

基于多参数特征融合的无袖带连续血压测量方法

金星亮¹, 万程², 谢晨杰^{2,3}, 刘三超¹, 吴丹^{2*}

¹ (深圳迈瑞生物医疗电子股份有限公司, 深圳 518057)

² (中国科学院深圳先进技术研究院, 深圳 518055)

³ (南方科技大学, 深圳 518055)

摘要: 血压是人体的一大生理指标, 连续测量患者每个心动周期的动脉血压, 是医护人员对患者进行实时诊断的重要依据。现有的无袖带连续血压测量方法大多基于脉搏波和心电图两路信号获取的特征进行预测建模, 但因无法涵盖影响血压的多种因素, 其模型存在一定误差。本文对 55 位志愿者进行实验, 在传统脉搏波和心电信号的基础上, 引入了心阻抗等体征信息, 探索影响血压测量精度的因素。结果表明, 基于多参数特征融合的随机森林模型相比于基于单个特征的线性模型, 其对收缩压、舒张压预测的平均绝对误差分别减小了 13.79mmHg、9.30mmHg。证明了基于多特征融合的无袖带血压预测模型可以提高血压预测的精度。

关键词: 连续血压; 无袖带; 多参数; 机器学习; 心阻抗 doi: 10.12146/j.issn.2095-3135.20221116001

中图分类号:

Cuffless continuous blood pressure measurement method based on multi-parameter feature fusion

JIN Xingliang¹, WAN Cheng², XIE Chenjie^{2,3}, LIU Sanchao¹, WU Dan^{2*}

¹ (Shenzhen Mindray Bio-Medical Electronics Co., Ltd., Shenzhen 518057, China)

² (Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China)

³ (Southern University of Science and Technology, Shenzhen, 518055, China)

Corresponding Author: Dan WU. Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China. Email: dan.wu@siat.ac.cn.

Abstract: Blood pressure is a major physiological indicator of human body. Continuous measurement of arterial blood pressure in each cardiac cycle is an important basis for real time diagnoses. Most of the cuffless

来稿日期: 2022-11-16 修回日期: yyyy-mm-dd

基金项目: 国家自然科学基金青年基金项目 (81701788); 广东省自然科学基金面上项目 (2022A1515011217)。

作者简介: 金星亮, 硕士, 研究方向为生理信号检测; 万程, 硕士研究生, 研究方向为机器学习; 谢晨杰, 硕士研究生, 研究方向为生物医学建模; 刘三超, 硕士, 研究方向为生理信号分析算法; 吴丹 (通讯作者), 高级工程师, 研究方向为可穿戴传感与智能计算, E-mail: dan.wu@siat.ac.cn。

continuous blood pressure measurements are performed according to the predictive models based on the pulse wave and electrocardiogram signals. However, they may produce errors due to the limited measurements. In this paper, multiple physical signs, such as impedance cardiogram, are explored to improve the measured accuracy of blood pressure. Experiments were conducted upon 55 volunteers, and results show that the random forest model based on multi-parameter feature fusion is able to reduce the average absolute error of systolic and diastolic blood pressure prediction by 13.79 mmHg and 9.30 mmHg, respectively. It proves that the proposed cuffless blood pressure prediction model based on the multi-feature fusion could improve the accuracy of blood pressure prediction.

Key words: continuous blood pressure; cuffless; multi-parameter; machine learning; impedance cardiogram

1 引言

血压作为人体重要的生理参数，能及时反映人体的生理健康状况，是心脏和血管功能健康状况评估的重要依据。有大量临床研究强调在围术期连续血压监测的重要性^[1,2]。低血压在手术或危重病人^[3]中很常见，研究表明，当平均动脉压降低至 80mmHg 持续 10 分钟时，可能会发生器官损伤，并且这种损伤随着时间的持续而加重^[4,5]，因此，手术室及重症监护室的病人更需要进行血压的连续监测。临床上常用的连续血压测量方法需要动脉内插管，不仅具有有创性，而且极易引起其他的并发症。有研究表明：对于非心脏手术患者进行监测，在采用有创动脉血压的监测组中，29.1%的患者发生了心肌损伤，与接受无创血压监测的患者相比，其术后 72 小时内心肌损伤发病率更高^[6]。然而传统袖带式的无创血压测量因为无法做到持续每搏监测，因此对于病情变化迅速的病人，会因为不能及时发现血压波动而对病人生命安全产生影响。因此，探索一种连续的血压监测方法无论是对于临床体征监测还是家庭健康监测都具有十分重要的意义。

目前基于动脉张力法以及容积补偿法的连续血压测量理论较为成熟，但是前者传感器精度以及定位要求较高，后者长时间测量会导致静脉充血而影响精度。相比之下，基于 Moens-Korteweg 公式的脉搏波传导时间（Pulse Transmit Time, PTT）血压估计方法可以彻底摆脱袖带和指套，得到了更广泛的关注。然而，该模型存在需要校准以及精度不高两方面的局限性。为了得到更好的测量精度，一部分学者致力于探寻新的血压关联因子，在传统脉搏波传导时间模型的基础上引入了与血压相关的重要因子，如心率变异性^[7]、脉搏宽度^[8]、脉搏波强度比^[9]等，进而提高了连续血压估计的准确性。随着机器学习的发展，一部分学者开始研究新的建模方法更好的拟合血压模型，如人工神经网络^[10]、随机森林^[11]、循环神经网络^[12,13]等。2020 年，韩国首尔大学 Yang 等人^[14]从心电图（Electrocardiogram, ECG）和光电容积脉搏波（Photoplethysmographic, PPG）中提取了 42 个特征，然后利用线性回归、随机森林、人工神经网络和循环神经网络 4 种机器学习方法构建用于估计血压低频和高频成分的模型。在手术中采集的数据集上的验证结果表明，他们所构建的模型对收缩压（Systolic Blood Pressure, SBP）和舒张压（Diastolic Blood Pressure, DBP）的估计

误差分别为 $0.05 \pm 6.92 \text{ mmHg}$ 和 $-0.05 \pm 3.99 \text{ mmHg}$ 。2021 年, Wang 等人^[15]提出了基于迁移学习技术的血压测量方法; 他们首先将短时 PPG 转换成图片, 然后利用已经训练好的深度卷积神经网络从 PPG 图片中提取特征用于血压估计; 在 MIMIC 数据集上验证显示, 所构建的模型对 SBP 和 DBP 的估计误差分别为 $0.00 \pm 8.46 \text{ mmHg}$ 和 $-0.04 \pm 5.36 \text{ mmHg}$ 。2022 年, 微软团队^[16]在大规模穿戴式数据集上, 利用岭回归验证了不同信号 (ECG、PPG 和压力脉搏波) 估计血压的可行性; 其结果表明, 从压力脉搏波信号中提取的特征对血压的估计误差最低, 对 SBP 和 DBP 分别为 $0.32 \pm 9.8 \text{ mmHg}$ 和 $0.54 \pm 7.7 \text{ mmHg}$ 。目前存在的主要问题是, 血压影响因素复杂, 现有脉搏波理论无法涵盖多种影响因素会给测量带来误差。本文在 ECG 与 PPG 信号的基础上, 引入心阻抗信号 (Impedance Cardiogram, ICG), 旨在通过特征提取计算出更多反映心血管特性的信息, 探索影响血压测量的关键因素, 进而研究一种基于多特征融合的无袖带血压预测模型来提高模型的预测能力及在不同应用场景下的鲁棒性。

2 方法

2.1 数据采集方案

本研究招募了健康的成年受试者共 55 位 (排除实验前一天摄入酒精及咖啡的志愿者, 以及有心脑血管疾病史的志愿者)。志愿者年龄在 20 岁-66 岁之间, 其中有 28 位女性受试者, 27 位男性受试者。本研究通过了中国科学院深圳先进技术研究院伦理委员会的审批, 研究方案符合赫尔辛基宣言的伦理准则。整个实验过程分为平躺 (5 分钟)、正坐 (3 分钟)、深呼吸 (2 分钟)、游戏 (3 分钟) 和握力 (1 分半) 五个状态阶段。实验在安静的环境中进行, 避免不必要的对话, 尽量排除外界干扰。实验开始后, 受试者在实验床上平躺 5 分钟, 而后放松 2 到 3 分钟, 接着床板自动调节受试者转变为正坐状态保持 3 分钟, 而后再次进入放松状态, 待信号稳定后, 进行下一个任务, 受试者保持深呼吸 2 分钟 (每分钟 6 次), 再次进入放松状态, 待信号稳定后进行 3 分钟的游戏测试, 引起实验者的紧张情绪, 随后继续保持放松状态, 信号平稳后进入握力实验, 保持最大握力 1 分半, 随后实验结束, 将采集到的各个状态的多通道生理信号保存下来。实验过程中采用美国 BIOPAC MP150 型 16 通道电生理信号记录仪采集生理信号, 其中采用 ECG100C 模块采集 ECG 信号、PPG100C 模块采集 PPG 信号、EBI100C 模块采集生物电阻抗 (Electrical Bio-Impedance, EBI) 信号、RSP100C 模块采集呼吸波信号 (Respiration, RSP)。同时, 使用 CNAP 连续血压测量仪采集无创连续血压作为血压参考值。信号采样频率为 1000Hz。采集方式为: ECG 电极片置于左右手臂和右腿上, 脉搏波传感器夹在左手食指上, EBI 传感器安装在颈部、锁骨、和胸部两侧, 呼吸传感器绑在腰间, CNAP 的指套戴于左手中指和食指上, 袖带戴于左上臂。

2.2 信号预处理

为了解决心电信号的工频干扰和基线漂移问题，本文设计了一个巴特沃斯带通滤波器，设置其低通截止频率为 5Hz 以去除基线漂移，设置其高通截止频率为 30Hz 以去除工频干扰。在此通带范围内，可以最大程度的保留 ECG 信号的主要信息和 R 波波峰等重要特征点。对于脉搏波信号，它的主要信息集中在 0-10Hz 之间，本文设计了一个二阶巴特沃斯带阻滤波器来滤除其基线漂移，设置滤波器低通截止频率为 1Hz，高通截止频率为 10Hz。通过 BIOPAC 系统自带的 AcqKnowledge 软件对总阻抗图信号求一阶导得到 ICG 信号，ICG 信号频率分布在 5-10Hz 左右，采用巴特沃斯带通滤波器，设置其低通截止频率为 5Hz，高通截止频率为 10Hz，去除其低频基线漂移及高频抖动，使信号更加光滑、周期性更加明显。在采集到的所有周期信号中，血压是最稳定且受干扰最小的信号，因此本文选择血压信号作为一个基准来计算其信号周期，而后根据血压信号的周期序列来对其他信号进行分割并检测其特征点。

2.3 特征提取

如图 1 所示，对多通道信号进行特征点提取。提取的特征点有 ECG 信号的 R 波和 Q 波，PPG 信号的波谷点 Pv 和峰值点 Pk，以及心阻抗信号的 B 点和 X 点。其中脉搏波到达时间（Pulse Arrival Time，PAT）定义为同一个心动周期内 ECG 信号中的 R 峰到 PPG 信号峰值点 Pk 之间的时间差。PATm 定义为同一个心动周期内 ECG 信号中 R 峰到 PPG 信号峰值 Pk 和波谷值 Pv 点之间的时间中点的时间差。射血前期时间（Pre-ejection Period，PEP）定义为同一个心动周期内，ECG 信号 Q 点到 ICG 上的 B 点的时间差。左心室射血时间（Left Ventricular Ejection Time，LVET）定义为 ICG 信号的 B 和 X 两点时间之差。除此之外，还将提取得到的 PAT、PEP、LVET 等特征进行组合，计算其比值，获取了多个新的特征。表 1 给出了多导生理信号中初步提取得到的 89 种特征及其说明。其中，为了研究 ICG 信号对血压预测的贡献，本文针对 ICG 信号也提取了大量特征。




图 1 多导信号特征点的提取

Fig.1 Extraction of multiple signal feature points

表 1 多导生理信号中提取的 89 种特征

Table 1 89 features extracted from multiple physiological signals

特征	特征说明	特征	特征说明
F1—F3	PPG 的峰值、谷值与峰谷差	F42-F45	F26/F21、F27/F23、 F28/F24、F29/F25
F4	心率	F46-F49	F38/F22、F39/F23、 F40/F24、F41/F25
F5, F6	PTT 及平方值	F50-F53	ICG 信号面积、能量、方差 和均值
F7, F8	PAT 和 PATm	F54-F56	ICG 信号峰值、谷值和方差
F9—F11	PTTm,PEP,LVET	F57-F58	ICG 信号偏度和峰度
F12	收缩时间比	F59-F60	ICG 信号峰峰值和均方根值
F13	PTT/PEP	F61-F64	ICG 信号峰值、波形、脉 冲、裕度因子
F14	PEP/LVET	F65-F69	ICG 信号幅度谱最大、最小 值、中位数、均值和峰峰值
F15	PTT/PAT	F70-F73	ICG 信号功率谱最大值、最 小值、中位数、均值
F16	PAT/LVET	F74	ICG 信号信噪比
F17	PTT/LVET	F75	ICG 信号占用带宽
F18-F21	ECG 信号面积、能量、方差 和均值	F76- F81, F84	按表内顺序出现的信号的模 糊熵
F22-F25	PPG 信号面积、能量、方差 和均值	F82-F83	F78 和 F77、F81 和 F77 的比 值
F26-F29	PPG 峰谷间的信号面积、能 量、方差和均值	F85	ICG 信号与 PPG 信号的模糊 熵比值
F30-F33	EBI 信号面积、能量、方差 和均值	F86-F87	ECG 信号互相关函数的最大 值和均值
F34-F37	RSP 信号面积、能量、方差 和均值	F88-F89	PPG 信号互相关函数的最大 值和均值
F38-F41	R-P 点间 PPG 信号面积、能		

量、方差和均值

- (1) 时域特征：本文提取了几种信号在每一个心动周期下的均值、面积、方差、能量以及卷积计算得到的互相关函数的最大值及均值。

$$E = \sum_{i=1}^n |x_i|^2 \quad (1)$$

其中， E 为信号的能量， x_i 为一个心动周期中第 i 个采样点； n 为输入信号一个周期内的采样点数。

- (2) 偏度 (Skewness)

$$S = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{x_i - \mu}{\sigma} \right)^3 \right] \quad (2)$$

其中， μ 为信号均值； σ 为其标准差；偏度为信号的三阶矩阵，可用来反映信号概率密度的不对称程度。

- (3) 峰度 (Kurtosis)

$$K = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{x_i - \mu}{\sigma} \right)^4 \right] \quad (3)$$

同样的， μ 为信号均值； σ 为标准差；峰度为信号的四阶矩阵，反映了信号概率密度的陡峭程度。

- (4) 均方根值 (Root Mean Square, RMS)

$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (4)$$

以上三种信息都能敏感的表现出信号的一些微小变化，而后，引入几种不同的无量纲特征值，以便减少外界物理量的影响。

- (5) 峰值因子 (Crest Factor)

$$C = \frac{x_{peak}}{x_{rms}} \quad (5)$$

其中， x_{peak} 是信号的峰值，峰值因子为信号峰值与均方根值的比值，反映出波形中信号峰值的极端水平。

- (6) 脉冲因子 (Impulse Factor)

$$x_{arv} = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (6)$$

其中， x_{arv} 是信号绝对值的均值（整流平均值）。

$$I = \frac{x_{peak}}{x_{arv}} \quad (7)$$

脉冲因子是信号峰值与信号绝对值的均值之间的比值，与峰值因子的区别在其分母上。

(7) 裕度因子 (Margin Factor)

$$C_e = \frac{x_{peak}}{x_r} = \frac{x_{peak}}{\left(\frac{1}{n} \sum_{i=1}^n \sqrt{|x_i|} \right)^2} \quad (8)$$

其中， x_r 为方根幅值。

$$x_r = \left(\frac{1}{n} \sum_{i=1}^n \sqrt{|x_i|} \right)^2 \quad (9)$$

(8) 波形因子 (Shape)

$$S_f = \frac{x_{rms}}{x_{arv}} \quad (10)$$

波形因子是信号有效值与绝对值的均值间的比值，不难发现，也是脉冲因子与峰值因子的比值。

(9) 频域特征：对每一段心拍信号进行傅里叶变换，获得其中的幅度谱以及功率谱。

(10) 非线性特征：在连续的心拍（心动周期）中按照其时间序列，对其进行模糊熵^[17]的计算，提取出所有信号共 10 个模糊熵的特征（其中 3 个特征为某两种生理信号模糊熵的比值）。

2.4 特征筛选

为了进一步筛选特征，本文将提取到的 89 种特征分别与收缩压、舒张压进行皮尔森相关性系数 (Pearson correlation coefficient, Pearson) 以及最大互信息系数 (Maximal Information Coefficient, MIC) 计算，分别计算特征与血压的线性相关性以及非线性相关性。综合考虑两种相关性结果，筛选出 Pearson 和 MIC 统计得到表现较好的特征纳入特征优选簇，如表 2 所示，其中 Pearson 与 MIC 是各个特征与 SBP 相关系数的计算得分。

表 2 特征优选簇

Table 2 Preferred clusters of features

特征	特征说明	Pearson	MIC	特征	特征说明	Pearson	MIC
F6	PTT 平方值	0.259	0.117	F52	ICG 信号方差	-0.330	0.167
F7	PAT	0.186	0.132	F53	ICG 信号均值	0.020	0.047
F8	PATm	0.142	0.098	F55	ICG 信号谷值	0.191	0.083
F9	PTTm	0.211	0.096	F57	ICG 信号偏度	-0.292	0.119

F19	ECG 信号能量	0.406	0.198	F59	ICG 信号峰峰值	-0.464	0.189
F20	ECG 信号方差	0.424	0.208	F60	ICG 信号均方根值	-0.383	0.160
F21	ECG 信号均值	-0.051	0.063	F61	ICG 信号峰值因子	-0.252	0.099
F31	EBI 信号能量	-0.315	0.260	F66	ICG 信号幅度谱最小值	-0.078	0.048
F32	EBI 信号方差	-0.028	0.010	F70	ICG 信号功率谱最大值	-0.136	0.107
F34	RSP 信号面积	-0.226	0.154	F77	PPG 信号的模糊熵	-0.203	0.105
F35	RSP 信号能量	-0.162	0.156	F79	EBI 信号的模糊熵	-0.181	0.083
F36	RSP 信号方差	-0.111	0.109	F87	ECG 信号互相关函数的均值	0.072	0.059
F51	ICG 信号能量	-0.250	0.184				

2.5 血压建模方法

本文使用线性回归、随机森林回归、极限梯度提升回归模型进行血压预测，并对不同方法所得结果进行对比。线性回归模型： $y = \mathbf{w}^T \mathbf{x} + b$ ，通过模型训练得到最优的 $\mathbf{w}$ 和 b ，使得模型的预测值不断逼近真实值。随机森林（Random Forest，RF）是一种基于树的集成学习方法，它由大量弱决策树学习器组成，这些决策树同时并行生长以减小模型的偏差和方差，从而弥补传统分类和回归树的缺点。本文设置树的最大深度为 48，决策树的个数为 512。极限梯度提升（Extreme Gradient Boosting，XGBoost）模型通过集成多个弱的学习器，在使用加法函数学习后得到强的学习器来预测出结果。树的最大深度为设置为 12，学习率设置为 0.08，决策树的个数设置为 400。

3 实验结果

3.1 不同类型特征的血压预测结果对比

本文选取标准差（Standard Deviation，STD）、平均绝对误差（Mean Absolute Error，MAE），平均误差（Mean Error，ME），作为对所有训练模型进行测试时模型评估的指标。同时，为分析传统血压预测中所用的单特征（PTT）、本文经特征选择得到的特

征优选簇（Selected）以及提取得到的全部特征簇（All）对血压预测的影响，分别对这三类特征进行预测建模。

为了对实验中获取的五种实验状态进行统一预测估计，将提取到的所有状态下的特征簇数据集合合并后再进行模型训练。对数据进行分割之后，得到 23794 条记录，本文选取其中的 80%作为训练集，20%作为测试集。经过对传统血压预测中所用的单特征、本文经特征选择得到的特征优选簇以及提取得到的全部特征进行随机森林和极限梯度提升模型预测后，得到表 3 中所示的所有模型预测结果。

表 3 不同特征模型预测结果

Table 3 Prediction results of different feature models

模型	误差指标	SBP（mmHg）			DBP（mmHg）		
		PTT	Selected	All	PTT	Selected	All
LR	MAE	16.35	/	/	11.21	/	/
	STD	20.21	/	/	14.35	/	/
	ME	-0.15	/	/	-0.10	/	/
XGBoost	MAE	16.12	2.80	2.89	10.90	1.96	2.04
	STD	19.89	4.28	4.34	14.14	2.86	3.05
	ME	-0.21	0.13	0.21	0.06	0.11	0.19
RF	MAE	16.28	2.56	2.74	10.99	1.91	2.08
	STD	20.09	4.06	4.34	14.18	2.80	3.24
	ME	-0.16	-0.06	-0.08	-0.11	-0.03	-0.03

观察表 3 的结果可知 RF 在使用特征优选簇后对于 SBP 和 DBP 两类血压的预测建模效果均较好，误差指标均为最优结果，说明本文通过线性和非线性相关分析共同筛选得到的特征优选簇起到了一定的优化作用，使用特征优选簇的模型性能优于使用单个或全部特征建立的模型，拟合度较高，处在较好的置信区间内。

对于 SBP 预测，将预测结果较好的模型选出，绘制出预测拟合散点图 2，其中，XGBoost 和 RF 的预测散点图均是使用特征优选簇的结果。




图 2 线性回归预测散点图（a）、XGBoost 预测散点图（b）和 RF 预测散点图（c）

Fig.2 Linear regression prediction scatter plot (a), XGBoost prediction scatter plot (b) and RF prediction scatter plot (c)

通过观察图 2 可知，线性回归的拟合性较差，其斜率偏离分割线较远，而在 XGBoost 和 RF 的预测拟合图中很容易观察到，两者的预测回归线均贴近于分割线，两者对于血压预测的拟合度极高，经对比后可知 RF 的预测水平更高，其回归线的贴合度比 XGBoost 更高，而离群点也相对较少，其原因可能是 XBGooost 训练过程中容易导致梯度爆炸，使得离群值较多。

3.2 与其他工作对比

为了验证本文提出的多特征融合模型的性能，选择了与其他学习方法进行比较。其结果如表 4 所示。

表 4 相关工作的对比

Table 4 Comparison of related work

算法	信号	SBP（mmHg）		DBP (mmHg)	
		MAE	STD	MAE	STD
线性回归 ^[18]	PPG	14. 71	10. 79	6. 74	6. 11
U-Net ^[19]	PPG	3. 68	4. 42	1. 97	2. 92
卷积神经网络 ^[20]	PPG, ECG	3. 09	2. 76	2. 11	2.00
梯度提升决策树 ^[21]	PPG	3. 75	5. 46	3. 10	3. 93
随机森林（本文）	PPG, ECG, ICG, RSP	2. 56	4. 06	1. 91	2. 80

由 MAE, STD 对比结果可知，本文提出的基于多特征融合的随机森林模型预测结果较梯度提升决策树、U-Net 等模型具有一定优势，更适用于临床需要更高血压测量精度的应用场景。

4 讨论与分析

血压的变化受多种因素影响，如外周阻力、血管弹性、血容量、心输出量等。常用的 PTT 模型本质上仅反应了血管的硬度，无法涵盖影响血压变化的多种因素。本文在以 PTT 为特征的传统一元线性回归模型的基础上，引入从生理意义上与血压变化具有一定关联的心阻抗信号。从生理角度分析，当人体心脏在周期泵血过程中，人体不同部位的心阻抗会发生同样的周期性变化，因此可以通过心阻抗信号的波形变化图，计算得出心排量和相关的血流动力学参数，而每搏射血量和心排量是血压和心血管系统的重要参数，因此 ICG 信号会对血压预测产生一定影响并做出贡献。本文从线性与非线性相关性角度分析提取得了大量与血压相关性很高的 ICG 信号特征，同时不同特征的模型预测结果

表明利用特征筛选过后的特征优选簇可以提高机器学习模型性能，其模型预测误差比使用单个或全部特征建立的模型都更小。

随后，为了验证本文提出的特征优选簇在血压预测方面的性能，本文采用传统线性回归模型与机器学习模型进行对比，研究过程中可以明显发现，血压变化的影响因素是极为复杂的，其具体的机理也并不明确，由前面提到的心血管系统中所有的因素共同影响，简单的线性模型具有很大程度的局限性和不足，因此为了更好地对血压进行建模，进行临床连续、无创的血压估计，本文也同时对比了不同类型的机器学习模型。结果可知，使用特征优选簇的随机森林模型对于血压预测建模取得了更好的结果。而 XGBoost 模型相较于 RF 模型的性能稍弱一些，但其预测水平仍然很高，所有误差指标同样较低，接近于 RF 模型结果，属于较好的模型，低于 RF 的原因可能是由于 XGBoost 在空间上消耗多、时间代价大。本文研究的两种机器学习方法 XGBoost 和 RF 在使用特征优选簇后，模型误差均低于 AAMI 标准误差范围 $ME < \pm 5\text{mmHg}$ ， $STD < \pm 8\text{mmHg}$ 。最后，通过与其他文献工作的对比，进一步体现出本文提出多特征融合模型的优越性。

在对不同生理状态的血压预测分析中，本文没有采集高血压患者以及存在心脏问题患者的生理信号，因此在未来的实验中，应当对各类人群结合动脉血压的生理机制进行分析，特别是患有心血管疾病的患者，尽可能全面的揭示影响血压变化的具体因素。

5 结论

对于现有基于脉搏波和心电信号的血压预测模型预测误差大的问题，本文提出了基于多特征融合的血压预测模型，并加入了与血压具有较高相关性的心阻抗信号，经过线性和非线性分析，选取了特征集合中与血压相关性较高的特征组成特征优选簇，利用传统的一元 PTT 线性模型、XGBoost 模型以及 RF 模型，将所有实验阶段状态下的多维度特征优选簇合并输入并构建适用于多种状态的血压估计模型，随后对不同的机器学习模型的 MAE，STD 以及 ME 指标进行评估，结果表明随机森林算法更适合本文的建模，并且特征优选簇相比于一元 PTT 特征以及所有特征作为输入的模型预测效果都更好，说明经过特征筛选过后的特征优选簇提高了机器学习模型的性能。最后，通过与其他相关工作的对比，证明了本文提出的多特征融合的血压建模方法不仅具有高度的准确性，而且可应用于不同状态场景，具有一定的鲁棒性。

参考文献

- [1] Ackland GL, Brudney CS, Cecconi M, et al. Perioperative Quality Initiative consensus statement on the physiology of arterial blood pressure control in perioperative medicine[J/OL]. British Journal of Anaesthesia, 2019, 122(5): 542-551.
- [2] Eley VA, Christensen R, Guy L, et al. Perioperative Blood Pressure Monitoring in Patients With Obesity:[J/OL]. Anesthesia & Analgesia, 2019, 128(3): 484-491.
- [3] Maheshwari K, Nathanson BH, Munson SH, et al. The relationship between ICU hypotension

and in-hospital mortality and morbidity in septic patients[J/OL]. *Intensive Care Medicine*, 2018, 44(6): 857-867.

[4] Wesselink EM, Kappen TH, Torn HM, et al. Intraoperative hypotension and the risk of postoperative adverse outcomes: a systematic review[J/OL]. *British Journal of Anaesthesia*, 2018, 121(4): 706-721.

[5] Saugel B, Sessler DI. Perioperative Blood Pressure Management[J/OL]. *Anesthesiology*, 2021, 134(2): 250-261.

[6] Abbott TEF, Howell S, Pearse RM, et al. Mode of blood pressure monitoring and morbidity after noncardiac surgery: A prospective multicentre observational cohort study[J/OL]. *European Journal of Anaesthesiology*, 2021, 38(5): 468-476.

[7] Chen Y, Shi S, Liu YK, et al. Cuffless blood-pressure estimation method using a heart-rate variability-derived parameter[J/OL]. *Physiological Measurement*, 2018, 39(9): 095002.

[8] El-Hajj C, Kyriacou P. Deep learning models for cuffless blood pressure monitoring from PPG signals using attention mechanism[J/OL]. *Biomedical Signal Processing and Control*, 2021, 65: 102301.

[9] Ding XR, Zhang YT, Liu J, et al. Continuous Cuffless Blood Pressure Estimation Using Pulse Transit Time and Photoplethysmogram Intensity Ratio[J/OL]. *IEEE Transactions on Biomedical Engineering*, 2016, 63(5): 964-972.

[10] Priyanka KNG, Chao PCP, Tu TY, et al. Estimating Blood Pressure via Artificial Neural Networks Based on Measured Photoplethysmography Waveforms[C/OL]//2018 IEEE SENSORS. 2018: 1-4.

[11] Chen X, Yu S, Zhang Y, et al. Machine Learning Method for Continuous Noninvasive Blood Pressure Detection Based on Random Forest[J/OL]. *IEEE Access*, 2021, 9: 34112-34118.

[12] Senturk U, Polat K, Yucedag I. A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks[J/OL]. *Applied Acoustics*, 2020, 170: 107534.

[13] Su P, Ding XR, Zhang YT, et al. Long-term blood pressure prediction with deep recurrent neural networks[C/OL]//2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). Las Vegas, NV, USA: IEEE, 2018: 323-328.

[14] Yang S, Sohn J, Lee S, et al. Estimation and Validation of Arterial Blood Pressure Using Photoplethysmogram Morphology Features in Conjunction With Pulse Arrival Time in Large Open Databases[J/OL]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(4): 1018-1030.

[15] Wang W, Mohseni P, Kilgore K L, et al. Cuff-Less Blood Pressure Estimation From Photoplethysmography via Visibility Graph and Transfer Learning[J/OL]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(5): 2075-2085.

[16] Mieloszyk R, Twede H, Lester J, et al. A Comparison of Wearable Tonometry, Photoplethysmography, and Electrocardiography for Cuffless Measurement of Blood Pressure in an Ambulatory Setting[J/OL]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(7): 2864-2875.

[17] Chen W, Wang Z, Xie H, et al. Characterization of Surface EMG Signal Based on Fuzzy Entropy[J/OL]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(2): 266-272.

[18] Kachuee M, Kiani MM, Mohammadzade H, et al. Cuffless Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring[J/OL]. *IEEE Transactions on Biomedical*

Engineering, 2017, 64(4): 859-869.

[19] Athaya T, Choi S. An Estimation Method of Continuous Non-Invasive Arterial Blood Pressure Waveform Using Photoplethysmography: A U-Net Architecture-Based Approach[J/OL]. Sensors, 2021, 21(5): 1867.

[20] Yan C, Li Z, Zhao W, et al. Novel Deep Convolutional Neural Network for Cuff-less Blood Pressure Measurement Using ECG and PPG Signals[C/OL]//2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Berlin, Germany: IEEE, 2019: 1917-1920.

[21] Yan J, Cai X, Zhu G, et al. A non-invasive blood pressure prediction method based on pulse wave feature fusion[J/OL]. Biomedical Signal Processing and Control, 2022, 74: 103523.