



(12) 发明专利申请

(10) 申请公布号 CN 114081502 A

(43) 申请公布日 2022. 02. 25

(21) 申请号 202111331695.8

(22) 申请日 2021.11.11

(71) 申请人 中国科学院深圳先进技术研究院
地址 518055 广东省深圳市南山区深圳大学
学城学苑大道1068号

(72) 发明人 黄建龙 吴剑煌 谢炜芳

(74) 专利代理机构 北京市诚辉律师事务所
11430

代理人 耿慧敏 朱伟军

(51) Int. Cl.

A61B 5/346 (2021.01)

A61B 5/366 (2021.01)

A61B 5/352 (2021.01)

A61B 5/024 (2006.01)

A61B 5/00 (2006.01)

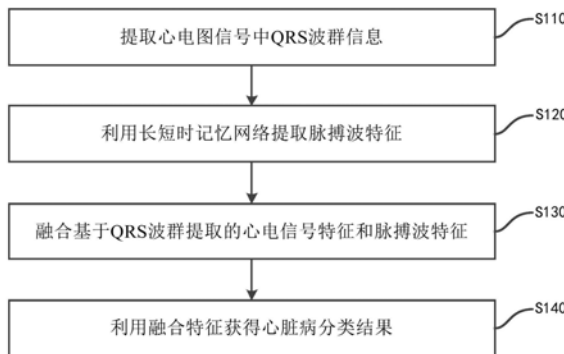
权利要求书1页 说明书7页 附图3页

(54) 发明名称

一种基于机器学习的非侵入性心脏病诊断方法和装置

(57) 摘要

本发明公开了一种基于机器学习的非侵入性心脏病诊断方法和装置。该方法包括：采集目标的心电图信号并检测对应的QRS波群；采集该目标的脉搏波信号；基于所述QRS波群提取心电图信号特征，构建为第一特征向量的样本空间；提取所述脉搏波信号的特征，将得到的特征向量矩阵构建为第二特征向量的样本空间；将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合，利用融合特征输入到预训练的分类器，获得心脏诊断结果。本发明提高了心脏识别的准确率和效率。



1. 一种基于机器学习的非侵入性心脏病诊断方法,包括以下步骤:
采集目标的心电图信号并检测对应的QRS波群;
采集该目标的脉搏波信号;
基于所述QRS波群提取心电图信号特征,构建为第一特征向量的样本空间;
提取所述脉搏波信号的特征,将得到的特征向量矩阵构建为第二特征向量的样本空间;
将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合,利用融合特征输入到预训练的分类器,获得心脏诊断结果。
2. 根据权利要求1所述的方法,其特征在于,所述采集目标的心电图信号并检测对应的QRS波群包括:
对于采集的心电图信号,利用Pan-Tompkins算法进行R波检测;
基于检测到的R波对信号进行切割,获得RR间期特征,并在截裁样本使用聚类算法进行数据筛选。
3. 根据权利要求1所述的方法,其特征在于,所述脉搏波信号的特征利用长短时记忆网络获得。
4. 根据权利要求1所述的方法,其特征在于,所述分类器是支持向量机。
5. 根据权利要求1所述的方法,其特征在于,在将融合特征输入分类器之前还包括:对所述第一特征向量的样本空间和所述第二特征向量的样本空间进行归一化处理。
6. 根据权利要求1所述的方法,其特征在于,检测对应的QRS波群包括:
分别采用低通滤波器和高通滤波器对采集的心电图信号进行滤波,其中低通滤波器的截止频率设置为11Hz,高通滤波器的截至频率设置为2Hz;
利用微分方法对于QRS波群进行陡坡特性的放大并通过非线性平方函数增强心电图信号中的高频特性;
利用移动窗积分确定波群中R波之外的其他特征;
利用阈值动态调整和搜索确定心电图信号的峰值。
7. 根据权利要求1所述的方法,其特征在于,所述脉搏波信号利用可穿戴设备基于光电容积脉搏波描记法获得。
8. 根据权利要求2所述的方法,其特征在于,所述聚类算法是K-Means聚类。
9. 一种基于机器学习的非侵入性心脏病诊断装置,包括:
第一数据采集单元:用于采集目标的心电图信号并检测对应的QRS波群;
第二数据采集单元:用于采集该目标的脉搏波信号;
第一特征提取单元:用于基于所述QRS波群提取心电图信号特征,构建为第一特征向量的样本空间;
第二特征提取单元:用于提取所述脉搏波信号的特征,将得到的特征向量矩阵构建为第二特征向量的样本空间;
分类识别单元:用于将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合,利用融合特征输入到预训练的分类器,获得心脏诊断结果。
10. 一种计算机可读存储介质,其上存储有计算机程序,其中,该程序被处理器执行时实现根据权利要求1至8中任一项所述方法的步骤。

一种基于机器学习的非侵入性心脏病诊断方法和装置

技术领域

[0001] 本发明涉及医学图像分析技术领域,更具体地,涉及一种基于机器学习的非侵入性心脏病诊断方法和装置。

背景技术

[0002] 随着心脏病患者的不断增加,有限的医疗资源无法满足日益增长的心血管疾病患者的就医需求。目前,心脏病已经成为危害人类健康的重大疾病。近年来,人工智能在医疗行业中逐渐受到人们关注,大量机器学习算法在医疗保健领域广泛应用,涉及智能风险评估、辅助诊断、医学影像、药物研发等多个领域,由此可见“互联网+医疗健康”模式将在未来成为人们日常生活的一部分。心电图(ECG)是医生诊断心血管疾病的重要依据,能真实地反映心脏的健康状况。同时,随着传感器技术的进步,基于脉搏波信号(PPG)的可穿戴设备越来越多,人们可以通过这些可穿戴设备收集人体生理体征信号,随时监控自身健康状况。

[0003] 在传统的心脏诊断中,医生通过查看心电图(Electrocardiography, ECG)判断心脏病,但这种诊断方式带有主观性,且耗时耗力。Kora等基于ECG使用Cuckoo Search算法实现自动识别心脏病;王凯基于ECG的自动心律失常检测模型能够有效监测心脏异常信号的ECG信号特征。心脏病监测的困难主要在于阵发性房颤,此类心脏病的特点是突发突止、持续时间短,24h动态心电图常作为首选的监测方法。李芳等通过分析总结心脏病的心电散点图特征,分析24h动态心电图来诊断心脏病。武求花等运用Lorenz-RR散点图(Lorenz散点图)与时间-RR间期散点图(时间散点图)及逆向技术相结合的方法,快速识别不同发作时间的PAF,为临床提供更快更准确的心电诊断技术。目前国内外对于心脏识别的研究大多基于ECG,但ECG设备普遍有操作复杂、携带困难、价格较高、多通道等局限性。光电容积脉搏波描记(PPG)是使用激光对待测流体或固体的体积进行检测与记录的方法,可以用来监测毛细血管中血液的体积变化。有研究表明,PPG方法采集信息容易、方便携带,相较于ECG方法,PPG更加擅长长期监测。但是PPG可能没有ECG准确。

[0004] 综上,在现有技术中,通常仅采用ECG或PPG进行心脏诊断分析,其准确性和效率还有待改进。

发明内容

[0005] 本发明的目的是克服上述现有技术的缺陷,提供一种基于机器学习的非侵入性心脏病诊断方法和装置。

[0006] 根据本发明的第一方面,提供一种基于机器学习的非侵入性心脏病诊断方法。该方法包括以下步骤:

[0007] 采集目标的心电图信号并检测对应的QRS波群;

[0008] 采集该目标的脉搏波信号;

[0009] 基于所述QRS波群提取心电图信号特征,构建为第一特征向量的样本空间;

[0010] 提取所述脉搏波信号的特征,将得到的特征向量矩阵构建为第二特征向量的样本

空间；

[0011] 将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合，利用融合特征输入到预训练的分类器，获得心脏诊断结果。

[0012] 根据本发明的第二方面，提供一种基于机器学习的非侵入性心脏病诊断装置。该装置包括：

[0013] 第一数据采集单元：用于采集目标的心电图信号并检测对应的QRS波群；

[0014] 第二数据采集单元：用于采集该目标的脉搏波信号；

[0015] 第一特征提取单元：用于基于所述QRS波群提取心电图信号特征，构建为第一特征向量的样本空间；

[0016] 第二特征提取单元：用于提取所述脉搏波信号的特征，将得到的特征向量矩阵构建为第二特征向量的样本空间；

[0017] 分类识别单元：用于将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合，利用融合特征输入到预训练的分类器，获得心脏诊断结果。

[0018] 与现有技术相比，本发明的优点在于，提出了基于ECG和PPG相结合的新型心脏识别方法，通过将PPG信号的特征和ECG信号的特征融合，放入分类器进行识别，提高了利用机器学习的方法对心脏识别的准确率。

[0019] 通过以下参照附图对本发明的示例性实施例的详细描述，本发明的其它特征及其优点将会变得清楚。

附图说明

[0020] 被结合在说明书中并构成说明书的一部分的附图示出了本发明的实施例，并且连同其说明一起用于解释本发明的原理。

[0021] 图1是根据本发明一个实施例的基于机器学习的非侵入性心脏病诊断方法的流程图；

[0022] 图2是根据本发明一个实施例的心电周期示意图；

[0023] 图3是根据本发明一个实施例的循环神经网络与长短时记忆网络的结构对比图；

[0024] 图4是根据本发明一个实施例的长短时记忆网络的结构示意图；

[0025] 图5是根据本发明一个实施例的基于多集判别相关分析的ECG和PPG特征层融合识别流程图。

具体实施方式

[0026] 现在将参照附图来详细描述本发明的各种示例性实施例。应注意到：除非另外具体说明，否则在这些实施例中阐述的部件和步骤的相对布置、数字表达式和数值不限制本发明的范围。

[0027] 以下对至少一个示例性实施例的描述实际上仅仅是说明性的，决不作为对本发明及其应用或使用的任何限制。

[0028] 对于相关领域普通技术人员已知的技术、方法和设备可能不作详细讨论，但在适当情况下，所述技术、方法和设备应当被视为说明书的一部分。

[0029] 在这里示出和讨论的所有例子中，任何具体值应被解释为仅仅是示例性的，而不

是作为限制。因此,示例性实施例的其它例子可以具有不同的值。

[0030] 应注意到:相似的标号和字母在下面的附图中表示类似项,因此,一旦某一项在一个附图中被定义,则在随后的附图中不需要对其进行进一步讨论。

[0031] 本发明利用计算机辅助诊断心脏病,通过机器学习相关的知识分别对于ECG和PPG的分类进行了相关的研究。例如,首先,利用LSTM提取PPG信号的特征;然后,根据特征提取的结果进行了样本的截裁;利用Pan-Tompkins算法,使用收集的心电图数据集对于心电信号QRS波群进行特征提取,进行样本的聚类分析,以剔除了部分特殊的截裁小样;在数据筛选完成后,进行样本特征的选择,利用主成分分析法(PCA),进行了降低维度的处理;最后,利用样本特征训练分类器,进而利用经训练的分类器实现对目标患者的心脏诊断结果。

[0032] 具体地,结合图1和图5所示,所提供的基于机器学习的非侵入性心脏病诊断方法包括以下步骤。

[0033] 步骤S110,提取心电图信号中QRS波群信息。

[0034] 心电图信号记录一定时间内心脏不同部位去极化产生的电压。QRS波群反映了左右心室的快速去极化的过程。心电信号具有周期性,相对于其它电信号例如脑电波,肌肉电波,属于比较容易判断分辨特征的一类电波。分析心电信号,必要环节是提取其QRS波群,基于QRS波群进行心电信号分析,有利于提高鲁棒性和稳定性。

[0035] QRS波群是心室去极化的电位变化,如图2所示,在心电图信号中,在P波结束后,进入PR区间,之后Q波会呈现出一个向下的趋势,R波则会快速向上,S波紧接着向下,这三个波所对应的连接电波,本文统称为QRS波群。

[0036] 由图2可以明显看出,R波是所有波形中最窄,幅度最大的波。T波对应的是人体心室肌肉的复极过程。心脏去极化的过程对应P波,因此它是钝圆形的图像。PR对应的是传导过程,在理想状态下实际上是没有电位变化的,即心电信号为平。QT期间对应人体心脏心室收缩的一个过程,因此通过QT区间的变化可以有效的判断人的心率,QT期间的大小与心率的快慢呈正比关系。

[0037] 在正常的心电信号的周期中,P波和T波没有明显的特征,为了明显分辨心电信号,基本上还是需要通过QRS波群的位置来对其进行判断。选择QRS波群还有一个非常重要的原因是因为QRS波群是心电信号中最明显的信号,正确选择了QRS波群才能进一步完成对其它信号波的选择。

[0038] 对于QRS波群的提取和检测方法包括小波变换、神经网络和Pan-Tompkins算法及其改良算法、增加了陷波器的小波改良算法等。

[0039] 小波变换方法准确性高,但是缺点在于计算步骤非常繁琐,因此计算效率较低,并且在小波变换过程中会导致数据的冗余度增加。

[0040] 神经网络一定程度上可以准确检测QRS波群,但训练神经网络的过程非常漫长的,并且需要采集大量的样本,此外不同的训练样本产生的训练结果也并不相同,而由于心脏病患者的心电图信号差异较大,经训练的神经网络模型并不适用于实际的应用。

[0041] 为了平衡心电信号分析的准确性和计算效率,在一个实施例中,采用Pan-Tompkins算法检测心电图中QRS波群信息。相对于其他的QRS波群提取算法,Pan-Tompkins算法计算效率高并且不需要模型训练。简言之,利用Pan-Tompkins法检测R波峰值包括:利用滤波器进行滤波;对滤波后的信号求一阶导数;对求导之后的信号进行平方运算;将信号

通过滑动窗口进行积分;使用阈值法检测经过处理之后的R波峰值等过程。

[0042] 具体地,基于Pan-Tompkins算法提取心电图信号的特征包括:

[0043] 步骤S111,利用滤波器进行降噪处理。

[0044] 因为信号采集设备和环境的不同,在心电信号采集过程中会引入不同的噪声,所以对于心电信号数据中的噪声处理是数据预处理的核心内容。

[0045] 在一个实施例中,采用高通滤波器和低通滤波器来滤除信号中的噪声,从而提升心电信号的信噪比。

[0046] 心电信号中主要的噪声为工频干扰和基线漂移。电力系统等带入的干扰信号称为工频干扰,频率一般集中在50Hz。而皮肤的接触,人的呼吸等都会产生所谓的基线漂移,频率一般集中在0.05Hz至2Hz。而QRS波群的频率主要集中在5Hz至11Hz。

[0047] 以T为采样周期,低通滤波器的截止频率为11Hz,差分方程可表示为:

$$[0048] \quad y(nT) = 2y(nT-T) - y(nT-2T)$$

$$[0049] \quad -2x(nT-6T) + x(nT-12T) + x(nT) \quad (1)$$

[0050] 高通滤波器的截止频率为2Hz,差分方程可表示为:

$$[0051] \quad y(nT) = y(nT-T) - x(nT)$$

$$[0052] \quad +32x(nT-16T) + x(nT-32T) \quad (2)$$

[0053] 步骤S112,进行放大处理以检测出R波。

[0054] QRS波群中R波是位于一个心电信号周期中最陡的一个波。为了方便将QRS波从其他的心电信号波中区分出来,需要利用相应的微分方法对于QRS波群进行陡坡特性的放大,具体的差分方程如下:

$$[0055] \quad y(nT) = x(nT) - x(xT-2T) \quad (3)$$

[0056] 高频特性可以通过非线性平方函数来增强,其方程可以表示为:

$$[0057] \quad y(nT) = [x(nT)]^2 \quad (4)$$

[0058] 步骤S113,确定R波外的其他特征

[0059] 上述的方法基本都是围绕R波来展开进行的,但单纯的对于R波的处理对于心电信号的异常判断无疑是够完整的。因此对于波群的其它特征同样也需要进行确定。

[0060] 在一个实施例中,采取了一个移动窗积分来确定其它相关的特征。目的是为了提取波群的其他特征。设积分窗内样本数为N,差分方程表示为:

$$[0061] \quad y(nT) = \frac{1}{N} \left\{ \begin{array}{l} x[nT - (N-1)T] \\ +x[nT - (N-2)T] + \dots + x(nT) \end{array} \right\} \quad (5)$$

[0062] 步骤S114,阈值动态调整和搜索

[0063] 阈值动态调整和搜索属于该算法的核心部分,通过其搜索心电信号峰值,通过一定的计算式更新阈值,并结合回溯检测,双向判别等内容来检测。该过程可采用现有技术实现,在此不再赘述。

[0064] 步骤S120,利用长短时记忆网络提取脉搏波特征。

[0065] 与传统RNN不同,长短时记忆网络(LSTM)不存在消失梯度问题,可记忆之前数千个离散时间步长的输入,与传统RNN相比,LSTM可在更长的序列中有更好表现。LSTM将神经元的激活功能替换为一个具有“门”控制结构的单元,每个单元称为一个细胞(Cell),本发明采用LSTM使用具有遗忘门的存储单元。

[0066] 如图3所示,相比于RNN只有一个传递状态 $h(t)$,LSTM则有两个传输状态 $c(t)$ (cell state,细胞状态)和 $h(t)$ (hidden state,隐藏状态),RNN中的 $h(t)$ 相当于LSTM的 $c(t)$ 。LSTM对于传递下去的 $c(t)$ 改变很慢,通常输出的 $c(t)$ 是上一个状态传过来的 $c(t-1)$ 加上一些数值,而 $h(t)$ 在不同节点下往往有很大区别,正是这些波动较大的 $h(t)$ 产生忘记和选择记忆的效果。

[0067] 首先使用当前输入 $x(t)$ 和上一个状态传递下来的 $h(t-1)$ 拼接训练得到4中状态(如图4所示): z 、 z^i 、 z^f 、 z^o ,其中 z^f 、 z^i 、 z^o 分别作为遗忘门(forget gate),输入门(input gate)和输出门(output gate)的控制信号, z 是神经网络输入层的输入。4种状态计算公式分别为:

$$[0068] \quad z^i(t) = \sigma(W_{xi} \odot x(t) + W_{hi} \odot h(t-1)) \quad (6)$$

$$[0069] \quad z(t) = \tanh(W_x \odot x(t) + W_h \odot h(t-1)) \quad (7)$$

$$[0070] \quad z^o(t) = \sigma(W_{xo} \odot x(t) + W_{ho} \odot h(t-1)) \quad (8)$$

$$[0071] \quad z^f(t) = \sigma(W_{xf} \odot x(t) + W_{hf} \odot h(t-1)) \quad (9)$$

[0072] 其中, W 表示对应项的权重。

[0073] 在该步骤中,对于光电容积脉搏波数据(PPG)序列通过忘记、选择记忆、输出阶段等得出符合生理规律的特征参数。PPG信号中包含大量例如与心率相关的特征,这些特征有利于LSTM网络提高预测精度。需说明的是,也可采用GRU(门控循环单元)替代LSTM。

[0074] 步骤S130,融合基于QRS波群提取的心电信号特征和脉搏波特征。

[0075] 在获得ECG信号特征和PPG信号特征后,可以在截裁样本后使用K-Means等聚类进行数据筛选,以进一步进行特征融合。

[0076] 在一个实施例中,特征融合过程包括:

[0077] 步骤S131,对ECG信号特征提取后得到的特征向量组成第一特征的样本空间 $X \in \mathbb{R}^p \times n$ 。

[0078] 例如,ECG信号特征反映波群形态特征和间期特征等。心电信号特征包括心电信号的时域特征、心电信号的变换域特征等。

[0079] 步骤S132,对PPG信号特征提取后得到的特征向量矩阵组成第二特征的样本空间 $Y \in \mathbb{R}^q \times n$ 。

[0080] 步骤S133,采用最大最小值法,对特征向量进行归一化操作,使得两组特征向量的数量级接近。

[0081] 优选地,通过对特征向量进行归一化处理,以消除奇异样本数据对后续预测结果的不良影响。

[0082] 步骤S140,利用融合特征获得心脏病分类结果。

[0083] 在该步骤中,利用融合特征训练分类器,进而利用经训练的分类器进行实时心脏病诊断分析。

[0084] 在一个实施例中,选用支持向量机(SVM)作为分类器。这是因为SVM是定义在特征空间上的间隔最大的分类器,并更适用于小样本学习,并且SVM最终的决策结果取决于少数支持向量,从而可以“剔除”大量冗余样本,计算效率较高并具有较好的“鲁棒”性。由于大量心脏病患者的心电图样本和PPG信号样本可能不易获得,并且在实际应用中,患者的相关数

据可能差异较大,因此选用SVM可获得更准确的诊断结果,如正常心跳、左心室动脉受阻心率、右心室动脉受阻心率、房颤、心室收缩和心房收缩等。

[0085] 此外,为了进一步降维特征数据并保证后续诊断结果的准确性,在此步骤中,还可以利用主成分分析选择关键特征作为分类器的输入。

[0086] 相应地,本发明还提供一种基于机器学习的非侵入性心脏病诊断装置,用于实现上述方法的一个方面或多个方面。例如,该装置包括:第一数据采集单元,其用于采集目标的心电图信号并检测对应的QRS波群;第二数据采集单元,其用于采集该目标的脉搏波信号;第一特征提取单元,其用于基于所述QRS波群提取心电图信号特征,构建为第一特征向量的样本空间;第二特征提取单元,其用于提取所述脉搏波信号的特征,将得到的特征向量矩阵构建为第二特征向量的样本空间;分类识别单元,其用于将所述第一特征向量的样本空间和所述第二特征向量的样本空间进行融合,利用融合特征输入到预训练的分类器,获得心脏诊断结果。该装置所涉及的各单元可采用处理器、FPGA或专用硬件实现。

[0087] 综上,本发明使用医院患者的数据,分别收集患者的脉搏波信号和心电图,首先利用LSTM提取PPG信号的特征。其次利用Pan-Tompkins算法,使用收集的心电图数据集对于心电图信号QRS波群进行特征提取,在截断样本后使用K-Means聚类进行数据筛选。再其次将提取的PPG信号特征和ECG信号特征进行融合,最后利用分类器对融合的特征进行分类。本发明提出了一种基于ECG和PPG相结合的新型心脏识别方法,首次将ECG和PPG相结合,为心脏识别提供了补充的解决方案,并提高了利用机器学习对心脏识别的准确率,获得的心脏诊断分类结果可用于临床指示。

[0088] 本发明可以是系统、方法和/或计算机程序产品。计算机程序产品可以包括计算机可读存储介质,其上载有用于使处理器实现本发明的各个方面的计算机可读程序指令。

[0089] 计算机可读存储介质可以是保持和存储由指令执行设备使用的指令的有形设备。计算机可读存储介质例如可以是但不限于电存储设备、磁存储设备、光存储设备、电磁存储设备、半导体存储设备或者上述的任意合适的组合。计算机可读存储介质的更具体的例子(非穷举的列表)包括:便携式计算机盘、硬盘、随机存取存储器(RAM)、只读存储器(ROM)、可擦式可编程只读存储器(EPR0M或闪存)、静态随机存取存储器(SRAM)、便携式压缩盘只读存储器(CD-ROM)、数字多功能盘(DVD)、记忆棒、软盘、机械编码设备、例如其上存储有指令的打孔卡或凹槽内凸起结构、以及上述的任意合适的组合。这里所使用的计算机可读存储介质不被解释为瞬时信号本身,诸如无线电波或者其他自由传播的电磁波、通过波导或其他传输媒介传播的电磁波(例如,通过光纤电缆的光脉冲)、或者通过电线传输的电信号。

[0090] 这里所描述的计算机可读程序指令可以从计算机可读存储介质下载到各个计算/处理设备,或者通过网络、例如因特网、局域网、广域网和/或无线网下载到外部计算机或外部存储设备。网络可以包括铜传输电缆、光纤传输、无线传输、路由器、防火墙、交换机、网关计算机和/或边缘服务器。每个计算/处理设备中的网络适配卡或者网络接口从网络接收计算机可读程序指令,并转发该计算机可读程序指令,以供存储在各个计算/处理设备中的计算机可读存储介质中。

[0091] 用于执行本发明操作的计算机程序指令可以是汇编指令、指令集架构(ISA)指令、机器指令、机器相关指令、微代码、固件指令、状态设置数据、或者以一种或多种编程语言的

任意组合编写的源代码或目标代码,所述编程语言包括面向对象的编程语言—诸如 Smalltalk、C++、Python等,以及常规的过程式编程语言—诸如“C”语言或类似的编程语言。计算机可读程序指令可以完全地在用户计算机上执行、部分地在用户计算机上执行、作为一个独立的软件包执行、部分在用户计算机上部分在远程计算机上执行、或者完全在远程计算机或服务器上执行。在涉及远程计算机的情形中,远程计算机可以通过任意种类的网络—包括局域网(LAN)或广域网(WAN)—连接到用户计算机,或者,可以连接到外部计算机(例如利用因特网服务提供商来通过因特网连接)。在一些实施例中,通过利用计算机可读程序指令的状态信息来个性化定制电子电路,例如可编程逻辑电路、现场可编程门阵列(FPGA)或可编程逻辑阵列(PLA),该电子电路可以执行计算机可读程序指令,从而实现本发明的各个方面。

[0092] 这里参照根据本发明实施例的方法、装置(系统)和计算机程序产品的流程图和/或框图描述了本发明的各个方面。应当理解,流程图和/或框图的每个方框以及流程图和/或框图中各方框的组合,都可以由计算机可读程序指令实现。

[0093] 这些计算机可读程序指令可以提供给通用计算机、专用计算机或其它可编程数据处理装置的处理器,从而生产出一种机器,使得这些指令在通过计算机或其它可编程数据处理装置的处理器执行时,产生了实现流程图和/或框图中的一个或多个方框中规定的功能/动作的装置。也可以把这些计算机可读程序指令存储在计算机可读存储介质中,这些指令使得计算机、可编程数据处理装置和/或其他设备以特定方式工作,从而,存储有指令的计算机可读介质则包括一个制品,其包括实现流程图和/或框图中的一个或多个方框中规定的功能/动作的各个方面的指令。

[0094] 也可以把计算机可读程序指令加载到计算机、其它可编程数据处理装置、或其它设备上,使得在计算机、其它可编程数据处理装置或其它设备上执行一系列操作步骤,以产生计算机实现的过程,从而使得在计算机、其它可编程数据处理装置、或其它设备上执行的指令实现流程图和/或框图中的一个或多个方框中规定的功能/动作。

[0095] 附图中的流程图和框图显示了根据本发明的多个实施例的系统、方法和计算机程序产品的可能实现的体系架构、功能和操作。在这点上,流程图或框图中的每个方框可以代表一个模块、程序段或指令的一部分,所述模块、程序段或指令的一部分包含一个或多个用于实现规定的逻辑功能的可执行指令。在有些作为替换的实现中,方框中所标注的功能也可以以不同于附图中所标注的顺序发生。例如,两个连续的方框实际上可以基本并行地执行,它们有时也可以按相反的顺序执行,这依所涉及的功能而定。也要注意的,框图和/或流程图中的每个方框、以及框图和/或流程图中的方框的组合,可以用执行规定的功能或动作的专用的基于硬件的系统来实现,或者可以用专用硬件与计算机指令的组合来实现。对于本领域技术人员来说公知的是,通过硬件方式实现、通过软件方式实现以及通过软件和硬件结合的方式实现都是等价的。

[0096] 以上已经描述了本发明的各实施例,上述说明是示例性的,并非穷尽性的,并且也不限于所披露的各实施例。在不偏离所说明的各实施例的范围和精神的情况下,对于本技术领域的普通技术人员来说许多修改和变更都是显而易见的。本文中所用术语的选择,旨在最好地解释各实施例的原理、实际应用或对市场中的技术改进,或者使本技术领域的其它普通技术人员能理解本文披露的各实施例。本发明的范围由所附权利要求来限定。

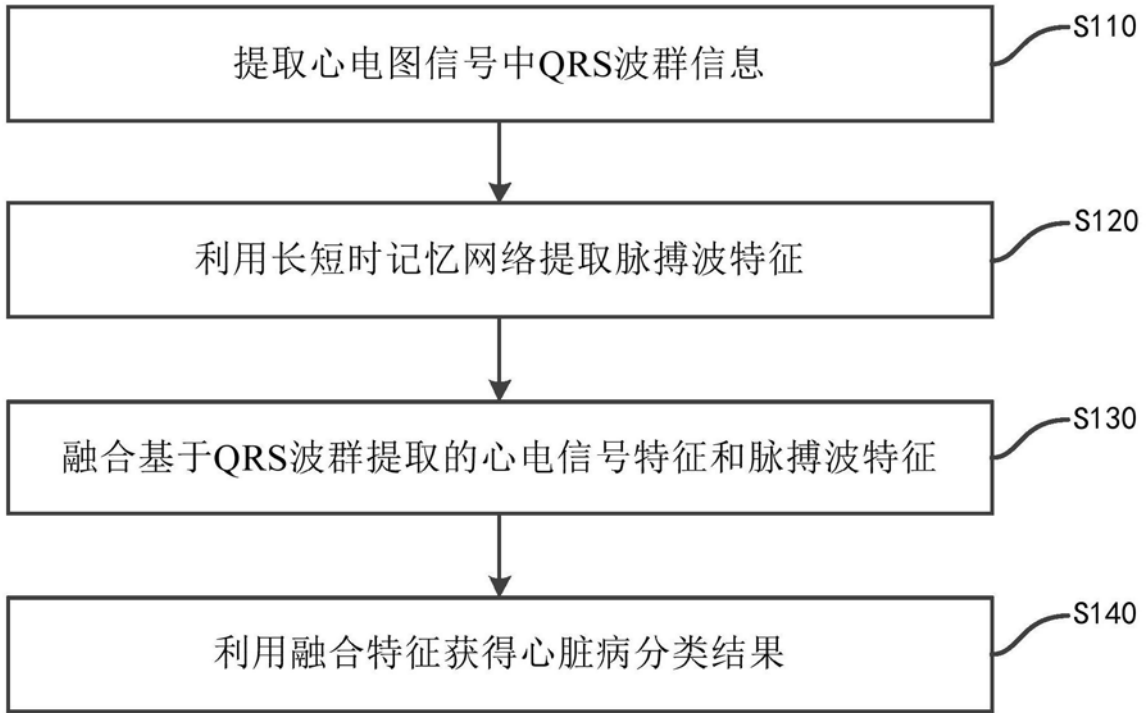


图1




图2




图3




图4

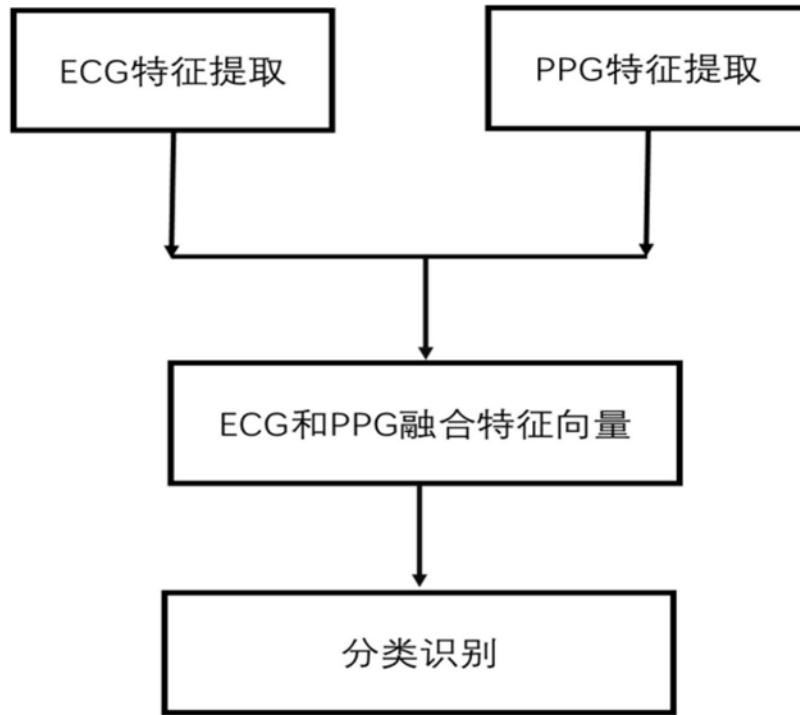


图5