



(12)发明专利申请

(10)申请公布号 CN 109965862 A

(43)申请公布日 2019.07.05

(21)申请号 201910305930.0

(22)申请日 2019.04.16

(71)申请人 重庆大学

地址 400044 重庆市沙坪坝区沙坪坝正街
174号(72)发明人 季忠 李孟泽 陈硕 谭霞
吴海燕(74)专利代理机构 北京同恒源知识产权代理有
限公司 11275

代理人 赵荣之

(51)Int.Cl.

A61B 5/021(2006.01)

A61B 5/00(2006.01)


权利要求书4页 说明书9页 附图4页

(54)发明名称

一种无袖带式长时连续血压无创监测方法

(57)摘要

本发明涉及一种无袖带式长时连续血压无创监测方法,属于生物医学工程领域。该方法包括:通过与计算机相连的心电信号和光电容积脉搏波信号监测子系统获取生理病理特征参数;由血压无创动态监测模型簇和血压动态长时监测软件子系统对参数进行无缝融合和处理分析,得到每个心跳节拍的血压值并实现动态长时的连续血压监测;血压无创动态监测模型簇是从无袖带式血压测量出发,采用上述信号测量子系统监测病人的生理病理特征参数,基于患者个体差异-特征参数平均影响值-机器学习方法构建,使系统具有血压长时连续测量的模型自校正能力。本发明提高了血压长时测量的稳定性和监测精度,血压的连续节拍或长时测量,可为高血压病的防治奠定更有效的基础。



1. 一种无袖带式长时连续血压无创监测方法,其特征在于,该方法具体包括以下步骤:

S1:构建血压无创动态监测模型簇Models;

S2:通过与计算机相连的心电信号和光电容积脉搏波信号监测子系统获取生理病理特征参数;

S3:由血压无创动态监测模型簇和血压动态长时监测软件子系统对特征参数进行无缝融合和处理分析,得到每个心跳节拍的血压值并实现动态长时的连续血压监测。

2. 根据权利要求1所述的一种无袖带式长时连续血压无创监测方法,其特征在于,所述步骤S1具体包括以下步骤:

S11:从无袖带式血压测量出发,采用心电信号和光电容积脉搏波测量子系统监测病人的生理病理信号并提取信号特征参数;

S12:基于患者个体差异-特征参数平均影响值-机器学习方法,评估不同参数对血压模型输出产生影响的重要程度,以及这些参数在血压动态监测过程中产生多大变化时会对血压预测模型输出结果产生显著性影响的规律;

S13:基于MIMIC数据库和实测数据样本集,结合患者个体差异性指标,利用机器学习方法进行分类,找出影响血压预测精度的重要性参数及其变化量大小对血压预测结果影响的规律,得到不同类别下的数据样本,将其划分为不同类别下的训练样本和验证样本子集;

S14:利用对应类别下的训练样本子集对MIV-BP模型进行训练,构建基于遗传算法GA的GA-MIV-BP网络模型,从而构建血压无创动态监测模型簇Models。

3. 根据权利要求1所述的一种无袖带式长时连续血压无创监测方法,其特征在于,所述步骤S3具体包括以下步骤:

S31:应用心电信号和光电容积脉搏波信号监测子系统,利用软件子系统的信号处理和特征提取功能,根据每个心跳节拍的心电信号和光电容积脉搏波信号的特征点进行特征参数提取;

S32:应用血压预测模型确定患者血压监测过程中患者生理病理变化重要性参数及其变化量,得到在血压无创动态监测模型簇中的匹配类别 i ,根据类别匹配对应的血压无创监测模型Model i ,对患者每个心跳节拍的血压值进行预测;

S33:通过每个节拍的心电和光电容积脉搏波信号的生理病理特征参数的提取和变化程度的计算,在血压动态长时测量过程中,实时判断与血压预测模型簇中模型的匹配类别,从而实现自适应选择血压无创动态监测模型簇中的合适模型进行当前心跳节拍的血压预测,实现血压预测模型的“自校正”,得到长时监测过程中连续心跳节拍的血压值,并通过显示器显示;

S34:对连续节拍的血压值进行动态变化过程分析,得到血压实时变化曲线,通过显示器显示。

4. 根据权利要求3所述的一种无袖带式长时连续血压无创监测方法,其特征在于,所述心电信号和光电容积脉搏波信号监测软件子系统包括心电监测传感器及导联线、光电容积脉搏波传感器、心电信号隔离放大模块、光电容积脉搏波信号隔离放大模块和数据采集模块;

所述心电和光电容积脉搏波传感器采集的信号经过各自的隔离放大模块,通过数据采集模块转变为数字量进入计算机,作为血压预测模型的输入量,通过显示器显示心电信号、

光电容积脉搏波信号、实测血压动态变化波形和每10个心跳节拍更新的血压平均值；某一时刻的血压预测模型是由软件子系统根据测量得到的心电信号和光电容积脉搏波信号的特征参数自适应从血压无创动态监测模型簇中匹配类别确定的，在血压动态长时测量过程中实现血压预测模型的自校正，而不需要进行血压预测模型的人为校正。

5. 根据权利要求2所述的一种无袖带式长时连续血压无创监测方法，其特征在于，步骤S14中，训练得到基于患者个体差异-特征参数平均影响值-人工神经网络的无创血压预测模型，具体步骤为：

1) BP神经网络模型的训练：将提取的脉搏波传输时间PWTT和PWPs共17个参数作为输入量，以MIMIC数据库和临床实测数据得到的SBP或DBP作为输出量，分别训练出1个关于收缩压的神经网络Net_{s0}，以及1个关于舒张压的神经网络Net_{d0}；

2) 基于平均影响值MIV的BP神经网络模型的训练：采用MIV作为评价各个自变量对因变量影响程度的指标，对输入的参数进行评估，降维处理，以步骤1)中构建的Net_{s0}和Net_{d0}为基础，通过MIV分析各输入参数对输出结果的影响程度，选出对输出影响累计贡献率大于85%的前几个参数，作为MIV-BP网络的输入参数，重新训练Net_{s0}和Net_{d0}网络，分别得到NET_{s0}和NET_{d0}两个神经网络模型；

3) 基于遗传算法GA的GA-MIV-BP网络模型的构建：考虑患者个体差异对血压预测模型精度的影响，选取训练得到的NET_{s0}网络来构建收缩压计算模型NET_s，NET_{d0}网络来构建舒张压计算模型NET_d，分别使用GA对收缩压计算模型和舒张压计算模型的个性化参数进行优化，从而得到预测性能较好的收缩压计算模型和舒张压计算模型。

6. 根据权利要求5所述的一种无袖带式长时连续血压无创监测方法，其特征在于，步骤1)中，所述神经网络模型的训练步骤为：

①输入参数和输出参数的初步确定，Net_{s0}或Net_{d0}网络的输入层神经元节点数为17，输出层神经元节点数为1；

②初始化BP神经网络参数，包括学习速率、预期误差和激励函数；

③设置网络的隐含层节点数，以神经网络的均方根误差和复杂度确定各网络的隐含层节点数；

④采用收敛性较好的BP神经网络的Scaled Conjugate Gradient算法训练这两个神经网络直到达到预期误差，即训练完成。

7. 根据权利要求5所述的一种无袖带式长时连续血压无创监测方法，其特征在于，所述步骤2)中，MIV的具体运算过程为：

①在训练好BP神经网络后，将训练样本X中每个输入变量分别在原值的基础上做加10%与减10%运算，构成新的两个训练样本X1和X2；

②分别将X1和X2输入到训练好的网络中进行仿真，得到两个仿真结果Y1和Y2；

③计算Y1与Y2的差值，即为该变量变化后对输出的影响变化值 (Impact Value, IV)；

④将IV按观测数目平均求出该自变量对因变量的平均影响值MIV；

按照上述步骤分别计算各自变量的MIV值，按下式计算出第i个自变量对于因变量的相对贡献率：

$$d_i = \frac{|MIV_i|}{\sum_i^m |MIV_i|}$$

其中, θ_i 为第 i 个自变量对于因变量的相对贡献率, 称 $\frac{\sum_{i=1}^n \theta_i}{\sum_{i=1}^m \theta_i}$ 为前 n 个自变量的累计贡献率, 在选取BP神经网络的输入参数时, 要求累计贡献率大于85%。

8. 根据权利要求5所述的一种无袖带式长时连续血压无创监测方法, 其特征在于, 所述步骤3) 中, 构建收缩压计算模型 NET_s 的计算公式为:

$$NET_s = a * NET_{s0} + \nabla s$$

构建舒张压计算模型的计算公式为:

$$NET_d = b * NET_{s0} + \nabla d$$

其中, NET_{s0} 和 NET_{d0} 分别表示利用MIV-BP神经网络训练得到的关于收缩压的神经网络和关于舒张压的神经网络; NET_s 和 NET_d 分别表示基于GA-MIV-BP构建的收缩压预测模型和舒张压预测模型, a 和 ∇s 为收缩压预测模型参数; b 和 ∇d 为舒张压预测模型参数。

9. 根据权利要求5所述的一种无袖带式长时连续血压无创监测方法, 其特征在于, 步骤S14中, 所述构建血压无创动态监测模型簇Models包括以下步骤:

S141: 调用MIMIC数据库中的ECG、PPG和ABP信号; 并对ECG、PPG信号处理及特征提取;

S142: 计算10秒内ECG、PPG信号特征参数平均值, 记为 $PWTT_0$ 、 $PWPS_0$;

S143: 判断计算是否已到最后一个节拍, 若是, 则结束计算; 否则继续ECG、PPG信号处理及特征提取;

S144: 计算ECG、PPG信号每个节拍的特征参数值, 记为 $PWTT_{i0}$ 、 $PWPS_{i0}$;

S145: 调用GA-MIV-BP血压预测模型 $model_0$, 计算得到血压预测值 BP_i ;

S146: 计算血压预测值 BP_i 与实际测量值 ABP_i 之间的误差: $\Delta BP_i = f_{abs}(BP_i - ABP_i)$, 并判断 ΔBP_i 是否在容许范围内, 若是, 则返回步骤S143; 否则执行步骤S147;

S147: 计算当前节拍ECG、PPG信号特征参数平均值, 记为 $PWTT_i$ 、 $PWPS_i$; 并计算特征参数变化量:

$$\Delta PWPS_i = PWPS_i - PWPS_0$$

$$\Delta PWTT_i = PWTT_i - PWTT_0$$

S148: 利用机器学习分类并构建对应类别的MIV-BP模型训练样本, 并调用MIV-BP模型训练算法生成新的GA-MIV-BP血压预测模型 $model_i$;

S149: 用 $model_i$ 替换 $model_0$, 并返回至S141。

10. 根据权利要求4所述的一种无袖带式长时连续血压无创监测方法, 其特征在于, 所述血压预测模型的自校正具体包括以下步骤:

1) 通过单点校正, 结合个体差异参数从模型簇中选择初始GA-MIV-BP血压预测模型 $model_0$;

2) ECG、PPG信号处理及特征提取;

3) 计算10秒内ECG、PPG信号特征参数平均值和血压预测平均值, 记为 $PWTT_0$ 、 $PWPS_0$ 和 BP_0 ;

4) 判断血压监测过程是否终止, 若终止, 则结束; 否则继续ECG、PPG信号处理及特征提取;

5) 计算ECG、PPG信号每个节拍的特征参数值, 记为 $PWTT_{i0}$ 、 $PWPS_{i0}$;

6) 计算得到血压预测值 BP_i ;

7) 计算血压预测值 BP_i 与初始血压平均值 BP_0 之间的误差： $\Delta BP_i = f_{abs}(BP_i - BP_0)$ ，并判断 ΔBP_i 是否在容许范围内，若是，则返回步骤4)；否则执行步骤8)；

8) 计算当前节拍后连续10s内ECG、PPG信号各节拍的特征参平均值，记为 $PWTT_1$ 、 PWP_{S1} ；计算得到血压预测值 BP_1 ，并计算血压预测值 BP_1 与初始血压平均值之间误差： $\Delta BP_1 = f_{abs}(BP_1 - BP_0)$ ，若 ΔBP_1 在容许范围内，则返回步骤4)；否则计算特征参数变化量：

$$\Delta PWP_{S1} = PWP_{S1} - PWP_{S0}$$

$$\Delta PWTT_1 = PWTT_1 - PWTT_0$$

10) 根据 $\Delta PWTT_1$ 、 ΔPWP_{S1} ，结合个体差异参数，用机器学习方法确定分类类别 i ；然后调用新的血压预测模型 $model_i$ ，并替换 $model_0$ 。

一种无袖带式长时连续血压无创监测方法

技术领域

[0001] 本发明属于生物医学工程领域,涉及一种无袖带式长时连续血压无创监测方法。

背景技术

[0002] 当今,高血压发病率越来越高,严重危害人体健康,大量流行病学及临床证据表明,长期患有高血压病会增加患者发生缺血性心脏病、脑卒中、肾衰竭、主动脉和外周动脉疾病等靶器官损害的风险。高血压病属于慢性疾病,多数需要长期终身护理,而对高血压患者生活方式控制的成效,降压药物的药效及高血压的介入治疗的功效评估,都需要对血压进行长时间动态监测,现有研究表明,每搏血压的变异性对高血压的判断意义也正引起越来越多的重视,因此对高血压患者的连续血压监测显得尤为重要。

[0003] 但是血压由于受诸多因素,如身体状况、情绪、生理韵律和环境条件等影响,单次测量血压存在较大差别;同时在心律不齐时,采用断续测量方法测量血压较困难。而连续测量方法可在每个心动周期测量血压,从而可以更早地识别出血压的变化并给予及时的治疗,在临床及医学研究中具有更重要的意义。

[0004] 有创血压监测和无创袖带血压监测是目前临床最常用的两种用于长时动态监测血压的方法,但因其各自的缺陷而限制其临床应用。文献可见的无创连续血压检测方法包括动脉张力法、容积补偿法、脉搏波传导时间法(PWTT)以及脉搏波特征参数(PWPs)法。其中脉搏波传导时间法和脉搏波特征参数法相对测量方便、舒适度高、效果较理想。近几年,诸多学者对PWTT法和PWPs法做了大量的研究,目的在于提高测量精度,以求能够应用于临床。而现有的基于PWTT法或PWPs法的连续血压监测模型仍存在许多不足,不同的PWTT的定义得到的血压预测效果不同,甚至不同研究得到相反的结论,导致利用此类方法建立的血压模型临床监测的稳定性和精度不够理想,不能克服个体差异和长时监测过程中复杂因素的影响,还没有真正达到临床广泛接受的程度。

[0005] 综上所述,血压连续无创监测方法虽然已有长足发展,但仍存在以下问题:(1)不同的方法在临床应用中缺乏普适性,必须在一定条件、一定范围和时间内应用才能满足基本精度要求;(2)不同文献采用了脉搏波等生理信号的不同特征信息作为血压预测模型输入,但得到的结果不一致,甚至相反,因而限制了这些方法的应用;(3)多数研究仅取脉搏波等生理信号的一个或若干个特征信息作为血压预测模型输入,较少或没有考虑每个心跳节拍的脉搏波等生理信号波形的整体特性是人体循环系统及血流动力学特性的综合反映;(4)目前所见方法和设备更多地着眼于血压的单点或短时的测量,且在此过程中,需要多次甚至不断的校准,限制了其应用,更不能进行长时或动态的血压无创监测。

发明内容

[0006] 有鉴于此,本发明的目的在于提供一种无袖带式长时连续血压无创监测方法,通过探究基于每个心跳节拍脉搏波整体特性下的脉搏波传输时间和脉搏波特征参数的无袖带式连续血压无创综合监测方法,研究心电信号、光电容积脉搏波信号不同特征参数对血

压预测结果的影响重要性程度,以及不同特征参数变化对血压输出精度影响的规律,构建血压无创动态监测模型簇,实现无袖带式血压无创动态长时监测过程中的模型结构及不同神经元之间连接权值的自适应动态调整,保证整个监测过程的血压预测精度,实现真正的动态连续节拍的血压长时监测,避免有创测量带来的创伤及袖带血压监测充放气的束缚。

[0007] 为达到上述目的,本发明提供如下技术方案:

[0008] 一种无袖带式长时连续血压无创监测方法,具体包括以下步骤:

[0009] S1:构建血压无创动态监测模型簇Models;

[0010] S2:通过与计算机相连的心电信号和光电容积脉搏波信号监测子系统获取生理病理特征参数;

[0011] S3:由血压无创动态监测模型簇和血压动态长时监测软件子系统对参数进行无缝融合和处理分析,得到每个心跳节拍的血压值并实现动态长时的连续血压监测;

[0012] 进一步,所述步骤S1具体包括以下步骤:

[0013] S11:从无袖带式血压测量出发,采用心电信号和光电容积脉搏波测量子系统监测病人的生理病理信号并提取信号特征参数;

[0014] S12:基于患者个体差异-特征参数平均影响值-机器学习方法,评估不同参数对血压模型输出产生影响的重要程度,以及这些参数在血压动态监测过程中产生多大变化时会对血压预测模型输出结果产生显著性影响的规律;

[0015] S13:基于MIMIC数据库和实测数据样本集,结合患者个体差异性指标,利用机器学习方法进行分类,找出影响血压预测精度的重要性参数及其变化量大小对血压预测结果影响的规律,得到不同类别下的数据样本,将其划分为不同类别下的训练样本和验证样本子集;

[0016] S14:利用对应类别下的训练样本子集对MIV-BP模型进行训练,构建基于遗传算法GA的GA-MIV-BP网络模型,从而构建血压无创动态监测模型簇Models。

[0017] 进一步,所述步骤S3具体包括以下步骤:

[0018] S31:应用心电信号和光电容积脉搏波信号监测子系统,利用软件子系统的信号处理和特征提取功能,根据每个心跳节拍的心电信号和光电容积脉搏波信号的特征点进行特征参数提取;

[0019] S32:应用血压预测模型确定患者血压监测过程中患者生理病理变化重要性参数及其变化量,得到在血压无创动态监测模型簇中的匹配类别i,根据类别匹配对应的血压无创监测模型Model_i,对患者每个心跳节拍的血压值进行预测;

[0020] S33:通过每个节拍的心电和光电容积脉搏波信号的生理病理特征参数的提取和变化程度的计算,在血压动态长时测量过程中,实时判断与血压预测模型簇中模型的匹配类别,从而实现自适应选择无创动态监测模型簇中的合适模型进行当前心跳节拍的血压预测,实现血压预测模型的“自校正”,得到长时监测过程中连续心跳节拍的血压值,并通过显示器显示;

[0021] S34:对连续节拍的血压值进行动态变化过程分析,得到血压实时变化曲线,通过显示器显示。

[0022] 进一步,所述心电信号和光电容积脉搏波信号监测软件子系统包括心电监测传感器及导联线、光电容积脉搏波传感器、心电信号隔离放大模块、光电容积脉搏波信号隔离放

大模块和数据采集模块；

[0023] 所述心电和光电容积脉搏波传感器采集的信号经过各自的隔离放大模块,通过数据采集模块转变为数字量进入计算机,作为血压预测模型的输入量,通过显示器显示心电信号、光电容积脉搏波信号、实测血压动态变化波形和每10个心跳节拍更新的血压平均值;某一时刻的血压预测模型是由软件子系统根据测量得到的心电信号和光电容积脉搏波信号的特征参数自适应从血压无创动态监测模型簇中匹配类别确定的,在血压动态长时测量过程中实现血压预测模型的自校正,而不需要进行血压预测模型的人为校正。

[0024] 进一步,步骤S14中,训练得到基于患者个体差异-特征参数平均影响值-人工神经网络的无创血压预测模型,具体步骤为:

[0025] 1) BP神经网络模型的训练:将提取的脉搏波传输时间PWTT和PWPs共17个参数作为输入量,以临床实测数据得到的SBP或DBP作为输出量,分别训练出1个关于收缩压的神经网络Net_{so},以及1个关于舒张压的神经网络Net_{do};

[0026] 2) 基于平均影响值MIV的BP神经网络模型的训练:采用MIV作为评价各个自变量对因变量影响程度的指标,对输入的参数进行评估,降维处理,以步骤1)中构建的Net_{so}和Net_{do}为基础,通过MIV分析各输入参数对输出结果的影响程度,选出对输出影响累计贡献率大于85%的前几个参数,作为MIV-BP网络的输入参数,重新训练Net_{so}和Net_{do}网络,分别得到NET_{so}和NET_{do}两个神经网络模型;

[0027] 3) 基于遗传算法GA的GA-MIV-BP网络模型的构建:考虑患者个体差异对血压预测模型精度的影响,选取训练得到的NET_{so}网络来构建收缩压计算模型NET_s,NET_{do}网络来构建舒张压计算模型NET_d,分别使用GA对收缩压计算模型和舒张压计算模型的个性化参数进行优化,从而得到预测性能较好的收缩压计算模型和舒张压计算模型。

[0028] 进一步,步骤1)中,所述神经网络模型的训练步骤为:

[0029] ①输入参数和输出参数的初步确定,NET_{so}或NET_{do}网络的输入层神经元节点数为17,输出层神经元节点数为1;

[0030] ②初始化BP神经网络参数,包括学习速率、预期误差和激励函数;

[0031] ③设置网络的隐含层节点数,以神经网络的均方根误差和复杂度确定各网络的隐含层节点数;

[0032] ④采用收敛性较好的BP神经网络的Scaled Conjugate Gradient算法训练这两个神经网络直到达到预期误差,即训练完成。

[0033] 进一步,所述步骤2)中,MIV的具体运算过程为:

[0034] ①在训练好BP神经网络后,将训练样本X中每个输入变量分别在原值的基础上做加10%与减10%运算,构成新的两个训练样本X1和X2;

[0035] ②分别将X1和X2输入到训练好的网络中进行仿真,得到两个仿真结果Y1和Y2;

[0036] ③计算Y1与Y2的差值,即为该变量变化后对输出的影响变化值(Impact Value, IV);

[0037] ④将IV按观测数目平均求出该自变量对因变量的平均影响值MIV;

[0038] 按照上述步骤分别计算各自变量的MIV值,按下式计算出第i个自变量对于因变量的相对贡献率:

$$[0039] \quad \theta_i = \frac{|MIV_i|}{\sum_i^m |MIV_i|}$$

[0040] 其中, θ_i 为第 i 个自变量对于因变量的相对贡献率, 称 $\frac{\sum_i^n \theta_i}{\sum_i^m \theta_i}$ 为前 n 个自变量的累计贡献率, 在选取BP神经网络的输入参数时, 要求累计贡献率大于85%。

[0041] 进一步, 所述步骤3) 中, 构建收缩压计算模型NET_s的计算公式为:

$$[0042] \quad NET_s = a * NET_{s0} + \nabla s$$

[0043] 构建舒张压计算模型的计算公式为:

$$[0044] \quad NET_d = b * NET_{d0} + \nabla d$$

[0045] 其中, NET_{s0}和NET_{d0}分别表示利用MIV-BP神经网络训练得到的关于收缩压的神经网络和关于舒张压的神经网络; NET_s和NET_d分别表示基于GA-MIV-BP构建的收缩压预测模型和舒张压预测模型, a 和 ∇s 为收缩压预测模型参数, a 的解空间为 $[0, 1]$ 之间的实数, ∇s 的解空间为 $[-20, 20]$ 之间的实数; b 和 ∇d 为舒张压预测模型参数, b 的解空间为 $[0, 1]$ 之间的实数, ∇d 的解空间为 $[-20, 20]$ 之间的实数。

[0046] 进一步, 步骤S14中, 所述构建血压无创动态监测模型簇Models包括以下步骤:

[0047] S141: 调用MIMIC数据库中的ECG、PPG和ABP信号; 并对ECG、PPG信号处理及特征提取;

[0048] S142: 计算10秒内ECG、PPG信号特征参数平均值, 记为PWTT₀、PWP_{s0};

[0049] S143: 判断计算是否已到最后一个节拍, 若是, 则结束计算; 否则继续ECG、PPG信号处理及特征提取;

[0050] S144: 计算ECG、PPG信号每个节拍的特征参数值, 记为PWTT_{i0}、PWP_{si0};

[0051] S145: 调用GA-MIV-BP血压预测模型model₀, 计算得到血压预测值BP_i (包括SBP_i、DBP_i);

[0052] S146: 计算血压预测值BP_i与实际测量值ABP_i之间的误差: $\Delta BP_i = f_{abs}(BP_i - ABP_i)$, 并判断 ΔBP_i 是否在容许范围内, 若是, 则返回步骤S143; 否则执行步骤S147;

[0053] S147: 计算当前节拍ECG、PPG信号特征参数平均值, 记为PWTT_i、PWP_{si}; 并计算特征参数变化量:

$$[0054] \quad \Delta PWP_{si} = PWP_{si} - PWP_{s0}$$

$$[0055] \quad \Delta PWTT_i = PWTT_i - PWTT_0$$

[0056] S148: 利用机器学习分类并构建对应类别的MIV-BP模型训练样本, 并调用MIV-BP模型训练算法生成新的GA-MIV-BP血压预测模型model_i;

[0057] S149: 用model_i替换model₀, 并返回至S141。

[0058] 进一步, 所述血压预测模型的自校正具体包括以下步骤:

[0059] 1) 通过单点校正, 结合个体差异参数从模型簇中选择初始GA-MIV-BP血压预测模型model₀;

[0060] 2) ECG、PPG信号处理及特征提取;

[0061] 3) 计算10秒内ECG、PPG信号特征参数平均值和血压预测平均值, 记为PWTT₀、PWP_{s0}和BP₀;

[0062] 4) 判断血压监测过程是否终止,若终止,则结束;否则继续ECG、PPG信号处理及特征提取;

[0063] 5) 计算ECG、PPG信号每个节拍的特征参数值,记为 $PWTT_{i0}$ 、 $PWPS_{i0}$;

[0064] 6) 计算得到血压预测值 BP_i (包括 SBP_i 、 DBP_i);

[0065] 7) 计算血压预测值 BP_i 与初始血压平均值 BP_0 之间的误差: $\Delta BP_i = f_{abs}(BP_i - BP_0)$, 并判断 ΔBP_i 是否在容许范围内,若是,则返回步骤4);否则执行步骤8);

[0066] 8) 计算当前节拍后连续10s内ECG、PPG信号各节拍的特征参平均值,记为 $PWTT_1$ 、 $PWPS_1$;计算得到血压预测值 BP_1 (包括 SBP_1 、 DBP_1),并计算血压预测值 BP_1 与初始血压平均值之间误差: $\Delta BP_1 = f_{abs}(BP_1 - BP_0)$,若 ΔBP_1 在容许范围内,则返回步骤4);否则计算特征参数变化量:

[0067] $\Delta PWPS_i = PWPS_i - PWPS_0$

[0068] $\Delta PWTT_i = PWTT_i - PWTT_0$

[0069] 10) 根据 $\Delta PWTT_i$ 、 $\Delta PWPS_i$,结合个体差异参数,用机器学习方法确定分类类别 i ;然后调用新的血压预测模型 $model_i$,并替换 $model_0$ 。

[0070] 本发明的有益效果在于:

[0071] (1) 本发明综合应用了与血压变化相关的生理信号特征参数和患者个体信息,避免个体差异影响,具有更好的适应性;

[0072] (2) 构建了基于患者个体差异-特征参数平均影响值-机器学习方法的血压长时动态监测模型簇,而不是单一模型,具有更高的准确性、有效性和临床适应性;

[0073] (3) 利用了机器学习方法建立了生理信号特征参数分类类别匹配模型簇中模型的匹配方法,实现了血压动态长时测量过程中自适应选择合适血压预测模型,实现了血压测量过程中的“自校正”,克服了现有方法需要多次校正、不能真正实现血压长时监测的缺陷。

[0074] 本发明的其他优点、目标和特征在某种程度上将在随后的说明书中进行阐述,并且在某种程度上,基于对下文的考察研究对本领域技术人员而言将是显而易见的,或者可以从本发明的实践中得到教导。本发明的目标和其他优点可以通过下面的说明书来实现和获得。

附图说明

[0075] 为了使本发明的目的、技术方案和优点更加清楚,下面将结合附图对本发明作优选的详细描述,其中:

[0076] 图1为本发明血压动态长时测量模型簇构建流程框图;

[0077] 图2为本发明血压动态长时测量模型自适应选择流程框图;

[0078] 图3为实测脉搏波信号干扰及其识别效果图;

[0079] 图4为脉搏波特征参数定义示意图;

[0080] 图5为基于GA优化的MIV-BP神经网络无创血压测量模型训练框图;

[0081] 图6为基于GA-MIV-BP模型的血压预测值与血压实际测量值的比较曲线图。

具体实施方式

[0082] 以下通过特定的具体实例说明本发明的实施方式,本领域技术人员可由本说明书

所揭示的内容轻易地了解本发明的其他优点与功效。本发明还可以通过另外不同的具体实施方式加以实施或应用,本说明书中的各项细节也可以基于不同观点与应用,在没有背离本发明的精神下进行各种修饰或改变。需要说明的是,以下实施例中所提供的图示仅以示意方式说明本发明的基本构想,在不冲突的情况下,以下实施例及实施例中的特征可以相互组合。

[0083] 本发明提供了一种无袖带式血压无创长时连续监测方法,通过与计算机相连的心电信号和光电容积脉搏波信号监测子系统获取生理病理参数,由血压动态长时测量模型簇及血压动态长时监测软件子系统对参数进行无缝融合和处理分析,得到每个心跳节拍的血压值并实现动态长时的连续血压监测。

[0084] 为了保证血压预测的准确性,首先要保证通过心电传感器和脉搏波传感器测量到的心电信号和脉搏波信号的质量,在对采集到的心电信号和脉搏波信号进行降噪处理的基础上,需要对去噪后的生理信号进行质量评估,有效识别出有用信号段和干扰信号段,为信号特征点的识别提供基础。图3所示为一段信号实际采集过程中模拟可能遇到的各种情况,如传感器滑落和放置过程中产生的脉冲干扰、信号丢失以及运动伪迹等,利用本发明软件子系统的信号处理分析和质量评估功能,可以有效划分有用信号和噪声的不同区域,准确提取出有用信号段和干扰信号段。

[0085] 利用本发明软件子系统的信号处理和特征提取功能对有用信号段的生理信号特征点实现准确识别,计算得到不同类型的特征参数,如图4所示,包括(1)时间类特征参数:升支相对时间(t_c/T)、特征点d相对时间(t_d/T)、特征点e相对时间(t_e/T)、特征点f相对时间(t_f/T)、特征点g相对时间(t_g/T)、周期T;(2)幅度类特征参数:特征点d相对高度(H_d/H_c)、特征点e相对高度(H_e/H_c)、特征点f相对高度(H_f/H_c)、特征点g相对高度(H_g/H_c);(3)其它特征参数:波形特征量K、主波上升斜率V、心输出量Z、收缩期相对面积(S_1/S)、舒张期相对面积(S_2/S)、收缩期与舒张期面积之比(S_1/S_2),以及脉搏波传输时间PWTT,共计17个参数。基于这17个参数,结合患者个体差异性指标,如年龄、性别、身高、体重、身体质量指数和高血压治疗情况等,按照图5所述方法训练得到基于患者个体差异-特征参数平均影响值-人工神经网络的无创血压预测模型。模型训练的具体步骤如下:

[0086] (1) BP神经网络模型的训练:将提取到的PWTT和PWP_s共17个参数作为输入量,以临床实测数据得到的SBP或DBP作为输出量,分别训练出1个关于收缩压的神经网络(Nets0),以及1个关于舒张压的神经网络(Netd0)。具体过程为:

[0087] ①输入参数和输出参数的初步确定,Nets0或Netd0网络的输入层神经元节点数为17,输出层神经元节点数为1。

[0088] ②初始化BP神经网络的参数,包括学习速率、预期误差和激励函数等。

[0089] ③设置网络的隐含层节点数,以神经网络的均方根误差和复杂度确定各网络的隐含层节点数。

[0090] ④采用收敛性较好的BP神经网络的Scaled Conjugate Gradient算法训练这两个神经网络直到达到预期误差,即训练完成。

[0091] (2) 基于平均影响值(MIV)的BP神经网络模型训练:采用MIV作为评价各个自变量对因变量影响程度的指标,对输入的参数进行评估,作降维处理,以(1)中构建的Nets0和Netd0为基础,通过MIV分析各输入参数对输出结果的影响程度,选出对输出影响累计贡献

率大于85%的前几个参数,作为MIV-BP网络的输入参数,重新训练Nets0和Netd0网络,分别得到NETs0和NETd0这两个神经网络模型。MIV的具体运算过程为:

[0092] ①在训练好BP神经网络后,将训练样本X中每个输入变量分别在原值的基础上做加10%与减10%运算,构成新的两个训练样本X1和X2;

[0093] ②分别将X1和X2输入到训练好的网络中进行仿真,得到两个仿真结果Y1和Y2;

[0094] ③计算Y1与Y2的差值,即为该变量变化后对输出的影响变化值(Impact Value, IV);

[0095] ④将IV按观测数目平均求出该自变量对因变量的平均影响值(MIV)。

[0096] 按照上述步骤分别计算各自变量的MIV值。最后根据式(1)计算出第i个自变量对于因变量的相对贡献率。

$$[0097] \quad \theta_i = \frac{|MIV_i|}{\sum_i^m |MIV_i|} \quad (1)$$

[0098] 式(1)中 θ_i 为第i个自变量对于因变量的相对贡献率,称 $\sum_i^n \theta_i$ 为前n个自变量的累计贡献率,在选取BP神经网络的输入参数时,要求累计贡献率大于85%。

[0099] (3)基于遗传算法(GA)的GA-MIV-BP网络模型的构建:考虑患者个体差异对血压预测模型精度的影响,选取训练得到的NETs0网络来构建收缩压计算模型,NETd0网络来构建舒张压计算模型,分别使用GA对收缩压计算模型和舒张压计算模型的个性化参数进行优化,从而得到预测性能较好的收缩压计算模型和舒张压计算模型。对于单个个体的GA-MIV-BP网络模型,以收缩压预测模型为例,具体步骤如下:

[0100] ①对收缩压预测模型的两个参数a和 ∇s 进行实数编码,a的解空间为[0,1]之间的实数, ∇s 的解空间为[-20,20]之间的实数,如{0.8315,-3.1349}就是一个合法的染色体。

[0101] ②染色编码完成后,随机产生40个染色体的初始种群作为起始解,并设置遗传代数为100。

[0102] ③适应度评估,用单个测试者的前两组数据作为训练集,将模型预测值和血压计测量值的误差平方和的倒数作为适应度值。优化的目标就是选择适应度值尽可能大的染色体,适应度值越大的染色体越优质,反之越劣质。

[0103] ④进行选择、交叉和变异得到新一代种群,本项目基于适应度比例选择父代个体繁殖下一代,设置交叉概率为0.7,变异概率为0.01。循环操作,判断是否满足设定的最大遗传代数,不满足则跳入适应度计算,继续遗传操作,反之遗传操作结束。

[0104] 利用GA-MIV-BP模型室对12个受测者的294组数据进行血压预测分析,所得收缩压(SBP)和舒张压(DBP)的血压预测值与血压计测量值之间的对比情况如图6所示。其中i-j表示第i个测试者的第j组数据。

[0105] 基于GA-MIV-BP血压预测模型框架,利用机器学习方法构建血压无创连续动态长时监测过程中的模型簇,以满足血压动态长时监测精度的要求。为避免使用过程中个体差异对模型预测精度的影响,在建模过程中按个体差异(如BMI、腰围、臀围、腰臀比、年龄、性别、动脉硬化指数、高血压治疗情况、区域条件等)类别引入不同校正系数,在按血压值进行血压级别分类的基础上,进一步按照年龄分段方法划分为5类:青春期:12-20;青年期:21-35;中年期:36-50;中老年期:51-75;老年期:>75,不同年龄组按个体差异情况进行分类。实

实际应用时,根据被试者情况确定其个体差异校正系数类别,直接使用相应的校正系数。在此基础上,按图1所示流程进行血压预测模型簇的构建:

[0106] ①血压连续监测过程中,因为患者个体差异的相关参数基本保持不变,因此将不再是影响血压监测模型输出精度的主要因素。监测过程中血压的变化将反映在心电、脉搏波信号的特征变化中,即影响患者血压值的生理病理变化通过信号特征反映出来,所以后续模型的动态调整将在考虑个体差异的基础上以信号特征参数及其变化规律为主要输入参数进行模型调整和预测;

[0107] ②评估心电、脉搏波信号不同特征参数对血压模型输出产生影响的重要程度,以及这些参数在血压动态监测过程中产生多大的变化时会对血压预测模型输出结果产生显著性影响的规律进行研究,与个体差异性指标一起作为机器学习算法的输入参数。利用支持向量机和随机森林方法等机器学习方法对数据进行分类,找出影响血压预测精度的重要性参数及其变化量大小对血压预测结果影响的规律,得到不同类别下的数据样本,将其划分为不同类别下的训练样本和验证样本子集,利用对应类别下的训练样本子集对MIV-BP模型进行训练,从而构建血压无创动态监测模型簇Models。模型簇训练流程图如图1所示。通过图1所述过程,得到血压预测精度超过容许误差时的输入特征参数及其变化量 $\Delta PWTT_i$ 和 ΔPWP_{Si} ,利用机器学习方法进行分类,调用MIV-BP网络训练算法,得到对应条件下满足血压预测精度要求的GA-MIV-BP血压预测模型 $model_i$,最终形成对个体差异性具有较强鲁棒性、与信号特征参数、 $\Delta PWTT_i$ 和 ΔPWP_{Si} 相关的对应类别下的血压预测模型簇 $models$ 。

[0108] ③利用机器学习得到血压无创监测模型簇后,实际长时监测血压时,在血压某一时刻的预测值与模型选择时刻血压值之间的变化量超过容许值时,可通过有效提取心电、脉搏波信号特征参数及重要性参数的变化量,利用机器学习,结合描述患者个体差异的参数IDPs (Individual Difference Parameters),实时判断其对血压预测值影响程度的匹配类别 i ,根据类别匹配对应的血压无创监测模型 $Model_i$,自适应选择合适血压预测模型进行血压预测,如式(2)所示,在血压长时或动态测量过程中,实现血压预测模型的“自校正”,进而得到更加精确的血压输出,如式(3)和(4)所示,真正实现血压无创监测过程中的血压预测模型的动态调整,克服现有方法中血压预测模型长时监测时不可靠、需要多次校正、无法满足临床实际需求的缺陷,真正满足临床连续节拍的血压无创长时监测需求。

[0109] $model_i = F(IDPs, PWTT, PWP_s, \Delta PWTT, \Delta PWP_s)$ (2)

[0110] $SBP(t) = s_model_i(IDPs, PWTT(t), PWP_1(t), PWP_2(t), \dots, PWP_n(t))$ (3)

[0111] $DBP(t) = d_model_i(IDPs, PWTT(t), PWP_1(t), PWP_2(t), \dots, PWP_n(t))$ (4)

[0112] 式(2)中的 $model_i$ 包括了用于收缩压预测的 s_model_i 和用于舒张压预测的 d_model_i ,PWTT指脉搏波传输时间,PWP_s指除各个PWTT外脉搏波波形特征参数,IDPs表示描述患者个体差异的参数,F(*)表示用于血压预测的与IDPs及心电和脉搏波信号特征参数有关的函数关系。式(3)中的 $s_model_i(*)$ 和式(4)中的 $d_model_i(*)$ 分别表示当前时刻选择的用于收缩压和舒张压预测的模型。

[0113] 如图1所示,血压无创动态监测模型簇Models包括以下步骤:

[0114] 1) 调用MIMIC数据库中的ECG、PPG和ABP信号;并对ECG、PPG信号处理及特征提取;

[0115] 2) 计算10秒内ECG、PPG信号特征参数平均值,记为PWTT₀、PWP_{s0};

[0116] 3) 判断计算是否已到最后一个节拍,若是,则结束计算;否则继续ECG、PPG信号处

理及特征提取；

[0117] 4) 计算ECG、PPG信号每个节拍的特征参数值，记为 $PWTT_{i0}$ 、 $PWPS_{i0}$ ；

[0118] 5) 调用GA-MIV-BP血压预测模型 $model_0$ ，计算得到血压预测值 BP_i (包括 SBP_i 、 DBP_i)；

[0119] 6) 计算血压预测值 BP_i 与实际测量值 ABP_i 之间的误差： $\Delta BP_i = f_{abs}(BP_i - ABP_i)$ ，并判断 ΔBP_i 是否在容许范围内，若是，则返回步骤3)；否则执行步骤7)；

[0120] 7) 计算当前节拍ECG、PPG信号特征参数平均值，记为 $PWTT_i$ 、 $PWPS_i$ ；并计算特征参数变化量：

[0121] $\Delta PWPS_i = PWPS_i - PWPS_0$

[0122] $\Delta PWTT_i = PWTT_i - PWTT_0$

[0123] 8) 利用机器学习分类并构建对应类别的MIV-BP模型训练样本，并调用MIV-BP模型训练算法生成新的GA-MIV-BP血压预测模型 $model_i$ ；

[0124] 9) 用 $model_i$ 替换 $model_0$ ，并返回至1)。

[0125] 其中，血压无创监测过程中预测模型自适应选择流程如图2所示，具体步骤为：

[0126] 1) 通过单点校正，结合个体差异参数从模型簇中选择初始GA-MIV-BP血压预测模型 $model_0$ ；

[0127] 2) ECG、PPG信号处理及特征提取；

[0128] 3) 计算10秒内ECG、PPG信号特征参数平均值和血压预测平均值，记为 $PWTT_0$ 、 $PWPS_0$ 和 BP_0 ；

[0129] 4) 判断血压监测过程是否终止，若终止，则结束；否则继续ECG、PPG信号处理及特征提取；

[0130] 5) 计算ECG、PPG信号每个节拍的特征参数值，记为 $PWTT_{i0}$ 、 $PWPS_{i0}$ ；

[0131] 6) 计算得到血压预测值 BP_i (包括 SBP_i 、 DBP_i)；

[0132] 7) 计算血压预测值 BP_i 与初始血压平均值 BP_0 之间的误差： $\Delta BP_i = f_{abs}(BP_i - BP_0)$ ，并判断 ΔBP_i 是否在容许范围内，若是，则返回步骤4)；否则执行步骤8)；

[0133] 8) 计算当前节拍后连续10s内ECG、PPG信号各节拍的特征参平均值，记为 $PWTT_1$ 、 $PWPS_1$ ；计算得到血压预测值 BP_1 (包括 SBP_1 、 DBP_1)，并计算血压预测值 BP_1 与初始血压平均值之间误差： $\Delta BP_1 = f_{abs}(BP_1 - BP_0)$ ，若 ΔBP_1 在容许范围内，则返回步骤4)；否则计算特征参数变化量：

[0134] $\Delta PWPS_i = PWPS_i - PWPS_0$

[0135] $\Delta PWTT_i = PWTT_i - PWTT_0$

[0136] 10) 根据 $\Delta PWTT_i$ 、 $\Delta PWPS_i$ ，结合个体差异参数，用机器学习方法确定分类类别 i ；然后调用新的血压无创监测模型 $model_i$ ，并替换 $model_0$ 。

[0137] 最后说明的是，以上实施例仅用以说明本发明的技术方案而非限制，尽管参照较佳实施例对本发明进行了详细说明，本领域的普通技术人员应当理解，可以对本发明的技术方案进行修改或者等同替换，而不脱离本技术方案的宗旨和范围，其均应涵盖在本发明的权利要求范围当中。




图1




图2




图3




图4




图5




图6

专利名称(译)	一种无袖带式长时连续血压无创监测方法		
公开(公告)号	CN109965862A	公开(公告)日	2019-07-05
申请号	CN201910305930.0	申请日	2019-04-16
[标]申请(专利权)人(译)	重庆大学		
申请(专利权)人(译)	重庆大学		
当前申请(专利权)人(译)	重庆大学		
[标]发明人	季忠 李孟泽 陈硕 谭霞 吴海燕		
发明人	季忠 李孟泽 陈硕 谭霞 吴海燕		
IPC分类号	A61B5/021 A61B5/00		
CPC分类号	A61B5/02108 A61B5/7246		
外部链接	Espacenet SIPO		

摘要(译)

本发明涉及一种无袖带式长时连续血压无创监测方法，属于生物医学工程领域。该方法包括：通过与计算机相连的心电信号和光电容积脉搏波信号监测子系统获取生理病理特征参数；由血压无创动态监测模型簇和血压动态长时监测软件子系统对参数进行无缝融合和处理分析，得到每个心跳节拍的血压值并实现动态长时的连续血压监测；血压无创动态监测模型簇是从无袖带式血压测量出发，采用上述信号测量子系统监测病人的生理病理特征参数，基于患者个体差异-特征参数平均影响值-机器学习方法构建，使系统具有血压长时连续测量的模型自校正能力。本发明提高了血压长时测量的稳定性和监测精度，血压的连续节拍或长时测量，可为高血压病的防治奠定更有效的基础。

