

基于支持向量回归模型的血压预测方法

吴晓姣, 吴礼发

(南京邮电大学 计算机学院, 江苏 南京 210023)

摘要: 血压实时检测对于及时了解人体的心血管系统状态具有重要意义。传统的侵入式和袖带法的血压测量方式是以间歇式为主, 不能满足血压实时检测的需求。针对目前血压检测方式的不规范以及血压预测方法的准确度低下等问题, 提出了一种仅使用光电容积脉搏波的基于支持向量回归模型的血压预测方法。该方法仅使用人的光电容积脉搏波生理信号, 对该信号消除噪声污染和周期划分之后, 再对原始的光电容积脉搏波信号以及其一阶导数和二阶导数提取相关特征, 并使用支持向量回归算法构建预测血压的模型。基于 MIMIC III 数据库的数据进行实验, 结果表明该模型能有效预测人的血压值, 在均值误差和均方根误差方面的表现优于现有的方法, 同时血压预测值大多数都在 96% 的一致性范围内。

关键词: 血压预测; 支持向量回归算法; 信号处理; 传感器; 光电容积脉搏波

中图分类号: TP181

文献标识码: A

文章编号: 1673-629X(2021)12-0161-06

doi: 10.3969/j.issn.1673-629X.2021.12.027

A Blood Pressure Prediction Method Based on Support Vector Regression Model

WU Xiao-jiao, WU Li-fa

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Real-time detection of blood pressure is of great significance for timely understanding the state of the human cardiovascular system. The traditional invasive and cuff blood pressure measurement methods are mainly intermittent, which cannot meet the demand of real-time blood pressure measurement. In order to solve the problems of irregular blood pressure detection methods and low accuracy of blood pressure prediction methods, a new blood pressure prediction method based on support vector regression model using only photoplethysmography is proposed. In this method, only human photoplethysmography physiological signal is used. After eliminating noise pollution and period division of the signal, relevant features are extracted from the original photoplethysmography signal as well as its first and second derivatives, and the support vector regression algorithm is used to build a model for predicting blood pressure. Experiments based on data from the MIMIC III database show that the model can effectively predict human blood pressure, and it performs better than existing methods in terms of mean error and root mean square error. Meanwhile, the predictive values for blood pressure were mostly within the 96 percent consistent range.

Key words: blood pressure prediction; support vector regression algorithm; signal processing; sensor; photoplethysmography

0 引言

高血压一直是一种较为普遍的疾病, 它意味着一个人有更高的健康风险问题^[1]。因为患有高血压的患者通常是没有显著的症状和信息, 所以大多数人不能够及时意识到自己已患病。因此, 它又被人们称为“沉默杀手”。总而言之, 血压问题在日常生活中是不可忽视的, 即血压的实时检测是必不可少的。血压是指从心脏向全身输送血液时对动脉壁的压力, 这些动脉在心脏收缩时扩张, 在心脏扩张时收缩, 则血压被分为收缩压 (systolic blood pressure, SBP) 和舒张压

(diastolic blood pressure, DBP)。

伴随着科技技术迅猛发展的趋势, 传感器设备在医疗领域中的应用受到了广泛关注^[2], 并且使用其检测人体的生理参数也越来越得到大家的认可, 其中生理参数包括心率、脉搏、血压等^[3]。与此同时, 使用传感器检测到的人的生理信号进行预测血压的研究也随之兴起^[4]。

目前, 针对预测血压的相关研究有很多^[5]。Teng 等人^[6]首先获取人的光电容积脉搏波生理信号 (photoplethysmography, PPG) 并分析其某些特征与动脉血

收稿日期: 2020-12-31

修回日期: 2021-05-06

基金项目: 国家自然科学基金面上项目 (61571238)

作者简介: 吴晓姣 (1995-), 女, 硕士研究生, 研究方向为机器学习、边缘计算等; 吴礼发, 教授, 博导, 研究方向为网络安全、软件安全。

压 (ABP) 之间的关系, 然后采用线性回归算法 (LR) 构建预测血压的模型, 实验结果表明通过人的生理信号预测血压这一方法是可行的。Zhang 等人^[7] 从 32 个人中获取 7 000 个生理信号的实例, 并使用支持向量机算法构建预测血压的模型。实验在均值误差 (MAE) 方面的值分别为 11.64 和 7.62, 结果表明该模型的预测精度较低。Kachuee 等人^[8] 则从 MIMIC II 数据库中提取 1 000 个人的心电图 (ECG) 和 PPG 信号, 然后从这两个信号中提取实验所需特征, 并使用机器学习算法构建预测血压的模型。实验预测 SBP 和 DBP 的 MAE 分别为 11.17 和 5.35, 实验结果表明增加了 ECG 信号之后预测精度有一点提高, 但是该模型预测 SBP 的精度仍然较低。Su 等人^[9] 从 ECG 和 PPG 信号提取实验所需特征, 然后使用长短期记忆网络 LSTM 构建预测血压的模型。实验在均方根误差 (RMSE) 方面的值分别为 3.73 和 2.43, 结果表明该模型的预测精度良好。但是, 该模型需要同时从 ECG 和 PPG 两个信号中提取特征, 即实验需要对这两个信号进行同步性处理操作, 则在信号处理之前就需要付出很多的努力, 从而增加实验的任务量。Zadi 等人^[10] 是从 15 个人中获取 PPG 信号, 然后使用 ARMA 模型构建预测血压的模型。实验预测 SBP 和 DBP 的 RMSE 分别为 6.49 和 4.33, 实验结果表明该模型的预测精度良好, 即仅使用 PPG 信号预测血压是可行的。Kurylyak 等人^[11] 首先通过 MIMIC II 数据库的一部分数据来提取 PPG 信号的波形特征, 然后研究分析这些特征与 ABP 之间的关系, 最后使用人工神经网络 (ANN) 构建预测血压的模型。实验预测的 SBP 和

DBP 的 MAE 分别为 3.80 和 2.21, 实验结果表明该模型预测血压的精度较好。但是, 该实验只从原始的 PPG 信号中提取相关特征。Yang 等人^[12] 对原始的 PPG 信号、PPG 信号的二阶导数提取相应的特征, 然后使用 SVR 构建预测血压的模型。实验预测的 SBP 和 DBP 的 MAE 分别为 13.40 和 6.90, RMSE 分别为 8.54 和 4.34。Slapnicar 等人^[13] 首先从 MIMIC III 数据库中获取了 510 个人的 PPG 信号, 然后从原始的 PPG 信号、PPG 信号的一阶导数、PPG 信号的二阶导数中提取相关特征, 最后使用深度学习算法构建预测血压的模型。实验预测的 SBP 和 DBP 的 RMSE 值分别为 9.43 和 6.88, 实验结果表明该模型预测血压的精度一般, 但是实验对于 PPG 信号提取特征较为全面。

针对上述预测血压研究存在的问题, 该文提出一种基于支持向量回归模型 (SVR) 的血压预测方法。该方法仅考虑人的 PPG 信号, 通过对 PPG 信号的处理分析并提取相关特征, 然后再使用 SVR 构建预测血压的模型。

1 基于 SVR 的血压预测方法

1.1 问题定义

通过传感器设备获取某人在一段时间内的生理信号数据, 预测血压的一般过程为: 首先获取某人一段时间内的 PPG 和 ABP 信号, 然后对 PPG 信号进行处理并提取特征 X_t , 同时对 ABP 信号处理获取 SBP 和 DBP 值, 即标签 Y , 最后结合特征 X_t 和标签 Y 分别构建预测 SBP 和 DBP 值的模型, 如图 1 所示。

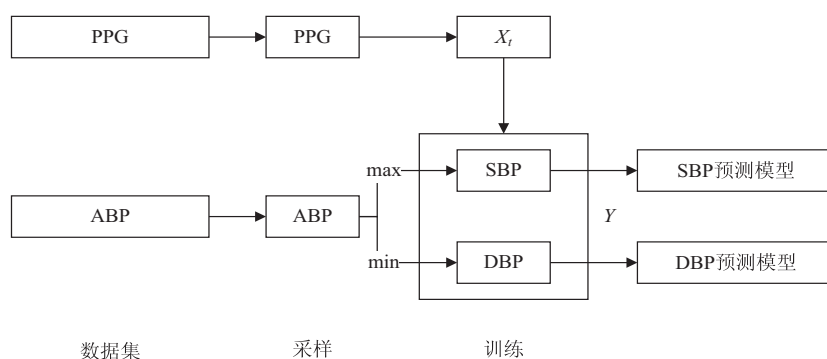


图1 血压预测的一般过程

1.2 SVR 回归原理

支持向量机 (SVM) 是一种在分类与回归分析中对数据进行处理和监督式机器学习模型, 包括线性 SVM 和非线性 SVM^[14]。当数据是线性时, 线性 SVM 可以通过寻找超平面来对数据样本进行处理操作^[15]。然而, 当数据是非线性时, 线性 SVM 则不适用, 此时非线性 SVM 将会被使用。非线性 SVM 主要是通过核函数将低维空间中的非线性问题转换为高维空间中

的线性问题, 从而再使用解决线性问题的方式来解决非线性问题。根据 PPG 和 ABP 信号之间的关系实现血压的预测, 以及 PPG 信号属于人的生理信号是非线性数据, 因此该文采用非线性 SVM, 即支持向量回归算法 (SVR) 来构建预测 SBP 和 DBP 值的模型。

给定某人一段时间内的 PPG 信号和 SBP (或 DBP) 值组成的训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 其中 x_i 表示 PPG 信号, y_i 表示对应的 SBP

(或 DBP) 值, $i = 1, 2, \dots, N$, 则预测血压的 SVR 模型的公式为:

$$f(x) = w^T x + b \quad (1)$$

SVR 采用 ε -不敏感损失 (ε -insensitive loss) 函数, 该损失函数的公式为:

$$l_\varepsilon(z) = \begin{cases} 0, & |z| \leq \varepsilon \\ |z| - \varepsilon, & |z| > \varepsilon \end{cases} \quad (2)$$

因此, 预测血压的 SVR 模型可形式化为:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N l_\varepsilon(f(x_i) - y_i) = \min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N l_\varepsilon(f(x_i) - y_i) \quad (3)$$

其中, z 是模型输出 $f(x)$ 与真实值 y 之间的差值, C 是惩罚因子。同时, 通过引入松弛变量 ξ_i 和 ζ_i , 式(3)可重写为:

$$\min_{w,b,\xi,\zeta} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \zeta_i) \quad (4)$$

$$\text{s. t. } \begin{cases} f(x_i) - y_i = (w^T x_i + b) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \zeta_i \\ \xi_i \geq 0, \zeta_i \geq 0, i = 1, 2, \dots, N \end{cases}$$

引入拉格朗日乘子 α 、 β 、 γ 、 σ 可以将最优化问题转化为对偶问题, 由拉格朗日乘子法得到拉格朗日函数为:

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \zeta_i) - \sum_{i=1}^N \alpha_i \xi_i - \sum_{i=1}^N \beta_i \zeta_i + \sum_{i=1}^N \gamma_i (f(x_i) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^N \sigma_i (y_i - f(x_i) - \varepsilon - \zeta_i) \quad (5)$$

将式(1)代入上式中, 再使用 L 分别对 w 、 b 、 ξ 、 ζ 求偏导, 同时将每个偏导数置为 0, 计算得到:

$$w = \sum_{i=1}^N \sigma_i x_i - \sum_{i=1}^N \gamma_i x_i = \sum_{i=1}^N (\sigma_i - \gamma_i) x_i \quad (6)$$

$$\sum_{i=1}^N \sigma_i - \sum_{i=1}^N \gamma_i = \sum_{i=1}^N (\sigma_i - \gamma_i) = 0 \quad (7)$$

$$C = \gamma_i + \alpha_i \quad (8)$$

$$C = \sigma_i + \beta_i \quad (9)$$

再将式(6)到式(9)代入式(5)中就实现了将最优化问题转化为对偶问题。此时, SVR 模型的对偶问题为:

$$\min_{\gamma,\sigma} \sum_{i=1}^N y_i (\sigma_i - \gamma_i) - \varepsilon (\sigma_i + \gamma_i) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\sigma_i - \gamma_i) (\sigma_j - \gamma_j) x_i^T x_j \quad (10)$$

$$\text{s. t. } \begin{cases} \sum_{i=1}^N (\sigma_i - \gamma_i) = 0 \\ 0 \leq \gamma_i, \sigma_i \leq C \end{cases}$$

将核函数 $\kappa(x_i, x_j)$ 代入上式中, SVR 模型的对偶问题变为:

$$\max_{\gamma,\sigma} \sum_{i=1}^N y_i (\sigma_i - \gamma_i) - \varepsilon (\sigma_i + \gamma_i) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\sigma_i - \gamma_i) (\sigma_j - \gamma_j) \kappa(x_i, x_j) \quad (11)$$

同时令上式的值为 0, 则可以得到 SVR 模型的回归方程为:

$$f(x) = \sum_{i=1}^N (\sigma_i - \gamma_i) \kappa(x, x_i) + b \quad (12)$$

其中 b 为:

$$b = y_i + \varepsilon - \sum_{i=1}^N (\sigma_i - \gamma_i) x_i^T x_j \quad (13)$$

$\kappa(x_i, x_j)$ 为:

$$\kappa(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (14)$$

实验中使用的核函数是高斯核函数 (RBF), 它的公式为:

$$\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (15)$$

其中, $\sigma > 0$ 表示高斯核的带宽, x_i 、 x_j 表示特征向量。

1.3 血压预测方法

基于上述讨论, 该文提出一种基于 SVR 的血压预测方法, 如图 2 所示。

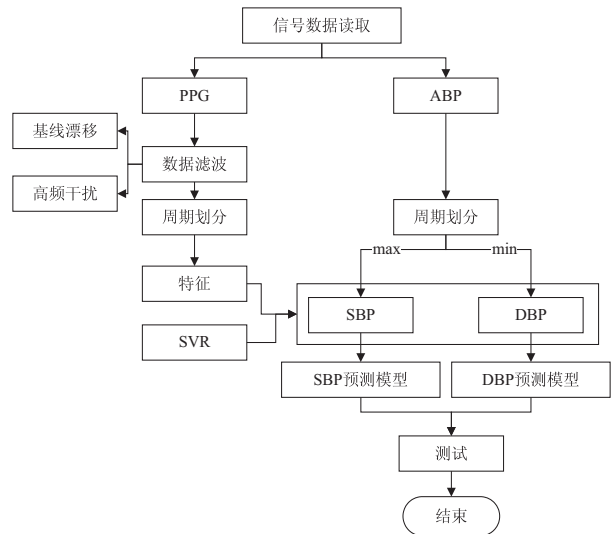


图 2 基于 SVR 的血压预测流程

该方法的操作步骤如下:

(1) 信号数据读取。读取某人一段时间内的 PPG 和 ABP 信号;

(2) PPG 信号的数据过滤。通过数据过滤来消除 PPG 信号的噪声污染;

(3) 信号的周期划分。ABP 和 PPG 信号属于周期性数据, 则需要对两个信号进行周期划分;

(4) PPG 信号的特征。对已消除噪声污染的单个周期的原始的 PPG 信号、PPG 信号的一阶导数、PPG 信号的二阶导数提取相关特征;

(5) 获取 SBP 和 DBP 值。从单个周期的 ABP 信号中获取对应的 SBP 和 DBP 值;

(6)训练模型。将已提取的 PPG 信号的特征结合 SBP(或 DBP)值,然后使用 SVR 构建预测 SBP(或 DBP)值的模型;

(7)测试模型。对于预测 SBP 和 DBP 值的两个模型进行准确率测试。

下面介绍图 2 中 PPG 信号的数据滤波处理。由于 PPG 信号是通过传感器设备获取,则在测量的过程中该信号容易受到外界的因素干扰而造成噪声污染^[16]。主要影响测量 PPG 信号的因素有:(1)环境光的影响;(2)工频以及其他电磁的影响;(3)运动影响。这些都是测量 PPG 信号过程中会出现的问题,因此在使用 PPG 信号构建预测血压的模型之前需要对该信号进行数据滤波以消除噪声污染。Chowdhur 等人^[17]使用 25 Hz 的六阶巴特沃斯无限脉冲响应零相位滤波器消除 PPG 信号的噪声污染。师荣堃等人^[18]则是先使用 0.7 Hz~4 Hz 带通滤波器对 PPG 信号进行初步滤波,然后再使用优化的全零直线型形态学滤波器消除该信号的基线漂移,最后再使用 4 Hz 的 FIR 低通滤波器消除前面操作带来的高频噪声。

巴特沃斯滤波器主要是由 butter 和 filtfilt 两个函数组成,其 Python 代码为:

```
b, a = scipy.signal.butter(N, Wn, btype, analog,
output, fs)
data_filter = scipy.signal.filtfilt(b, a, x, axis, padtype,
padlen, method, irlen)
```

其中,实验需要设置的重要参数为:

(1) N 表示实验中采用的巴特沃斯滤波器阶数;

(2) W_n 表示截止频率的归一化, $0 < W_n < 1$ 。注意:截止频率过大会造成过拟合,截止频率过小又会使该信号被过滤的过于光滑,因此实验需要采取合适的截止频率, W_n 的计算公式为:

$$W_n = 2 * \text{cutoff} / \text{sample} \quad (16)$$

其中, cutoff 表示巴特沃斯滤波器的截止频率, sample 表示信号的采样频率。

(3) btype 表示滤波的类型,分为高通 (highpass)、低通 (lowpass)、带通 (bandpass) 和带阻 (bandstop);

(4) b, a 表示巴特沃斯滤波器的分子和分母的多项式,同时也是 filtfilt 函数的重要参数;

(5) x 表示要过滤的信号数据,要求以数组的形式。

针对消除 PPG 信号噪声污染的处理问题,该文提出一种仅使用巴特沃斯滤波器对 PPG 信号消除噪声污染的方法。该方法将消除 PPG 信号噪声污染分为消除信号的基线漂移和高频干扰两个步骤,其中对于消除基线漂移使用巴特沃斯低通滤波器,对于消除高

频干扰使用巴特沃斯高频滤波器。

2 实验结果与分析

2.1 数据库介绍

MIMIC III 数据库(<https://mimic.mit.edu/about/mimic/>),其全称为 Medical Information Mart for Intensive Care III(重症监护医学信息集市 III),是由 MIT 麻省理工学院下属管理的一个公共临床数据库。它包含 2001 年至 2012 年在贝斯以色列女执事医疗中心(Beth Israel Deaconess Medical Center)重症监护病房住院的 4 万多名病人的生理信息数据,例如床旁生命体征(每小时记录 1 次)、检查结果、手术、用药、监护记录、影像报告和死亡情况(包括院内和院外)等等。由于它是从传感器中直接读取的生理信号数据,因此在实验过程中不方便查看和操作,则对于下载的信号数据需要通过 WFDB 工具箱^[19-20]进行相应的处理操作。

2.2 评价指标

2.2.1 均值误差和均方根误差

均值误差(MAE)是指观测值和预测值的误差绝对值和占总样本数的平均值,因此 MAE 可被用来评估观测值和预测值之间的平均误差,并且 MAE 越小表示该模型的性能越好。MAE 的公式为:

$$\text{MAE} = \frac{\sum_{i=1}^N |y_i - y_{\text{pred},i}|}{N} \quad (17)$$

其中, N 表示血压样本的数量, y_i 表示血压的观测值(SBP 或 DBP), $y_{\text{pred},i}$ 表示血压的预测值(SBP 或 DBP)。

均方根误差(RMSE)是观测值与预测值的误差平方和比上总样本数再取平方根,因此 RMSE 可被用来评估观测值与预测值之间误差的波动性,并且 RMSE 值越小表示该模型的性能越好。RMSE 的公式为:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (y_i - y_{\text{pred},i})^2}{N}} \quad (18)$$

其中, N 表示血压样本的数量, y_i 表示血压的观测值(SBP 或 DBP), $y_{\text{pred},i}$ 表示血压的预测值(SBP 或 DBP)。

2.2.2 Bland-Altman 图

Bland-Altman 图是通过计算出两种测量结果的一致性界限的一种性能评估方法,同时可以使用图形直观展示这个一致性界限。因此,实验中可以采用 Bland-Altman 图可视化预测值和观测值的一致性状况。

2.3 结果与分析

实验选择数据集的 80% 作为训练集,20% 作为测

试集,以及使用网格搜索方法寻找 SVR 模型的最优超参数组合。表 1 给出了文中预测血压的方法与其他相

关文献的方法在 MAE 和 RMSE 值上的比较结果。从表 1 中可以看出:

表 1 文中方法与其他相关文献的方法的比较结果

算法	SBP(mmHg)		DBP(mmHg)	
	MAE	RMSE	MAE	RMSE
ANN ^[11]	3.80		2.21	
SVR ^[12]	13.40	8.54	6.90	4.34
GPR ^[17]	3.02	6.74	1.74	3.59
SVR	3.24	4.12	1.96	2.50

(1)文中 SVR 模型的 MAE 小于文献 [11] 的 ANN 模型的 MAE。由于在文献 [11] 中,实验只提取了原始的 PPG 信号的波形特征。而文中 SVR 模型除了对于原始的 PPG 信号提取特征外,还对于 PPG 信号的一阶导数和二阶导数提取了相应的特征。因此 SVR 模型对于 PPG 信号提取特征较全面一些,则该模型在预测血压的性能上较优于 ANN 模型。

从两图中可以看出,文中的血压预测模型 SVR 对于 SBP 和 DBP 的预测值绝大多数都落在 96% 的一致性范围内,即 $[\bar{d} - 1.96SD, \bar{d} + 1.96SD]$ 。实验结果表明 SVR 模型的预测值和观测值之间具有较好的一致性,对血压预测具有一定的可行性。

(2)文中 SVR 模型的 MAE 和 RMSE 均小于文献 [12] 的 SVR 模型的 MAE 和 RMSE。在文献 [12] 中,实验只是对原始的 PPG 信号以及其二阶导数提取特征,然后使用 SVR 构建预测血压的模型。而文中还对该信号的一阶导数也提取了特征,因此该模型在性能上较优于文献 [12] 中的 SVR 模型。




图 4 DBP 的 Bland-Altman 图

(3)文献 [17] 中 GPR 模型的 MAE 比文中 SVR 模型的 MAE 小一点,其 RMSE 值则大得多。在文献 [17] 中,实验是采用 25 Hz 的六阶巴特沃斯无限脉冲响应零相位滤波器消除 PPG 信号的噪声污染。而文中将消除 PPG 信号噪声污染分为消除基线漂移和高频干扰两个步骤,首先使用巴特沃斯低通滤波器消除该信号的基线漂移,然后使用巴特沃斯高通滤波器消除该信号的高频干扰。后面消除高频干扰的操作不仅消除 PPG 信号本身的高频噪声,而且还消除由于前面操作带来的高频噪声,比文献 [17] 中消除 PPG 信号噪声污染的操作较彻底一点。因此文中 SVR 模型在性能上较优于 GPR 模型。

综上所述,从与其他相关文献的 MAE 或 RMSE 值的对比以及 Bland-Altman 图可知,文中 SVR 模型具有一定的可行性,同时能够有效地预测出人的血压的 SBP 和 DBP 值。因此,该模型能帮助人们及时了解自身的血压情况,一旦血压出现异常情况能够尽早知晓。

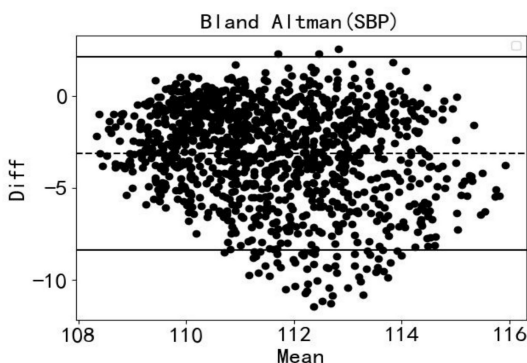


图 3 SBP 的 Bland-Altman 图

SBP 和 DBP 的 Bland-Altman 图见图 3 和图 4。

3 结束语

针对血压预测问题,该文提出了一种基于 SVR 的血压预测方法,并使用 MIMIC III 数据库中的 PPG 和 ABP 信号数据实验验证了该方法的有效性。实验结果表明,基于 SVR 的血压预测方法的 MAE 和 RMSE 较小于其他相关文献的方法的 MAE 和 RMSE,预测效果较好。但是,由于数据库数据的局限性和设备有限等因素,该文没有综合考虑个人的体征信息(如年龄、性别等),未来将考虑这一方面信息并构建更加精确的血压预测模型。

参考文献:

[1] 赵运昇. 高血压病的危害及预防和治疗[J]. 光明中医, 2017,32(5):728-729.

- [2] 王 敏. 可穿戴式光电容积脉搏波传感器的研究[D]. 上海:上海交通大学,2018.
- [3] CHOWDHURY M E H, ALZOUBI K, KHANDAKAR A, et al. Wearable real-time heart attack detection and warning system to reduce road accidents[J]. *Sensors*, 2019, 19(12): 2780–2785.
- [4] RUNDO F, ORTIS A, BATTIATO S, et al. Advanced bio-inspired system for noninvasive cuff-less blood pressure estimation from physiological signal analysis[J]. *Computation*, 2018, 6(3): 46–48.
- [5] 宋晓洋, 刘立勋. 基于 SVM 回归的连续血压测量方法[J]. *吉林大学学报:信息科学版*, 2016, 34(3): 384–389.
- [6] TENG X F, ZHANG Y T. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach[C]//Proceedings of the 25th annual international conference of the IEEE engineering in medicine and biology society (IEEE Cat. No. 03CH37439). Cancun, Mexico; IEEE, 2003: 3153–3156.
- [7] ZHANG Y, FENG Z. A SVM method for continuous blood pressure estimation from a PPG signal[C]//Proceedings of the 9th international conference on machine learning and computing. New York, NY, United States: Association for Computing Machinery, 2017: 128–132.
- [8] KACHUEE M, KIANI M M, MOHAMMADZADE H, et al. Cuffless blood pressure estimation algorithms for continuous health-care monitoring[J]. *IEEE Transactions on Biomedical Engineering*, 2017, 64(4): 859–869.
- [9] SU P, DING X R, ZHANG Y T, et al. Long-term blood pressure prediction with deep recurrent neural networks[C]//2018 IEEE EMBS international conference on biomedical & health informatics (BHI). Las Vegas, NV, USA: IEEE, 2018: 323–328.
- [10] ZADI A S, ALEX R, ZHANG R, et al. Arterial blood pressure feature estimation using photoplethysmography[J]. *Computers in Biology and Medicine*, 2018, 102: 104–111.
- [11] KURYLYAK Y, LAMONACA F, GRIMALDI D. A neural network-based method for continuous blood pressure estimation from a PPG signal[C]//2013 IEEE international instrumentation and measurement technology conference (I2MTC). Minneapolis, MN, USA: IEEE, 2013: 280–283.
- [12] YANG S, ZHANG Y, CHO S Y, et al. Cuff-less blood pressure measurement using fingertip photoplethysmogram signals and physiological characteristics[C]//Optics in health care and biomedical optics VIII. Beijing, China: International Society for Optics and Photonics, 2018: 1082036.
- [13] SLAPNICAR G, MLAKAR N, LUŠTREK M. Blood pressure estimation from photoplethysmogram using a spectro-temporal deep neural network[J]. *Sensors*, 2019, 19(15): 3420–3423.
- [14] 孙德山. 支持向量机分类与回归方法研究[D]. 长沙:中南大学, 2004.
- [15] 孙 玲. 一种支持向量机参数选择方法的研究及应用[D]. 杭州:杭州电子科技大学, 2017.
- [16] LEE C, SHIN H S, LEE M. Relations between ac-dc components and optical path length in photoplethysmography[J]. *Journal of Biomedical Optics*, 2011, 16(7): 077012.
- [17] CHOWDHURY M H, SHUZAN M N I, CHOWDHURY M E H, et al. Estimating blood pressure from the photoplethysmogram signal and demographic features using machine learning techniques[J]. *Sensors*, 2020, 20(11): 3127–3131.
- [18] 师荣堃. 基于光电容积脉搏波的无创血压测量模型研究[D]. 上海:上海交通大学, 2019.
- [19] 吴 丹. 基于深度神经网络的连续无创血压检测及其应用研究[D]. 深圳:中国科学院大学(中国科学院深圳先进技术研究院), 2017.
- [20] SILVA I, MOODY G B. An open-source toolbox for analyzing and processing physionet databases in matlab and octave[J]. *Journal of Open Research Software*, 2014, 2(1): 1–4.