房颤信号识别。

2. 如权利要求1所述的一种基于机器学习的房颤信号识别方法,其特征在于,将所述多个心电波形信号转换为多个频谱图像采用改进的频率切片小波变换。

3. 如权利要求2所述的一种基于机器学习的房颤信号识别方法,其特征在于,所述改进的频率切片小波变换公式为:

$$W_f(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \hat{f}(u) \hat{p}^* \left(\frac{u - \omega}{q(\hat{f}(u))} \right) e^{iut} du$$

其中,信号 $f(t)$ 的傅里叶变换为 $\hat{f}(u)$, t 和 ω 分别是设置的观察时间和频率,“*”表示共轭算子, \hat{p} 代表频片功能函数, q 被定义为一个尺度函数: $q = \delta + \text{sign} \left(\nabla \left| \hat{f}(u) \right| \right)$, δ 对应着 $\left| \hat{f}(u) \right|$ 的最大值, $\nabla(\bullet)$ 是微分算子, $\text{sign}(\bullet)$ 表示符号函数。

4. 如权利要求1所述的一种基于机器学习的房颤信号识别方法,其特征在于,所述RR间期特征包括房颤熵、样本熵、样本熵系数、平均RR时间序列、RR时间序列的最小心率、RR时间序列的最大心率以及RR时间序列的中位心率。

5. 一种基于机器学习的房颤信号识别系统,其特征在于,包括:

数据获取模块,获取多个心电波形信号作为训练样本;

数据预处理模块,将所述多个心电波形信号转换为多个频谱图像;

模型训练模块,采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;将得到的多个预测概率进行合并,得到一个一维特征;对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型;

房颤信号识别模块,基于最终的房颤/非房颤分类模型,进行房颤信号识别。

6. 一种计算机可读存储介质,其上存储有计算机程序,用于指纹图谱相似度计算,其特征在于,该程序被处理器执行时实现如权利要求1-4任一项所述房颤信号识别方法。

7.一种电子设备,包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,其特征在于,所述处理器执行所述程序时实现如权利要求1-4任一项所述房颤信号识别方法。

8.一种基于机器学习的房颤信号识别系统,其特征在于,包括心电信号获取装置和如权利要求7所述的电子设备。

一种基于机器学习的房颤信号识别方法及系统

技术领域

[0001] 本发明属于心电信号处理技术领域,尤其涉及一种基于机器学习的房颤信号识别方法及系统。

背景技术

[0002] 本部分的陈述仅仅是提供了与本公开相关的背景技术信息,不必然构成在先技术。

[0003] 房颤(Atrial Fibrillation,AF)又称心房颤动,是一种心律失常疾病,与许多心血管疾病的高死亡率和发病率有关。根据资料统计,房颤这一疾病影响大约全世界总人口1.5%-2%,目前我国患房颤病人数已超过1000万。房颤是导致脑中风重要的病因之一,而且由房颤引起的中风具有高致死率、高致残率和高复发率的特点,如果没有得到适当的诊断和治疗,可能会导致生命危险。房颤的及早发现和辅助诊断研究,对改善病人的治疗对策和提高治疗质量,减少病人危重症发生率和死亡率等有重要的临床和社会意义。

[0004] 发明人发现,ECG波形具有多样性的特点,目前诊断模型的识别精度受ECG波形的影响,没有很好泛化能力。随着科技的进步,用于ECG监测的可穿戴便捷电子设备正在迅速发展,可以实时的检测到心电信息,可用于家庭检测。用于ECG监测的可穿戴便捷电子技术发展起来以后,不间断采集状态下的海量心电数据给医生带来了很大的负担,亟需具有泛化能力的房颤诊断模型。

发明内容

[0005] 为克服上述现有技术的不足,本发明提供了一种基于机器学习的房颤信号识别方法及系统,基于频谱图像作为训练模型的数据,并且结合使用深度卷积神经网络和支持向量机来训练房颤/非房颤识别模型,具有较好的泛化能力,并且识别精度更高。

[0006] 为实现上述目的,本发明的一个或多个实施例提供了如下技术方案:

[0007] 一种基于机器学习的房颤信号识别方法,包括以下步骤:

[0008] 获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;

[0009] 采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;

[0010] 将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

[0011] 将得到的多个预测概率进行合并,得到一个一维特征;

[0012] 对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

[0013] 采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型;

[0014] 基于最终的房颤/非房颤分类模型,进行房颤信号识别。

[0015] 进一步地,将所述多个心电波形信号转换为多个频谱图像采用改进的频率切片小

波变换。

[0016] 进一步地,所述改进的频率切片小波变换公式为:

$$[0017] \quad W_f(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \hat{f}(u) \hat{p}^* \left(\frac{u - \omega}{q(\hat{f}(u))} \right) e^{iut} du$$

[0018] 其中,信号 $f(t)$ 的傅里叶变换为 $\hat{f}(u)$, t 和 ω 分别是设置的观察时间和频率,“*”

表示共轭算子, \hat{p} 代表频片功能函数, q 被定义为一个尺度函数: $q = \delta + \text{sign} \left(\nabla \left| \hat{f}(u) \right| \right)$, δ 对应着 $\left| \hat{f}(u) \right|$ 的最大值, $\nabla(\bullet)$ 是微分算子, $\text{sign}(\bullet)$ 表示符号函数。

[0019] 进一步地,所述RR间期特征包括房颤熵、样本熵、样本熵系数、平均RR时间序列、RR时间序列的最小心率、RR时间序列的最大心率以及RR时间序列的中位心率。

[0020] 一个或多个实施例提供了一种基于机器学习的房颤信号识别系统,包括:

[0021] 数据获取模块,获取多个心电波形信号作为训练样本;

[0022] 数据预处理模块,将所述多个心电波形信号转换为多个频谱图像;

[0023] 模型训练模块,采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;将得到的多个预测概率进行合并,得到一个一维特征;对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型;

[0024] 房颤信号识别模块,基于最终的房颤/非房颤分类模型,进行房颤信号识别。

[0025] 一个或多个实施例提供了一种计算机可读存储介质,其上存储有计算机程序,用于指纹图谱相似度计算,该程序被处理器执行时实现所述房颤信号识别方法。

[0026] 一个或多个实施例提供了一种电子设备,包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,所述处理器执行所述程序时实现所述房颤信号识别方法。

[0027] 一个或多个实施例提供了一种基于机器学习的房颤信号识别系统,包括心电信号获取装置和所述的电子设备。

[0028] 以上一个或多个技术方案存在以下有益效果:

[0029] (1) 深度卷积神经网络(CNN)在提取图像的频谱特征时,提取的特征信息不仅包含RR间期的特征,还包括P波或f波特征,而且在提取特征的过程中不受QRS检测器和P波或f波检测器的检测精度影响。由于P波或f波比较微弱,目前的其检测器检测精度很不是很高,基于P波或f波的分类器精度并不是很高;而基于RR间期特征的分类器,对心动过速等RR间期不规则的疾病容易误判成房颤。本文使用深度卷积神经网络(CNN)的预测概率作为SVM的新增的一维特征,相当于将P波或f波特征加入到SVM分类器,在MIT-BIH AF数据库上与现有算法相比,提高了基于特征提取的SVM房颤分类模型的分类精度。

[0030] (2) 本发明基于多个数据库进行了模型训练和测试,测试结果证明本发明得到的模型具有高度鲁棒性以及泛化能力,并且能够准确识别ECG波形中的房颤。

附图说明

[0031] 构成本发明的一部分的说明书附图用来提供对本发明的进一步理解,本发明的示意性实施例及其说明用于解释本发明,并不构成对本发明的不当限定。

[0032] 图1为本发明一个或多个实施例中一种基于机器学习的房颤信号识别方法的流程图;

[0033] 图2为10s房颤信号的MFSWT频谱;

[0034] 图3为10s正常信号的MFSWT频谱;

[0035] 图4为30s房颤信号所采用的CNN模型架构示意图;

[0036] 图5为10s房颤信号所采用的CNN模型架构示意图;

[0037] 图6为基于本发明一个或多个实施例中所述方法,30s房颤信号识别结果图;

[0038] 图7为基于本发明一个或多个实施例中所述方法,10s房颤信号识别结果图;

[0039] 图8为基于可穿戴设备进行心电信号采集的示意图;

[0040] 图9为测量得到的心电信号数据。

具体实施方式

[0041] 应该指出,以下详细说明都是示例性的,旨在对本发明提供进一步的说明。除非另有指明,本文使用的所有技术和科学术语具有与本发明所属技术领域的普通技术人员通常理解相同含义。

[0042] 需要注意的是,这里所使用的术语仅是为了描述具体实施方式,而非意图限制根据本发明的示例性实施方式。如在这里所使用的,除非上下文另外明确指出,否则单数形式也意图包括复数形式,此外,还应当理解的是,当在本说明书中使用术语“包含”和/或“包括”时,其指明存在特征、步骤、操作、器件、组件和/或它们的组合。

[0043] 在不冲突的情况下,本发明中的实施例及实施例中的特征可以相互组合。

[0044] 实施例一

[0045] 本实施例提供了一种基于机器学习的房颤信号识别方法,如图1所示,包括以下步骤:

[0046] 步骤1:获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像。

[0047] 使用改进的频率切片小波变换(MFSWT)将1-D ECG波形转换为2-D时频图像。改进频率切片小波变换(MFSWT)是在频率切片小波变换的基础上改进得到的,该方法更便于调节观测时间和观测频率,可以精确定位到ECG中的R波,P波,T波信息。

[0048] 信号 $f(t)$ 的傅里叶变换为 $\hat{f}(u)$,则可以将MFSWT模型的频域表示为:

$$[0049] \quad W_f(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \hat{f}(u) \hat{p}^* \left(\frac{u - \omega}{q(\hat{f}(u))} \right) e^{iut} du$$

[0050] 其中, t 和 ω 分别是设置的观察时间和频率, “*” 表示共轭算子, \hat{p} 代表频片功能函数 (Frequency Slice Function, FSF): $\hat{p}(x) = e^{-x^2/2}$, q 被定义为一个尺度函数:

$q = \delta + \text{sign} \left(\nabla \left| \hat{f}(u) \right| \right)$, δ 对应着 $\left| \hat{f}(u) \right|$ 的最大值, $\nabla(\bullet)$ 是微分算子, $\text{sign}(\bullet)$ 表示符号函数, 其

特性为: 若输入大于0则返回1, 若为0则返回0, 若小于0则返回-1。图2和图3为10-s ECG的MFSWT频谱图。

[0051] 步骤2: 采用所述多个频谱图像, 基于深度卷积神经网络 (CNN) 训练房颤/非房颤分类模型;

[0052] 深度卷积神经网络 (CNN) 可以自动提取频谱图像的特征, 这样不需要人工手动提取信号的特征; 传统的手动提取ECG信号特征, 通常需要R峰检测器定位R峰的位置, 而这种提取方法不再受R峰检测器检测精度的影响。而且深度卷积神经网络 (CNN) 不仅可以提取到RR间期特征, 还可以提取到P波特征。

[0053] 步骤3: 获取模型参数后, 再将所述多个频谱图像作为模型的输入, 得到各频谱图像相应的预测概率。

[0054] 使用深度卷积神经网络 (CNN) 提供的优势是可以自动提取功能, 无需人工干预和专家先验知识。本实施例采用Matlab R2017b中的神经网络工具箱, 分别以10s和30s的改进频率切片小波变换 (MFSWT) 图像作为训练数据, 学习深度卷积神经网络 (CNN) 模型。

[0055] 对于30秒的图像, 根据输入图片搭建深度卷积神经网络 (CNN) 模型。输入层 (第0层) 的大小为 $45 \times 200 \times 1$, 然后是一个20层网络, 其中包含7个卷积层, 7个ReLU层, 2个最大池化层, 1个全连接层和除了输入和输出层外, 还有1个softmax层 (图4), 参数如表1所示。

[0056] 对于10s图像, 根据输入图片大小搭建深度卷积神经网络 (CNN) 模型, 输入层 (第0层) 的大小为 $45 \times 100 \times 1$, 然后是19层网络, 其中包含7个卷积层, 7个ReLU层, 1个最大合并层, 1个全连接层和除了输入和输出层外, 还有1个softmax层 (图5和表1)。

[0057] 当使用MIT-BIH AF数据库作为训练集时, 30s的epoch是20, 10s的epoch是10。当将PhysioNet/CinC Challenge用作训练集时, 30s的epoch是150, 10s的epoch是40。

[0058] 表1深度卷积神经网络 (CNN) 模型参数

CNN参数	30-s频谱图	10-s频谱图
学习率	0.05	0.05
第一卷积层核函数尺寸	3*7	3*7
#第一卷积和下采样层的特征图	16	16
第二卷积层核函数尺寸	3*7	3*7
#第二卷积和下采样层的特征图	16	16
第三卷积层核函数尺寸	3*8	3*8

#第三卷积和下采样层的特征图	32	32
第四卷积层核函数尺寸	3*8	3*8
#第四卷积和下采样层的特征图	32	32
下采样核函数尺寸	1*2	—
第五卷积层核函数尺寸	3*18	3*10
#第五卷积和下采样层的特征图	64	64
第六卷积层核函数尺寸	3*18	3*10
#第六卷积和下采样层的特征图	64	64
第七卷积层核函数尺寸	4*17	4*17
#第七卷积和下采样层的特征图	20	20
下采样层核函数	2	2
#全连接层的神经元	2	2
#最小批大小	256	256

[0060] 步骤4:对心电信号进行R波检测并提取RR间期,计算RR间期特征。

[0061] 首先是定位信号的R峰的位置,然后提取RR间期,计算RR间期特征,包括房颤熵(Entropy_AF)、样本熵(SampEn)、样本熵系数(CosEn)、平均RR时间序列(mRR)、RR时间序列的最小心率(minHR)、RR时间序列的最大心率(maxHR)以及RR时间序列的中位心率(medHR)共7个特征。

[0062] 步骤5:使用步骤3中CNN模型输出的预测概率作为新增的一维特征,结合步骤4中的7个RR间期特征,基于支持向量机训练房颤/非房颤分类模型。

[0063] 其中,预测概率是指深度卷积神经网络(CNN)模型根据每张图片的特征,给出将这每张图片分类成房颤的概率,预测概率值是0-1之间的一个数。具体地,采用具有高斯核函数的支持向量机(SVM)作为分类器,其中,该支持向量机模型中参数包括:核宽Gamma和正则化参数Capacity,使用网格搜索法进行寻优,Gamma的寻优范围: $\{2^{(-15:2:3)}\}$,Capacity的寻优范围: $\{2^{(-5:2:15)}\}$ 。本实施例使用CNN的预测概率作为SVM的新增的一维特征,提高了基于特征提取的SVM房颤分类模型的分类精度。

[0064] 步骤6:基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。

[0065] 实施例二

[0066] 本实施例的目的是提供一种基于机器学习的房颤信号识别系统。所述系统包括:

[0067] 数据获取模块,获取多个心电波形信号作为训练样本;

[0068] 数据预处理模块,将所述多个心电波形信号转换为多个频谱图像;

[0069] 模型训练模块,采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;

[0070] 将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

[0071] 将得到的多个预测概率进行合并,得到一个一维特征;

[0072] 对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

[0073] 采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型;

[0074] 房颤信号识别模块,基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。

[0075] 实施例三

[0076] 本实施例的目的是提供一种计算机可读存储介质。

[0077] 一种计算机可读存储介质,其上存储有计算机程序,用于指纹图谱相似度计算,该程序被处理器执行时执行以下步骤:

[0078] 获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;

[0079] 采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;再将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

[0080] 将得到的多个预测概率进行合并,得到一个一维特征;

[0081] 对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

[0082] 采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型,训练得到的模型即为最终得到的房颤/非房颤分类模型。

[0083] 基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。

[0084] 实施例四

[0085] 本实施例的目的是提供一种电子设备。

[0086] 一种电子设备,包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,所述处理器执行所述程序时实现以下步骤,包括:

[0087] 获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;

[0088] 采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;再将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

[0089] 将得到的多个预测概率进行合并,得到一个一维特征;

[0090] 对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

[0091] 采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类模型,训练得到的模型即为最终得到的房颤/非房颤分类模型。

[0092] 基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。

[0093] 实施例五

[0094] 本实施例提供了一种基于机器学习的房颤信号识别系统,包括心电信号获取装置和电子设备;

[0095] 所述心电信号获取装置,用于获取人体心电信号并传输至所述计算装置,如图8;

[0096] 所述电子设备包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,所述处理器执行所述程序时实现以下步骤,包括:

[0097] 获取多个心电波形信号作为训练样本,将所述多个心电波形信号转换为多个频谱图像;

[0098] 采用所述多个频谱图像,基于深度卷积神经网络训练房颤/非房颤分类模型,得到模型参数;再将所述多个频谱图像作为模型的输入,得到各频谱图像相应的预测概率;

[0099] 将得到的多个预测概率进行合并,得到一个一维特征;

[0100] 对心电信号进行R波检测并提取RR间期,计算多个RR间期特征;

[0101] 采用所述一维特征,以及多个RR间期特征,基于支持向量机训练房颤/非房颤分类

模型,训练得到的模型即为最终得到的房颤/非房颤分类模型。

[0102] 基于最终得到的房颤/非房颤分类模型,进行房颤信号识别。

[0103] 以上实施例二-五的装置中涉及的各步骤与方法实施例一相对应,具体实施方式可参见实施例一的相关说明部分。术语“计算机可读存储介质”应该理解为包括一个或多个指令集的单个介质或多个介质;还应当被理解为包括任何介质,所述任何介质能够存储、编码或承载用于由处理器执行的指令集并使处理器执行本发明中的任一方法。

[0104] 实验效果:

[0105] 本发明对三种方法进行效果比对。方法一:基于频谱图像,仅采用深度卷积神经网络进行模型训练,方法二:基于RR间期特征,仅采用支持向量机进行模型训练,方法三:将基于深度卷积神经网络模型的预测结果作为支持向量机的一个特征进行模型训练。

[0106] 训练数据采用:MIT-BIH AF数据库、the PhysioNet/Computing in Cardiology (CinC) Challenge 2017数据集;

[0107] 测试数据采用:2018年中国生理信号挑战 (CPSC) 数据库和可穿戴式ECG数据库 (实验室采集的)。

[0108] 采用两个时间窗口30秒和10秒进行模型训练。

[0109] 如图6-7,在MIT-BIH AF数据库上进行5折交叉验证,发现第三种方法实现了最高的检测准确度,即30秒检测准确度为97.87%,10秒的为96.09%。在PhysioNet/CinC Challenge 2017数据集上进行测试,其30秒准确率达到89.07%,10秒的准确率达到90.07%。在CPSC 2018数据库上进行测试,相应的准确度分别为98.51%和97.97%。在采集的房颤患者的可穿戴式ECG数据库上(术前10小时,术后10小时),图6为30s术前(图6(a)和图6(c))与术后(图6(b)和图6(d))数据输入模型后的输出结果,图7为10s的术前(图7(a)和图7(c))与术后(图7(b)和图7(d))数据输入模型后的输出结果,其准确率分别为99.21%和98.42%。当PhysioNet/CinC Challenge 2017数据集用作训练集时,第三种方法也实现了最高的检测准确度。在MIT-BIH AF数据库上测试,其30秒的准确率达到94.84%,10秒的准确率达到94.50%。在CPSC 2018数据库上,相应的准确度为99.25%和95.95%。在AF患者的可穿戴式ECG数据库上测试,相应的准确度分别为96.38%和96.72%。这些结果证实了所提出的方法可以很好地识别房颤事件,具有临床应用潜能。

[0110] 以上一个或多个实施例具有以下技术效果:

[0111] (1) 深度卷积神经网络 (CNN) 在提取图像的频谱特征时,提取的特征信息不仅包含RR间期的特征,还包括P波或f波特征,而且在提取特征的过程中不受QRS检测器和P波或f波检测器的检测精度影响。由于P波或f波比较微弱,目前的其检测器检测精度很不是很高,基于P波或f波的分类器精度并不是很高;而基于RR间期特征的分类器,对心动过速等RR间期不规则的疾病容易误判成房颤。本文使用深度卷积神经网络 (CNN) 的预测概率作为SVM的新增的一维特征,相当于将P波或f波特征加入到SVM分类器,在MIT-BIH AF数据库上与现有算法相比,提高了基于特征提取的SVM房颤分类模型的分类精度。

[0112] (2) 本发明基于多个数据库进行了模型训练和测试,测试结果证明本发明得到的模型具有高度鲁棒性以及泛化能力,并且能够准确识别ECG波形中的房颤。

[0113] 本领域技术人员应该明白,上述本发明的各模块或各步骤可以用通用的计算机装置来实现,可选地,它们可以用计算装置可执行的程序代码来实现,从而,可以将它们存储

在存储装置中由计算装置来执行。

[0114] 以上所述仅为本发明的优选实施例而已,并不用于限制本发明,对于本领域的技术人员来说,本发明可以有各种更改和变化。凡在本发明的精神和原则之内,所作的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。

[0115] 上述虽然结合附图对本发明的具体实施方式进行了描述,但并非对本发明保护范围的限制,所属领域技术人员应该明白,在本发明的技术方案的基础上,本领域技术人员不需要付出创造性劳动即可做出的各种修改或变形仍在本发明的保护范围以内。

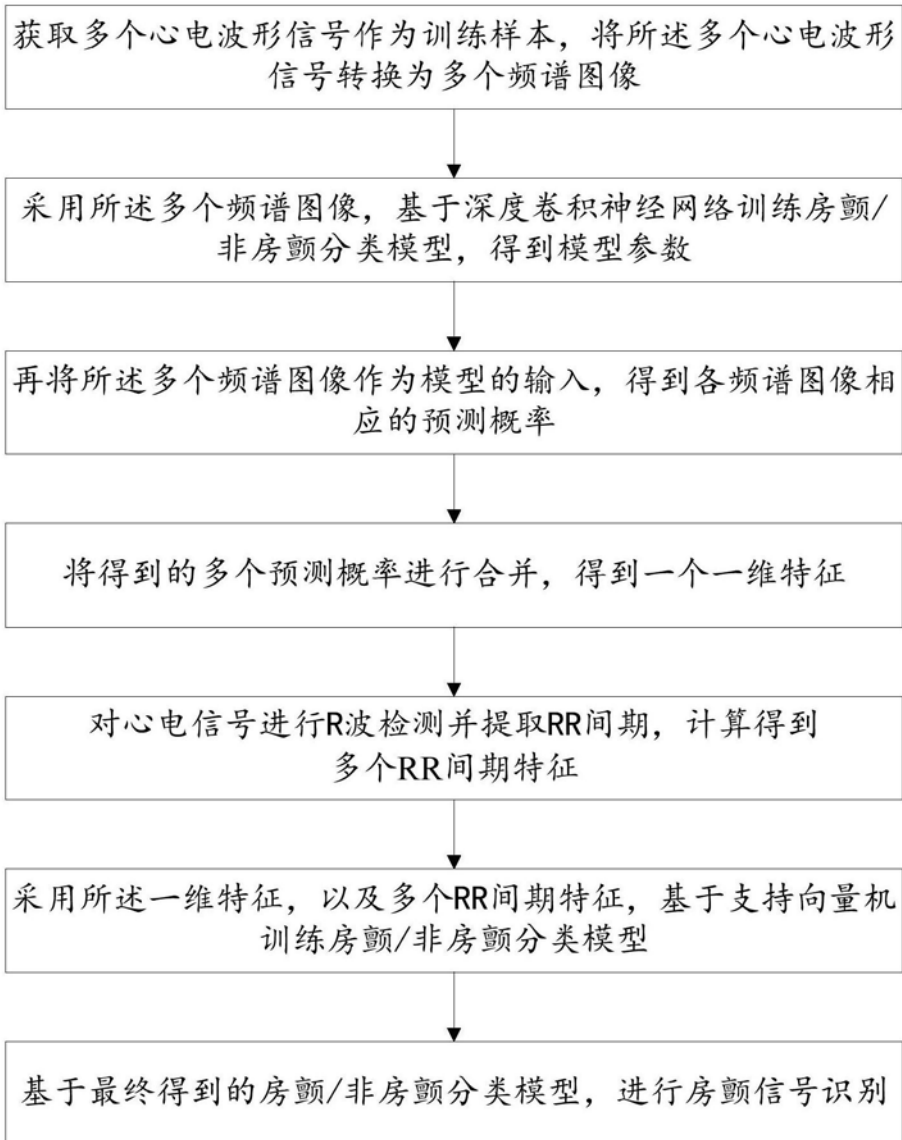


图1




图2




图3




图4




图5

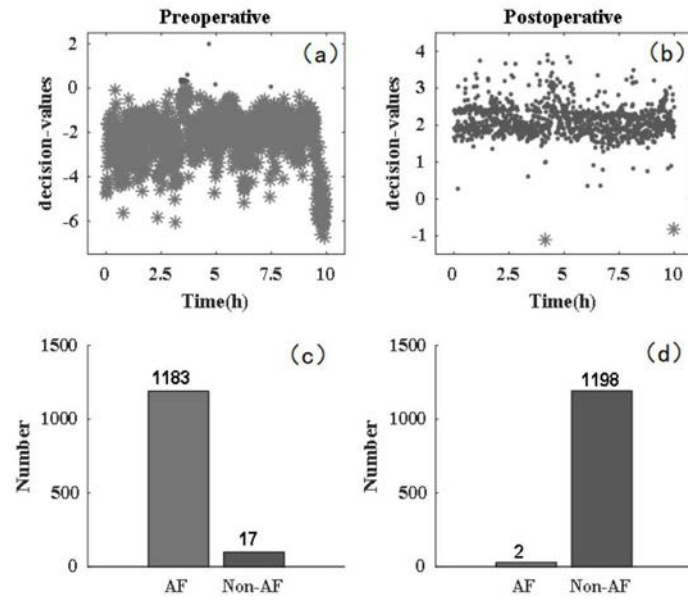


图6

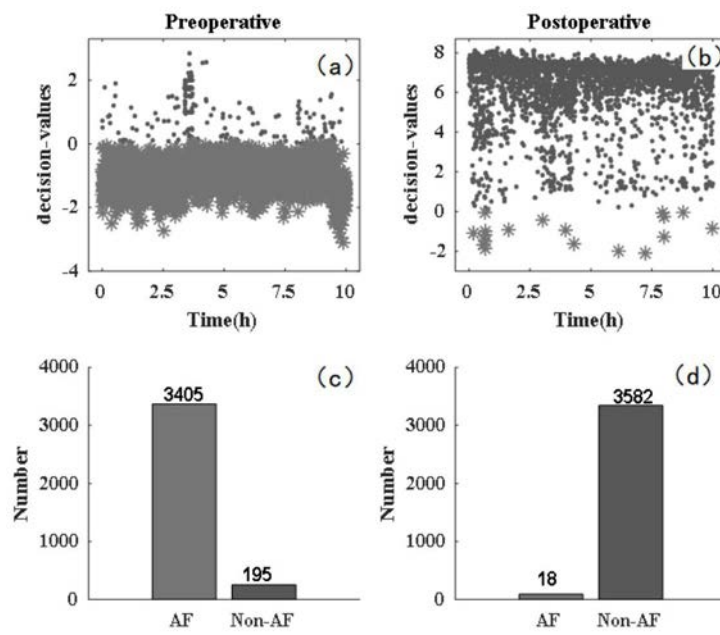


图7




图8




图9

专利名称(译)	一种基于机器学习的房颤信号识别方法及系统		
公开(公告)号	CN110840402A	公开(公告)日	2020-02-28
申请号	CN201911133626.9	申请日	2019-11-19
[标]申请(专利权)人(译)	山东大学		
申请(专利权)人(译)	山东大学		
当前申请(专利权)人(译)	山东大学		
[标]发明人	魏守水 马彩云 陈永超		
发明人	魏守水 马彩云 陈永超		
IPC分类号	A61B5/00 A61B5/0402 G06K9/00 G06K9/62		
CPC分类号	A61B5/0402 A61B5/0456 A61B5/725 A61B5/7267 A61B5/7285 G06K9/00523 G06K9/00536 G06K9/6268 G06K9/6269		
代理人(译)	黄海丽		
外部链接	Espacenet SIPO		

摘要(译)

本发明公开了一种基于机器学习的房颤信号识别方法，包括以下步骤：获取多个心电波形信号作为训练样本，将所述多个心电波形信号转换为多个频谱图像；采用所述多个频谱图像，基于深度卷积神经网络训练房颤/非房颤分类模型，得到模型参数；将所述多个频谱图像作为模型的输入，得到各频谱图像相应的预测概率；将得到的多个预测概率进行合并，得到一个一维特征；对心电信号进行R波检测并提取RR间期，计算多个RR间期特征；采用所述一维特征，以及多个RR间期特征，基于支持向量机训练房颤/非房颤分类模型，基于最终得到的房颤/非房颤分类模型，进行房颤信号识别。本发明基于频谱图像作为特征数据，将卷积神经网络的输出作为支持向量机的一个特征，有效提高了识别精度。

