

文章编号: 2095-2163(2023)12-0149-06

中图分类号: TP391

文献标志码: A

基于机器学习的脉搏信号辅助中医预测血压

谈冰冰, 高国伟

(1 北京信息科技大学 传感器北京市重点实验室, 北京 100101;

2 北京信息科技大学 现代测控技术教育部重点实验室, 北京 100192)

摘要: 高血压是脑血管意外、心血管疾病和肾功能损害相关的主要危险因素之一。其症状和警告信号通常是模糊的, 往往导致疾病被忽视, 被称为“沉默的杀手”。中医脉诊操作明确、方法简单, 通过脉搏信号来预测血压, 使普通大众对自己的身体状况清楚明朗, 早发现早治疗, 同时可以促进中医脉诊客观化和科学化发展。本文基于现代化人工智能科学领域的发展, 通过多种机器学习模型利用脉搏信号预测血压, 以提升中医诊断的准确性, 从而促进中医脉诊的现代化发展。实验表明, 经过对比不同机器学习模型的结果, 模型平均绝对误差可达到 0.087, 验证了基于机器学习的方法可以促进中医脉诊的客观化, 且中医脉诊可以准确的预测人体血压。

关键词: 血压; 中医脉诊; 机器学习; 客观化

Machine learning based pulse signal to assist TCM practitioners in predicting blood pressure

TAN Bingbing, GAO Guowei

(1 Beijing Key Laboratory of Sensors, Beijing Information Science and Technology University, Beijing 100101, China;

2. Key Laboratory of Modern Measurement and Control Technology, Ministry of Education, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: Hypertension is one of the major risk factors associated with cerebrovascular accidents, cardiovascular disease and renal impairment. Its symptoms and warning signs are usually vague, which often leads to the disease being overlooked and is known as the "silent killer". Chinese pulse diagnosis is a clear and simple method to predict blood pressure by pulse signals, which allows the general public to have a clear understanding of their health condition and early detection and treatment, and at the same time promotes the objectification and scientific development of Chinese pulse diagnosis. In this paper, based on the development in the field of modern artificial intelligence science, blood pressure is predicted by using pulse signals through various machine learning models in order to improve the accuracy of TCM diagnosis, thus promoting the modernization of TCM pulse diagnosis. The experiments show that after comparing the results of different machine learning models, the average absolute error of the models can reach 0.087, which verifies that the machine learning-based approach can promote the objectivity of TCM pulse diagnosis and that TCM pulse diagnosis can accurately predict human blood pressure.

Key words: blood pressure; Chinese medicine pulse diagnosis; machine learning; objectification

0 引言

中医理论博大精深, 是中华文化的重要组成部分之一。中医诊断是中医理论现代化的基础, 其科学内涵是中医理论现代化的关键^[1]。国家非常重视中医的发展, 要传承并弘扬中华文化, 不断的发展中医, 使中医行业顺应时代的潮流, 利国利民、造福

大众。随着人工智能的发展, 中医脉诊得到了许多现代化的发展, 机器学习已在医疗行业广泛应用。为实现中医诊断结果的可解释性, 提高中医诊断结果的接受度和认可度, 本文将中医的精髓内化到机器学习模型中去预测人体血压, 从而提高中医疾病诊断的准确性, 关注人类的生命健康。

从中医的观点来看, 个体脉搏信息中的内容, 很

基金项目: 国家自然科学基金(62071054); 国家自然科学基金联合基金重点项目(U20A20167)。

作者简介: 谈冰冰(1994-), 女, 硕士研究生, 主要研究方向: 中医脉诊指压传感器、机器学习。

通讯作者: 高国伟(1963-), 男, 博士, 教授, 研究生导师, 主要研究方向: 检测技术、传感器技术。Email: ggw@bistu.edu.cn

收稿日期: 2022-11-12

多都能直接被解读为单个个体的生理或者病理的信息^[2],其是一个天然的信息源。血压(BP)是诊断受试者健康状况时,需要监测的生命体征之一。全球约16%至37%的人口患有高血压,据悉2010年全球死亡人数中,有18%(约940万人)与高血压有关^[3]。如果能及时注意,就能挽救数百万人的生命。

机器学习是一门多领域交叉学科,是利用计算机技术对数据进行经验学习,通过建立模型或提取特征,提高对新数据的决策判断(Samuel, 1959)^[4]。换言之,就是找一类样本(数据集)中的规律,用一个复杂的公式(模型)表示出来。本文使用的方法是对脉搏信号数据进行预处理(归一化),用线性回归、决策树、人工神经网络及LSTM等模型对血压进行预测,对比不同模型预测的准确性。

1 脉搏波信号及其预处理

1.1 脉搏波的生理机制

脉搏是临床检查和生理研究中常见的生理现象,是指随着心脏的间歇性收缩和舒张,血液压力、血流速度和血流量的脉动,以及血管壁的变形和振动在血管系统中的传播^[5]。一个脉搏波的搏动周期,是由一个上升支和一个下降支共同组成,是规律性搏动;并且动脉中的血液向全身进行传播的同时,血液遇到毛细血管等阻力作用,以及动脉血管的弹性收缩变化返回,而回流的血液遇到主动脉瓣关闭而反射回主动脉,因此主动脉壁得到一个短暂扩张,脉搏波中出现了小的波峰,也就是重搏波的形成^[6]。切迹是心脏收缩期与舒张期的分割点。不同人的脉搏会有所差别。脉搏波的产生示意如图1所示。




图1 脉搏波产生图

Fig. 1 Pulse wave generation diagram

1.2 脉搏信号特征

光电容积脉搏波描记法(Photo Plethysmography, PPG)利用光电传感器检测经过人体血液和组织吸收后的反射光强度的不同,描记出血管容积在心动周期内的变化,从而得到的脉搏波形^[7-8]。通常可采用PPG采集脉搏波信号来分析人体的生

理特征及其相关病理。由于脉搏波特征参数与人体血管外周阻力和血容量存在相关关系^[9-11],因此可通过提取及分析脉搏波信号的特征参数进行血压的预测。

近年来,许多研究者通过提取PPG信号的特征并进行特征选择,筛选出与血压具有高度相关性的特征,用来训练机器学习模型,从而完成血压估计。这种方法依赖于非线性学习模型来提取信息。与以往方法相比,该方法对信号形状的变化更可靠,并且对所有有效信号都合理有效。但是,这种方法需要被提取的特征向量长度相对较大,因此需要更多的训练样本。

1.3 数据预处理


数据归一化(Normalization)是处理数据的一项基础工作^[12],是特征缩放(Feature Scaling)的方法,也是数据预处理的关键步骤。部分模型归一化后,可以提升模型的收敛速度。

由于评估指标的不同,其量纲也不同,可以通过数据归一化对其无量纲化处理,这样就可以进行综合性分析了。归一化还可以解决数值太大引发的数值问题。最常见的归一化方法,就是把数据转换到(0,1)或者(-1,1)区间的数据映射方式,即Min-Max归一化。转换函数如下:


$$x_{\text{new}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

其中, x_{max} 、 x_{min} 分别为样本数据的最大值和最小值。

归一化后的数据波形如图2所示:



(a) PPG数据



(b) BP数据

图2 归一化后的数据波形图

Fig. 2 Normalized PPG plot

2 机器学习建模

2.1 线性回归模型

线性回归模型是机器学习中最基础的模型,而线性回归原理就是寻找变量函数之间的线性关系。若在一个问题中有因变量 y 及其自变量 $x_1, x_2, x_3, \dots, x_n$ 。可以设想 y 的值由两部分构成:一部分是由 $x_1, x_2, x_3, \dots, x_n$ 影响所致,可以表示为 $f(x_1, x_2, x_3, \dots, x_n)$; 另一部分则由其他众多未加考虑的因素,包括随机因素的影响所致,记为 b 。于是得到线性回归公式为

$$y = f(x_1, x_2, x_3, \dots, x_n) + b \quad (2)$$

线性回归模型为

$$y = w_1 x_1 + w_2 x_2 + \dots + w_n x_n + b = [w_0 \ w_1 \ w_2 \ \dots \ w_n] \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix} + b \quad (3)$$

统一形式为

$$y = \sum_{i=1}^n w_i x_i + b = w^T x + b \quad (4)$$

其中, y 是预测函数; w 是模型参数; x 是特征输入; b 是偏置项。

2.2 决策树模型

决策树是一种既可以被用于回归也可以被用于分类的监督学习算法,其对于非线性关系的建模具有非常强大的能力,使模型更具解释性。其策略是自顶向下的节点分裂方式,每分裂一次查看代价函数最小者,在当前分裂的情况下取代价函数最小的作为节点。决策树采用贪心算法,来递归地分裂节点,所以需要停止策略。其中,最常见的停止策略有:指定单个节点下最小的样本数、当树达到了某一深度就停止训练,以及当所有叶子节点不再发生变化时停止等。

回归树算法流程:

输入 训练数据集 D

输出 回归树 $f(x)$

在训练数据集所在的输入空间中,递归地将每个区域划分为两个子区域,并决定每个子区域上的输出值,构建二叉决策树^[13]。

(1) 选择最优切分变量 j 与切分点 s , 求解

$$\min_{j,s} [\min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2] \quad (5)$$

遍历变量 j , 对固定的切分变量 j 扫描切分点 s ,

选择使上式达到最小值的对 (j, s) 。

(2) 对 (j, s) 进行划分, 决定相应的输出值:

$$R_1(j, s) = \{x \mid x^{(j)} \leq s\} \quad (6)$$

$$R_2(j, s) = \{x \mid x^{(j)} > s\} \quad (7)$$

$$\hat{c}_m = \frac{1}{N_{m \times i \in R_m(j,s)}} \sum y_i, x_i \in R_m, m = 1, 2 \quad (8)$$

(3) 对步骤(2)中划分的两个子区域重复执行步骤(1)、(2)的操作,直到满足停止条件时为止。

(4) 将输入空间划分为 M 个区域 R_1, R_2, \dots, R_m , 生成决策树:

$$f(x) = \sum_{m=1}^M \hat{c}_m I, x \in R_m \quad (9)$$

2.3 神经网络模型

神经网络是机器学习中的一种模型,网络依靠系统的复杂程度,通过调整内部大量节点之间相互连接的关系,从而达到处理信息的目的^[14]。生物神经网络使大脑能够以复杂的方式处理大量信息,神经元是大脑的基本处理单元,神经元之间通过突触的连接便可形成一个网络,这就是生物神经网络^[15]。人工神经网络(Artificial Neural Networks, ANN)是对人脑或自然神经网络若干基本特性的抽象和模拟,是在生物神经网络基础上被提出的。

人工神经网络基本结构如图 3 所示,包括输入层、隐藏层与输出层^[16]。其中,输入层只从外部环境接收信息,然后把信息传递到下一层,隐藏层负责计算并分析数据,连接输入层与输出层,让数据更适配,输出层生成最终结果^[17]。每个输出单元对应某一种特定的分类,将结果值传送给外部系统。




图 3 人工神经网络基本结构

Fig. 3 Basic structure of Artificial Neural Network

图中, x_i 为输入层接收特征向量; $h_\theta(x)$ 为产出最终的预测; a_i 为隐含层。

本文旨在实现脉搏传感信号预测血压,外部输入的人工神经网络构造的第一层为输入层,第二层隐含层包含 1 024 个神经元,第三层包含 521 个神经元,第四层为输出层;第二层与第三层采用了 Relu 激活函数,第一层采用了 Sigmoid 激活函数;前三层均采用 Dropout 正则化技术,输入训练数据对人工神经网络进行训练。在训练过程中,随机地忽

略一些神经元,通过非线性回归方法预测血压。本文共定义了2 048个节点,使用Sigmoid激活函数的神经层。定义第一层时,需要制定数据输入的形状,后面的其他层会自动计算前一层输出的形状。

ANN模型训练过程如图4所示。

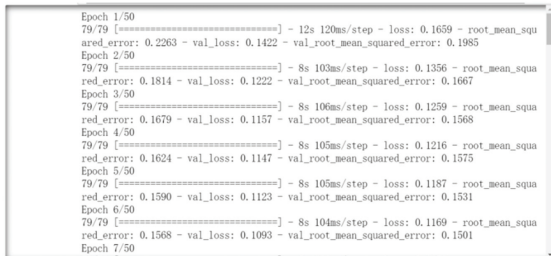


图4 ANN模型训练过程

Fig. 4 The training process of ANN model

2.4 LSTM模型

长短期记忆(Long Short Term Memory, LSTM)是一种特殊的递归神经网络,通过门限机制留下输入数据的有用信息,解决了信息冗余问题。在流经神经元时,允许信息被选择性的保留或遗弃,从而增强了原始信息的权重,并削弱了不相关信息的权重。

LSTM神经网络结构如图5所示。

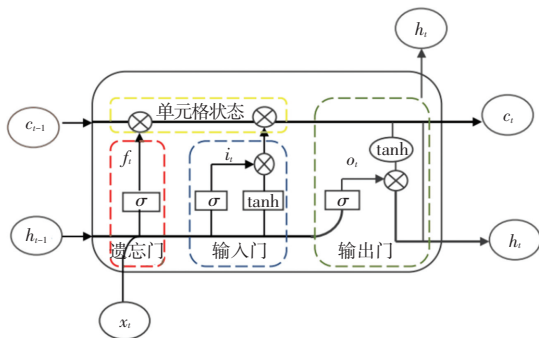


图5 LSTM神经网络结构图

Fig. 5 LSTM neural network structure diagram

各单元工作的描述公式如下:

(1)判定为无用或不相关的历史信息将被遗忘门抛弃,遗忘门公式为

$$f_t = \sigma(W_f * |h_{t-1}, x_t| + b_f) \quad (10)$$

(2)将上一时刻保留的信息与此时刻的输入信息共同作为输入门的更新状态,公式为:

$$i_t = \sigma(W_i * |h_{t-1}, x_t| + b_i) \quad (11)$$

$$\tilde{C}_t = \tanh(W_c * |h_{t-1}, x_t| + b_f) \quad (12)$$

(3)由输出门输出当前时刻的状态信息,公式为:

$$o_t = \sigma(W_o * |h_{t-1}, x_t| + b_o) \quad (13)$$

$$h_t = o_t * \tanh(C_t) \quad (14)$$

(4)单元格状态公式

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (15)$$

式中: W_i 、 W_c 、 W_f 和 W_o 为相应的连接权值, b_i 、 b_f 与 b_o 为相应的偏置, f_t 对应 t 时刻遗忘门的激活值, σ 为 Sigmoid 函数, C_t 对应 t 时刻的细胞状态更新值, h_t 对应当前神经元的输出值。

LSTM模型部分训练过程如图6所示。

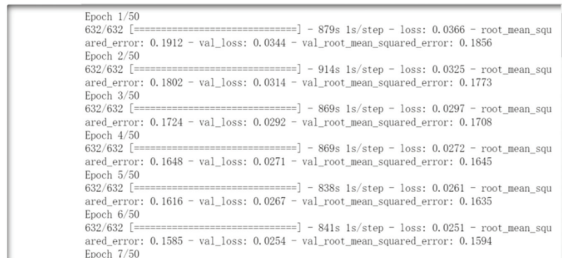


图6 LSTM模型部分训练过程

Fig. 6 Partial training process of LSTM model

3 实验结果与分析

对于机器学习理论来说,模型的优劣是相对的,使用不同的评估指标其结果会有所不同。可以明确的是,好的模型预测误差会更小,结果会更精确。对于回归模型来说,可以用均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)来评价。

(1) RMSE

RMSE是预测值和真实值偏差的平方与观测次数 n 比值的平方根。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (16)$$

其中, \hat{y} 为预测值, y_i 为真实值。

(2) MAE

MAE表示预测值和观测值之间绝对误差的平均值,公式为

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (17)$$

其中, \hat{y} 为预测值, y_i 为真实值。

(3) MAPE

理论上,MAPE的值越小,说明预测模型拟合效果越好,具有更好的精确度,公式为

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (18)$$

其中, \hat{y} 为预测值, y_i 为真实值。


模型对比评估结果见表1。

表 1 评估指标
Table 1 Evaluation metric


评估指标	ANN 模型	LSTM 模型	线性回归模型	决策树模型
MAE	0.087	0.114	0.917	16.411
RMSE	0.121	0.153	0.124	22.001
MAPE	0.089	0.116	0.919	16.556

由表 1 可知,ANN 模型的性能最好,其均方根误差和平均绝对误差都是最小的。

ANN 与 LSTM 模型训练过程中 Loss 和 RMSE 变化如图 7。



(a) ANN 模型



(b) LSTM 模型

图 7 模型训练的损失和均方根误差对比


Fig. 7 Comparison of loss and root mean square error of ANN model training

通过对比两种神经网络在训练过程中损失函数和均方根误差的变化可知,ANN 模型的 Loss 和 RMSE 不仅在逐渐减小,而且其曲线趋于水平,其值也在向 0 无限接近;而 LSTM 模型的 Loss 和 RMSE 刚开始也在逐渐下降,但在第 18 次迭代后,曲线开始不断波动,其值接近于 0,并在 0 附近波动。


线性回归模型、决策树模型、ANN 模型与 LSTM 模型下,BP 预测值和 BP 真实值的对比如图 8 所示。

决策树以树结构的形式构建模型,树结构由许多决策节点组成,每个决策节点根据训练的条件选择一个分支。但在某些问题中,其可能会创建过度复杂的结构,这些结构不能很好地泛化,因此表现出较差的性能。线性回归模型简单,易于训练,不易过度拟合,并且与其他替代方案相比,需要较少的训练样本,因此效率更高。由各模型 BP 真实值与预测值对比结果可知,神经网络模型的拟合效果更好。


其中,决策树模型的拟合程度最差,ANN 模型的拟合程度最好。




(a) 线性回归模型



(b) 决策树模型



(c) ANN 模型



(d) LSTM 模型

图 8 BP 预测值和 BP 真实值的对比

Fig. 8 Comparison of BP predicted values and BP true values

4 结束语

在中医研究中,判断人体机能的一个重要指标就是脉象。有经验的中医可以通过脉象判断出病症的紧迫性、位置和相应的特征。作为机器学习分析方法,其可以在没有中医专家的参与下,进行脉象信号分析,得出相应的结论,再进行进一步优化研究,实现中医诊断结果的可解释性,提高中医诊断结果的接受度和认可度。(下转第 157 页)