



(12)发明专利申请

(10)申请公布号 CN 109886347 A

(43)申请公布日 2019.06.14

(21)申请号 201910150825.4

(22)申请日 2019.02.28

(71)申请人 泉州师范学院

地址 360000 福建省泉州市丰泽区东海大街398号

(72)发明人 刘宁

(74)专利代理机构 福州君诚知识产权代理有限公司 35211

代理人 戴雨君

(51) Int. Cl.

G06K 9/62(2006.01)

G06N 3/04(2006.01)

A61B 5/021(2006.01)

A61B 5/00(2006.01)

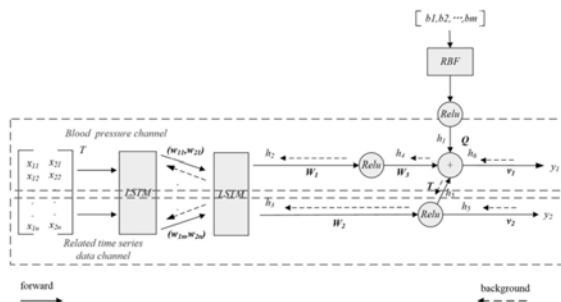
权利要求书1页 说明书8页 附图1页

(54)发明名称

基于RBF和LSTM模型的多因素网络的血压预测方法

(57)摘要

本发明公开基于RBF和LSTM模型的多因素网络的血压预测方法,其包括以下步骤:步骤1,输入近期血压观测值利用现有的双通道预测的LSTM模型获取血压预测输出h3;步骤2,输入时序测量数据利用现有的双通道预测的LSTM模型获取时序数据预测输出h4;步骤3,采用RBF神经网络对用户基本信息归类且线性求和获取输出h6并作为基本信息线索b,步骤4,将h3、h4、h6数据联合后采用Relu非线性激活得到输出h5,步骤5,应用线性回归分别得到血压的预测值和时序线索的预测值。本发明引入RBF网络对输入的用户信息进行特征提取,将预测血压预测值和时序数据预测值与用户信息相关联,以适应不同人群特点,具有更好预测效果,适用于血压长期预测。



CN 109886347 A

1. 基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在于:其包括以下步骤:

步骤1,输入近期血压观测值 $X_1 = [x_{11}, x_{12}, \dots, x_{1n}]$,利用现有的双通道预测的LSTM模型获取血压预测通道隐藏层输出 h_3 ;

步骤2,输入与血压关联的时序测量数据 $X_2 = [x_{21}, x_{22}, \dots, x_{2n}]$,利用现有的双通道预测的LSTM模型获取时序数据预测通道隐藏层输出 h_4 ;

步骤3,获取用户基本信息,采用RBF神经网络使用径向函数对用户基本信息归类且线性求和得到隐藏层输出 h_6 并作为基本信息线索 b ,

步骤4,将血压预测通道隐藏层输出 h_3 、时序数据预测通道隐藏层输出 h_4 、用户基本信息线索 h_6 数据联合后采用ReLu来进行非线性激活得到隐藏层输出 h_5 ,见公式(4),

$$h_5 = \text{ReLu}(h_3W_3 + h_4T + h_6Q) \quad \text{MERGEFORMAT (4)};$$

其中, W_3 表示血压预测通道隐藏层输出的权重, T 表示时序数据预测通道隐藏层输出的权重, Q 表示基本信息线索的权重;

步骤5,应用线性回归来分别得到血压的预测值和时序线索的预测值,计算公式如下:

$$y_1 * h_5 V_1 + b_1 \quad \text{MERGEFORMAT (5)}$$

$$y_2 * h_5 V_2 + b_2 \quad \text{MERGEFORMAT (6)}$$

其中, V_1 是血压预测的线性回归参数, V_2 是时序数据预测的线性回归参数, b_1 是血压预测的偏差, b_2 是时序数据预测的偏差; y_1 表示血压预测值, y_2 表示预测时序数据预测值。

2. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:

步骤2中具体选取用户的心率数据作为时序数据。

3. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:

步骤3中用户信息包括:年龄、性别、BMI、身高、体重、服药情况、饮酒情况、吸烟情况。

4. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:步骤3的具体步骤为:

步骤3.1,将用户基本信息整理成M维向量 $B, B = [b_1, b_2, \dots, b_m]$ 输入给RBF神经网络;

步骤3.2,RBF神经网络的神经元采用聚类的方法对输入的用户信息聚类中心点将用户信息进行归类处理;

步骤3.3,线性求和得到RBF神经网络的隐藏层输出 h_6 作为基本信息线索 b 。

5. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:步骤3中采用K-means聚类方法进行归类处理。

6. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:步骤3中使用采用高斯函数作为RBF神经网络隐藏层单元的传递函数。

7. 根据权利要求1所述的基于RBF和LSTM模型的多因素网络的血压预测方法,其特征在在于:步骤3中由RBF神经网络的每个神经元的核函数处理聚类中心点及附近的类或者对象,聚类中心点即为各个神经元中核函数的中心点。

基于RBF和LSTM模型的多因素网络的血压预测方法

技术领域

[0001] 本发明涉及医疗技术领域,尤其涉及基于RBF和LSTM模型的多因素网络的血压预测方法。

背景技术

[0002] 血压是一个人健康状况的重要指标,血压过高容易发生心肌梗死、心力衰竭、脑出血等突发状况。为了预防血压的不良变化带来严重后果,提前对血压进行预测以监控血压变化非常重要。

[0003] 血压监测包括测量和预测两种方法,绝大部分血压计采用听诊法和示波法等换算测量得到某一时刻的血压值。随着健康管理的普及,从连续的历史血压数据来提前预测近期可能的血压变化成为可能。然而,仅仅采用用户连续时段的血压数据预测其下一时段的血压是不全面的。事实上,血压的变化与很多因素相关,将这些因素作为辅助因素用于血压预测,将会提高血压预测的准确度。

[0004] 目前使用历史血压测量数据对血压值进行预测的研究还是比较少,该方面研究多采用机器学习算法和神经网络算法。文献[26]采用多模糊函数模型来预测平均动态血压,该方法改善了在进行连续多个时间段的血压预测的误差累积状况,但没有能够充分利用血压数据时间状态上的关联性和其他与血压关联的因素对其的影响,文献[27]采用回声状态网络来进行血压预测,回声状态网络是为了解决传统递归神经网络(RNN)出现梯度消失与梯度爆炸问题而提出,其在RNN中添加了储备池来对简单时序数据进行记忆,但该网络只能进行短期的记忆,不能很好处理复杂动态问题,文献[28]分别采用BP神经网络和径向基神经网络使用用户个人信息预测用户的舒张压情况,对高于舒张压正常范围的用户进行提醒,对用户信息与舒张压情况建立关系,但该方法仅有单次预测能力,不具有实时预测,实时监控的能力,不能及时为用户提供血压预警,文献[29]基于递归神经网络,提出了一种带有用户辅助信息层的递归模型(LSTM-CL)来预测用户的血压值,但模型没有考虑基本信息与血压的相关性大小差异和时序测量数据与血压变化关系,以上方法单从血压本身或一些简单的相关数据出发,没有能够充分利用与血压相关联的数据变化对血压的影响。

发明内容

[0005] 本发明的目的在于提供基于RBF和LSTM模型的多因素网络的血压预测方法。

[0006] 本发明采用的技术方案是:

[0007] 基于RBF和LSTM模型的多因素网络的血压预测方法,其包括以下步骤:

[0008] 步骤1,输入近期血压观测值 $X_1 = [x_{11}, x_{12}, \dots, x_{1n}]$,利用现有的双通道预测的LSTM模型获取血压预测通道隐藏层输出 h_3 ;

[0009] 步骤2,输入与血压关联的时序测量数据 $X_2 = [x_{21}, x_{22}, \dots, x_{2n}]$,利用现有的双通道预测的LSTM模型获取时序数据预测通道隐藏层输出 h_4 ;

[0010] 步骤3,获取用户基本信息,采用RBF神经网络对用户基本信息归类且线性求和得

到隐藏层输出 h_6 并作为基本信息线索 b ,

[0011] 步骤4,将血压预测通道隐藏层输出 h_3 、时序数据预测通道隐藏层输出 h_4 、用户基本信息线索 h_6 数据联合后采用 ReLu 来进行非线性激活得到隐藏层输出 h_5 ,见公式(4),

[0012] $h_5 = \text{ReLu}(h_3W_3 + h_4T + h_6Q)$ MERGEFORMAT (4);

[0013] 其中, W_3 表示血压预测通道隐藏层输出的权重, T 表示时序数据预测通道隐藏层输出的权重, Q 表示基本信息线索的权重;

[0014] 步骤5,应用线性回归来分别得到血压的预测值和时序线索的预测值,计算公式如下:

[0015] $y_1 * h_5 V_1 + b_1$ MERGEFORMAT (5)

[0016] $y_2 * h_5 V_2 + b_2$ MERGEFORMAT (6)

[0017] 其中, V_1 是血压预测的线性回归参数, V_2 是时序数据预测的线性回归参数, b_1 是血压预测的偏差, b_2 是时序数据预测的偏差; y_1 表示血压预测值, y_2 表示预测时序数据预测值。

[0018] 进一步地,步骤2中具体选取用户的心率数据作为时序数据。

[0019] 进一步地,步骤3中用户信息包括:年龄、性别、BMI、身高、体重、服药情况、饮酒情况、吸烟情况。

[0020] 进一步地,步骤3的具体步骤为:

[0021] 步骤3.1,将用户基本信息整理成 M 维向量 B , $B = [b_1, b_2, \dots, b_m]$ 输入给RBF神经网络;

[0022] 步骤3.2,RBF神经网络的神经元采用聚类的方法对输入的用户信息聚类中心点将用户信息进行归类处理,

[0023] 步骤3.3,线性求和得到RBF神经网络的隐藏层输出 h_6 作为基本信息线索 b 。

[0024] 进一步地,步骤3中采用K-means聚类方法进行归类处理。

[0025] 进一步地,步骤3中使用采用高斯函数作为RBF神经网络隐藏层单元的传递函数。

[0026] 进一步地,步骤3中由RBF神经网络的每个神经元的核函数处理聚类中心点及附近的类或者对象,聚类中心点即为各个神经元中核函数的中心点。

[0027] 本发明采用以上技术方案,基于现有的LSTM的双通道模型,分别通过LSTM的血压预测通道利用近期血压观测值预测血压预测值;通过LSTM的时序预测通道通过与血压关联的时序测量数据预测时序数据预测值,运用的多任务学习的思想;关键是引入RBF网络对输入的用户信息来进行特征提取,将预测的血压预测值和时序数据预测值能够与用户信息相关联,以适应不同人群特点,且具有更好预测效果,适用于血压长期预测。

附图说明

[0028] 以下结合附图和具体实施方式对本发明做进一步详细说明;

[0029] 图1为本发明基于RBF和LSTM模型的多因素网络的血压预测方法的框架示意图。

具体实施方式

[0030] 如图1所示,本发明公开了基于RBF和LSTM模型的多因素网络的血压预测方法。现有技术中通过将用户的个人信息与环境因素信息添加进血压预测,与血压相关的不同类型因素采用不同的方法进行处理,采用传统统计学方法将用户的个人信息按不同比重进行组

合得到模型中的b值,个人信息包括:年龄、性别、BMI、身高、体重、服药情况、饮酒情况、吸烟情况等。

[0031] 为了克服在对用户进行分类后预测效果比较时,不同分类结果之间差异很大,用户血压预测的个性化时面对不同人群模型的适应能力差的状况。本发明采用RBF网络来克服原先按照相关性及因素重要程度进行赋不同权重的组合方法,减少人为干涉,更加智能化进行特征提取。本发明的基于RBF和LSTM模型的多因素网络的血压预测方法,其包括以下步骤:

[0032] 步骤1,输入近期血压观测值 $X_1 = [x_{11}, x_{12}, \dots, x_{1n}]$,利用现有的双通道预测的LSTM模型获取血压预测通道隐藏层输出 h_3 ;

[0033] 步骤2,输入与血压关联的时序测量数据 $X_2 = [x_{21}, x_{22}, \dots, x_{2n}]$,利用现有的双通道预测的LSTM模型获取时序数据预测通道隐藏层输出 h_4 ;

[0034] 步骤3,获取用户基本信息,采用RBF神经网络对用户基本信息归类且线性求和得到隐藏层输出 h_6 并作为基本信息线索b,

[0035] 步骤4,将血压预测通道隐藏层输出 h_3 、时序数据预测通道隐藏层输出 h_4 、用户基本信息线索 h_6 数据联合后采用Relu来进行非线性激活得到隐藏层输出 h_5 ,见公式(4),

[0036] $h_5 = \text{Relu}(h_3W_3 + h_4T + h_6Q)$ MERGEFORMAT (4);

[0037] 其中, W_3 表示血压预测通道隐藏层输出的权重, T 表示时序数据预测通道隐藏层输出的权重, Q 表示基本信息线索的权重;

[0038] 步骤5,应用线性回归来分别得到血压的预测值和时序线索的预测值,计算公式如下:

[0039] $y_1 * h_5 V_1 + b_1$ MERGEFORMAT (5)

[0040] $y_2 * h_5 V_2 + b_2$ MERGEFORMAT (6)

[0041] 其中, V_1 是血压预测的线性回归参数, V_2 是时序数据预测的线性回归参数, b_1 是血压预测的偏差, b_2 是时序数据预测的偏差; y_1 表示血压预测值, y_2 表示预测时序数据预测值。

[0042] 进一步地,步骤2中具体选取用户的心率数据作为时序数据。

[0043] 进一步地,步骤3中用户信息包括:年龄、性别、BMI、身高、体重、服药情况、饮酒情况、吸烟情况。

[0044] 进一步地,步骤3的具体步骤为:

[0045] 步骤3.1,将用户基本信息整理成M维向量 $B, B = [b_1, b_2, \dots, b_m]$ 输入给RBF神经网络;

[0046] 步骤3.2,RBF神经网络的神经元采用聚类的方法对输入的用户信息聚类中心点将用户信息进行归类处理,

[0047] 步骤3.3,线性求和得到RBF神经网络的隐藏层输出 h_6 作为基本信息线索b。

[0048] 进一步地,步骤3中采用K-means聚类方法进行归类处理。

[0049] 进一步地,步骤3中使用采用高斯函数作为RBF神经网络隐藏层单元的传递函数。

[0050] 进一步地,步骤3中由RBF神经网络的每个神经元的核函数处理聚类中心点及附近的类或者对象,聚类中心点即为各个神经元中核函数的中心点。

[0051] 下面就本发明的具体原理做详细说明:

[0052] 如图1所示,本发明模型具体结构为双通道预测结构,其包括血压预测通道和时序

预测通道。双通道工作原理相同,血压预测通道利用近期血压观测值 $X_1 = [x_{11}, x_{12}, \dots, x_{1n}]$ 预测血压预测值 y_1 ;时序预测通道通过与血压关联的时序测量数据 $X_2 = [x_{21}, x_{22}, \dots, x_{2n}]$ 预测时序数据预测值 y_2 ,运用的多任务学习的思想。

[0053] 本发明的网络模型的不同之处在于,用RBF网络来处理用户的基本信息的添加,将用户的基本信息组成M维向量 $B, B = [b_1, b_2, \dots, b_m]$ 输入给RBF神经网络,RBF神经元对输入信息进行聚类寻找合适的中心点,即采用聚类的方法对输入的用户信息做聚类处理,模型中采用K-means聚类方法,使得信息相近的用户归为一类。

[0054] 然后使用径向基函数作为隐藏层单元的传递函数,径向基函数采用高斯函数,聚类中心点即为各个神经元中核函数的中心点,每个神经元的核函数专注于处理自己中心点及附近的类或者对象。

[0055] 最后将神经元的输出进行线性求和得到 h_1 作为模型基本信息线索。

[0056] 综合而言,该RBF网络工作原理实际上是对训练集中所有用户进行聚类分析,得到聚类结果对应于神经元核函数的中心点,每个神经元专注于处理自己对应的类别人群,根据训练集数据训练对应于不同人群的处理方式。模型使得输入用户的基本信息后,在符合自己规律的神经元中得到最大处理,最后的到输出值。使得本发明的网络模型能够适应不同人群特点,增加了本发明的网络模型的个性化,提高了本发明的网络模型的适应能力。

[0057] 本发明的将血压预测通道隐藏层输出 h_3 、时序数据预测通道隐藏层输出 h_4 、用户基本信息线索 h_6 的进行融合,将循环结构与固定信息进行联合。数据联合后依然采用Relu来进行非线性激活得到隐藏层输出 h_5 ,最后,应用线性回归来得到血压的预测值和时序线索的预测值,本发明不光使得血压预测从用户相关信息中提取特征,提供辅助信息,还改进进了提取特征的实现方法,使得模型更加智能化,在特征数量大时,同样有很强处理能力。

[0058] 仿真实验:通过实验结果表明,本发明的Cues-RBF-LSTM模型可以进行长期血压预测,本发明的Cues-RBF-LSTM对三天的血压预测结果分析可知两种方法预测准确度都会随着时间往后而有所下降,整体比较来看,依次预测效果要好于直接预测效果,依据血压预测对准确度的要求,依次预测方式更适合于血压的长期预测。在用本发明的Cues-RBF-LSTM网络进行血压长期预测时,依然首先考虑选用依次预测的方式。但相比于Cues-LSTM等其他网络预测方法,本发明的Cues-RBF-LSTM网络取得了更好的预测结果。说明在进行用户个人基本信息的添加时,RBF效果要比统计学方法效果更好,本发明的Cues-RBF-LSTM模型用于血压长期预测时,效果显著。

[0059] 本发明引入RBF网络对输入的用户信息来进行特征提取,将预测的血压预测值和时序数据预测值能够与用户信息相关联,以适应不同人群特点,且具有更好预测效果,适用于血压长期预测。

[0060] 参考文献:

[0061] [1]、顾景范.《中国居民营养与慢性病状况报告(2015)》解读[J]、.营养学报,2016,38(6):525-529.

[0062] [2]、Sparrow D, Garvey A J, Rosner B, et al. Factors in predicting blood pressure change[J]. Circulation, 1982, 65(4): 789-94.

[0063] [3]、Reckelhoff J F. Gender differences in the regulation of blood pressure[J]. Hypertension, 2001, 37(5): 1199-1208.

- [0064] [4]、Golino H F, Amaral L S, Duarte S F, et al. Predicting increased blood pressure using machine learning[J]. J Obes, 2014, 2014(5): 637635.
- [0065] [5]、Criqui M H, Wallace R B, Mishkel M, et al. Alcohol consumption and blood pressure. The lipid research clinics prevalence study[J]. Hypertension, 1981, 3(5): 557-565.
- [0066] [6]、Hartung G H, Kohl H W, Blair S N, et al. Exercise tolerance and alcohol intake. Blood pressure relation[J]. Hypertension, 1990, 16(5): 501.
- [0067] [7]、李帅. 基于大规模快递数据的时序分析研究与实现[D]. 北京邮电大学, 2018.
- [0068] [8]、Povinelli R J. Time series data mining: identifying temporal patterns for characterization and prediction of time series events[M]. Marquette University, 1999.
- [0069] [9]、王志堂, 蔡淋波. 隐马尔可夫模型(HMM)及其应用[J]. 湖南科技学院学报, 2009, 30(4): 42-44.
- [0070] [10]、Chobanian A V, Bakris G L, Black H R, et al. The Seventh Report of the Joint National Committee on Prevention, Detection, Evaluation, and Treatment of High Blood Pressure: the JNC 7 report[J]. Acc Current Journal Review, 2003, 12(4): 31-32.
- [0071] [11]、Niiranen T J, Havulinna A S, Langén V L, et al. Prediction of Blood Pressure and Blood Pressure Change With a Genetic Risk Score[J]. Journal of Clinical Hypertension, 2016, 18(3): 181-186.
- [0072] [12]、Yoon Y Z, Yoon G W. Nonconstrained Blood Pressure Measurement by Photoplethysmography[J]. Journal of the Optical Society of Korea, 2006, 10(2): 91-95.
- [0073] [13]、Lo F P, Li C X, Wang J, et al. Continuous systolic and diastolic blood pressure estimation utilizing long short-term memory network[J]. Conf Proc IEEE Eng Med Biol Soc, 2017: 1853-1856.
- [0074] [14]、Ghosh S, Banerjee A, Ray N, et al. Continuous blood pressure prediction from pulse transit time using ECG and PPG signals[C]. Healthcare Innovation Point-Of-Care Technologies Conference. IEEE, 2016: 188-191.
- [0075] [15]、Forouzanfar M, Dajani H R, Groza V Z, et al. Feature-Based Neural Network Approach for Oscillometric Blood Pressure Estimation[J]. IEEE Transactions on Instrumentation & Measurement, 2011, 60(8): 2786-2796.
- [0076] [16]、Hsieh Y Y, Wu C D, Lu S S, et al. A linear regression model with dynamic pulse transit time features for noninvasive blood pressure prediction [C]. Biomedical Circuits and Systems Conference. IEEE, 2017: 604-607.
- [0077] [17]、Liang B, Duan K, Xie Q, et al. Live demonstration: A support vector machine based hardware platform for blood pressure prediction[C]. Biomedical Circuits and Systems Conference. IEEE, 2017: 130-130.
- [0078] [18]、贵明俊, 张新峰, 张钊, 刘晓民, 王新宴. 基于SVR的桡动脉血压预测[J]. 北京

生物医学工程,2016,35(3):267-271

[0079] [19]、Sideris C,Kalantarian H,Nemati E,et al.Building Continuous Arterial Blood Pressure Prediction Models Using Recurrent Networks[C].IEEE International Conference on Smart Computing.IEEE Computer Society,2016:1-5.

[0080] [20]、Lee S,Park C H,Chang J H.Improved Gaussian Mixture Regression Based on Pseudo Feature Generation using Bootstrap in Blood Pressure Estimation[J].IEEE Transactions on Industrial Informatics,2015(99):1-1.

[0081] [21]、Sadrawi M,Shieh J S,Fan S Z,et al.Intermittent blood pressure prediction via multiscale entropy and ensemble artificial neural networks[C].Biomedical Engineering and Sciences.IEEE,2017:356-359.

[0082] [22]、Kaur G,Arora A S,Jain V K.Using hybrid models to predict blood pressure reactivity to unsupported back based on anthropometric characteristics[J].Frontiers of Information Technology&Electronic Engineering,2015,16(6):474-485.

[0083] [23]、Lee S,Chang J H.Deep Belief Networks Ensemble for Blood Pressure Estimation[J].IEEE Access,2017,5:9962-9972.

[0084] [24]、Lee S,Chang J H.Deep Boltzmann Regression with Mimic Features for Oscillometric Blood Pressure Estimation[J].IEEE Sensors Journal,2017,PP(99):1-1.

[0085] [25]、Li P,Liu M,Zhang X,et al.Novel wavelet neural network algorithm for continuous and noninvasive dynamic estimation of blood pressure from photoplethysmography[J].Science China Information Sciences,2016,59(4):1-10.

[0086] [26]、Abbasi R,Moradi M H,Molaezadeh S F.Long-term prediction of blood pressure time series using multiple fuzzy functions[C].Biomedical Engineering.IEEE,2015:124-127.

[0087] [27]、Box G E,Jenkins G M.Time series analysis:forecasting and control rev.ed.[J].Journal of Time,1976,31(4):238-242.

[0088] [28]、Wu T H,Pang K H,Kwong W Y.Predicting Systolic Blood Pressure Using Machine Learning[C].International Conference on Information and Automation for Sustainability.IEEE,2015:1-6.

[0089] [29]、Li X,Wu S,Wang L.Blood Pressure Prediction via Recurrent Models with Contextual Layer[C].International Conference on World Wide Web.International World Wide Web Conferences Steering Committee,2017:685-693.

[0090] [30]、Sparrow D,Garvey A J,Rosner B,et al.Factors in predicting blood pressure change[J].Circulation,1982,65(4):789-94.

[0091] [31]、Golino H F,Amaral L S,Duarte S F,et al.Predicting increased blood pressure using machine learning[J].J Obes,2014,2014(5):637635.

[0092] [32]、Cook NR.Use and misuse of the receiver operating characteristic curve in risk prediction[J].Circulation,2007,115(7):928-35.

- [0093] [33]、Lydick E, Epstein RS, Himmelberger D, et al. Area under the curve: a metric for patient subjective responses in episodic diseases. [J]. Quality of Life Research, 1995, 4(1): 41-45.
- [0094] [34]、Gevins A S, Morgan N H. Applications of neural-network (NN) signal processing in brain research [J]. IEEE Transactions on Acoustics Speech & Signal Processing, 1988, 36(7): 1152-1161.
- [0095] [35]、Graves A. Long Short-Term Memory [M]. Supervised Sequence Labelling with Recurrent Neural Networks. Springer Berlin Heidelberg, 2012: 1735-1780.
- [0096] [36]、梁军, 柴玉梅, 原慧斌, 等. 基于极性转移和 LSTM 递归网络的情感分析 [J]. 中文信息学报, 2015, 29(5): 152-160.
- [0097] [37]、Bottou L. Large-Scale Machine Learning with Stochastic Gradient Descent [J]. 2010: 177-186.
- [0098] [38]、Zhang X. Regularization [J]. Encyclopedia of Machine Learning, 2017, 53(6): 845-849.
- [0099] [39]、Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. International Conference on International Conference on Machine Learning. JMLR.org, 2015: 448-456.
- [0100] [40]、Yao Y, Rosasco L, Caponnetto A. On Early Stopping in Gradient Descent Learning [J]. Constructive Approximation, 2007, 26(2): 289-315.
- [0101] [41]、Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [0102] [42]、Feelgood, Steven, Schaefer, Gerard A. Dealing with Missing Data [J]. Research Letters in the Information & Mathematical Sciences, 2002, 3(1): 153-160.
- [0103] [43]、Min-Ling Zhang, Zhi-Hua Zhou. ML-KNN: A lazy learning approach to multi-label learning [J]. Pattern Recognition, 2007, 40(7): 2038-2048.
- [0104] [44]、于亚飞. 基于划分和密度的聚类算法研究 [D]. 安徽大学, 2011.
- [0105] [45]、Aristidis Likas, Nikos Vlassis, Jakob J. Verbeek. The global k-means clustering algorithm [J]. Pattern Recognition, 2003, 36(2): 451-461.
- [0106] [46]、沈洁, 赵雷, 杨季文, 等. 一种基于划分的层次聚类算法 [J]. 计算机工程与应用, 2007, 43(31): 175-177.
- [0107] [47]、Schikuta E. Grid-Clustering: An Efficient Hierarchical Clustering Method for Very Large Data Sets [C]. International Conference on Pattern Recognition. IEEE, 1996: 101-105 vol. 2.
- [0108] [48]、Pratt L, Pratt L, Thrun S. Machine Learning-Special issue on inductive transfer [M]. Kluwer Academic Publishers, 1997.
- [0109] [49]、Caruana R. Multitask Learning [J]. Machine Learning, 1997, 28(1): 41-75.

- [0110] [50]、刘洪洋,李莉,崔天祥,等.血压控制良好的原发性高血压患者夜间收缩压下降率与心率及心率变异性的关系[J].中华高血压杂志,2015(11):1076-1079
- [0111] [51]、Billings S A,Zheng G L.Radial basis function network configuration using genetic algorithms[M].Elsevier Science Ltd.1995.
- [0112] [52]、董学思.多组学缺失数据联合填补方法评价及其应用[D].南京医科大学,2017.
- [0113] [53]、罗高博.健康管理云平台的设计与实现[D].北京交通大学,2017.

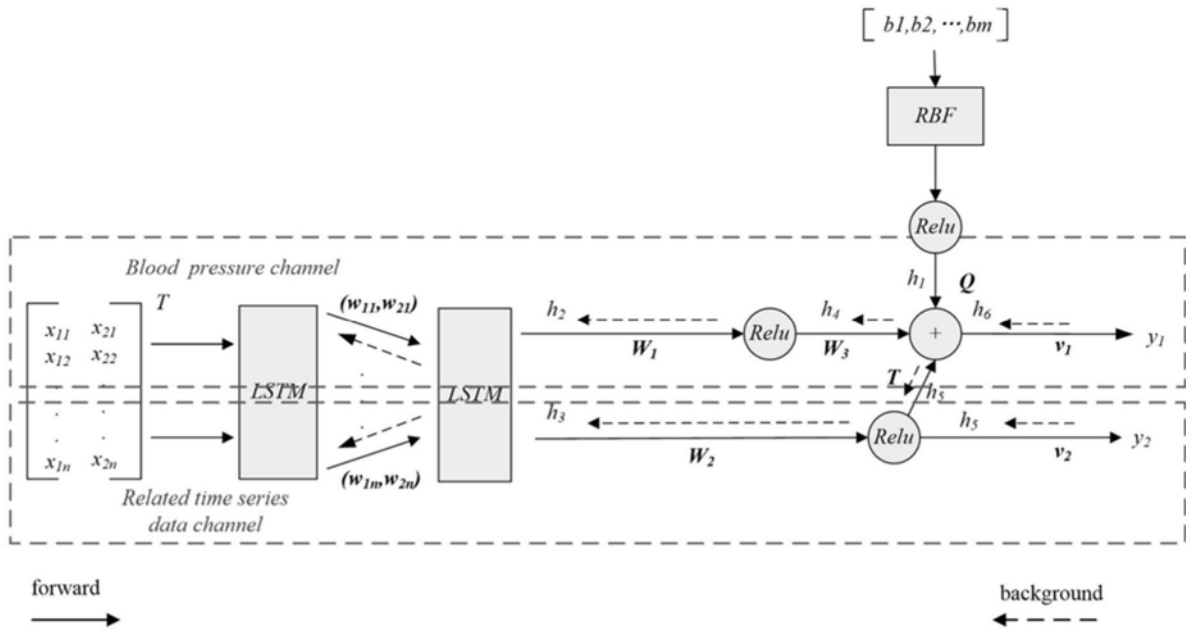


图1

专利名称(译)	基于RBF和LSTM模型的多因素网络的血压预测方法		
公开(公告)号	CN109886347A	公开(公告)日	2019-06-14
申请号	CN201910150825.4	申请日	2019-02-28
[标]申请(专利权)人(译)	泉州师范学院		
申请(专利权)人(译)	泉州师范学院		
当前申请(专利权)人(译)	泉州师范学院		
[标]发明人	刘宁		
发明人	刘宁		
IPC分类号	G06K9/62 G06N3/04 A61B5/021 A61B5/00		
代理人(译)	戴雨君		
外部链接	Espacenet SIPO		

摘要(译)

本发明公开基于RBF和LSTM模型的多因素网络的血压预测方法，其包括以下步骤：步骤1，输入近期血压观测值利用现有的双通道预测的LSTM模型获取血压预测输出h3；步骤2，输入时序测量数据利用现有的双通道预测的LSTM模型获取时序数据预测输出h4；步骤3，采用RBF神经网络对用户基本信息归类且线性求和获取输出h6并作为基本信息线索b，步骤4，将h3、h4、h6数据联合后采用Relu非线性激活得到输出h5，步骤5，应用线性回归分别得到血压的预测值和时序线索的预测值。本发明引入RBF网络对输入的用户信息进行特征提取，将预测血压预测值和时序数据预测值与用户信息相关联，以适应不同人群特点，具有更好预测效果，适用于血压长期预测。

