

DOI:10.3969/j.issn.1005-202X.2024.06.016

医学信号处理与医学仪器

基于PPG信号的极简特征回归树血压估计模型设计

李勋¹, 刘丽荣¹, 李浩², 杨怜琳³, 王志敏³, 邹梅¹

1. 昆明学院物理科学与技术学院, 云南 昆明 650214; 2. 昆明学院医学院, 云南 昆明 650214; 3. 昆明市延安医院, 云南 昆明 650051

【摘要】目的:提出一种基于光电容积脉搏波(PPG)的极简特征回归树血压估计模型。**方法:**从单路PPG信号中提取15个特征参数,利用斯皮尔曼相关系数筛选与血压相关性最高的4个参数,构建极简特征回归树血压模型。**结果:**极简特征回归树血压模型收缩压和舒张压的估计误差分别达到 (-0.02 ± 3.63) mmHg和 (-0.04 ± 2.10) mmHg。**结论:**提出的极简特征回归树血压模型结构简洁、准确率较高,这一发现对于在可穿戴设备中使用单路PPG信号进行血压估计具有重要意义。

【关键词】光电容积脉搏波;极简特征;斯皮尔曼相关系数;血压估计模型

【中图分类号】R318;Q632

【文献标志码】A

【文章编号】1005-202X(2024)06-0769-07

Regression tree model for blood pressure estimation using the minimalist characteristics of photoplethysmography signal

LI Xun¹, LIU Lirong¹, LI Hao², YANG Lianlin³, WANG Zhimin³, ZOU Mei¹

1. School of Physical Science and Technology, Kunming University, Kunming 650214, China; 2. School of Medicine, Kunming University, Kunming 650214, China; 3. Yan'an Hospital of Kunming City, Kunming 650051, China

Abstract: Objective To propose a regression tree model for the estimation of blood pressure using the minimalist characteristics of photoplethysmography (PPG) signals. **Methods** Fifteen characteristic parameters were extracted from the PPG signals, and the 4 parameters with the highest correlations with blood pressure were screened using the Spearman correlation coefficient to construct a regression tree model for blood pressure estimation using the minimalist characteristics. **Results** The estimation errors of systolic and diastolic blood pressures in the constructed model were (-0.02 ± 3.63) mmHg and (-0.04 ± 2.10) mmHg, respectively. **Conclusion** The proposed regression tree model has a simple structure and high accuracy, which is of great significance for using a single-channel PPG signal for blood pressure estimation in wearable devices.

Keywords: photoplethysmography; minimalist characteristics; Spearman correlation coefficient; blood pressure estimation model

前言

随着人们生活水平的提高,不良习惯和嗜好也随之增加,这导致了一系列健康问题,特别是心血管疾病等与血压异常有关的问题^[1-2]。为了预防这些疾病的发生,需要对血压进行长期监测^[3-5]。血压监测分为有创血压监测和无创血压监测^[6-7]。无创血压监测是一种在皮肤表面进行血压测量的方法,主要有

袖带式血压测量法和无袖带血压测量法。无袖带血压监测是一种不需要传统袖带的血压监测技术,该技术主要从心电图(Electrocardiography, ECG)信号、光电容积脉搏波(Photoplethysmography, PPG)信号和心音等生理信号中提取相关特征,利用机器学习构建血压模型,从而估计血压^[8-12]。PPG信号是通过光电技术检测可反映由心脏活动引起的外周血管中血容量变化的信号,具有便携、舒适性强等优点。因此,被越来越多地应用到血压估计的研究中。2016年,Duan等^[13]从PPG信号中提取11个形态学参数特征,利用支持向量机估计血压,其结果符合美国医疗器械协会(AAMI)标准。2017年,Kachuee等^[14]从PPG信号和ECG信号中提取18个形态学特征参数,利用AdaBoost估计血压,其结果仅有舒张压符合AAMI标准。2018年,Wang等^[15]从PPG信号中提取

【收稿日期】2024-02-25

【基金项目】昆明学院引进人才科研项目(XJ20210003);云南省科技厅基础研究计划(ZX20240033)

【作者简介】李勋,硕士,研究方向:医学信号处理, E-mail: 973338674@qq.com

【通信作者】邹梅,高级工程师,研究生导师,研究方向:医学信号处理以及光电传感器, E-mail: bill_zom@126.com

20个时间参数和频谱特征参数,利用人工神经网络估计血压。2019年,Mousavi等^[16]从PPG信号中提取43个波形数值参数,利用AdaBoost估计血压,其结果仅有收缩压符合AAMI标准。2020年,Hsu等^[17]从PPG信号中提取59个形态学参数,并利用人工神经网络估计血压。2020年,Chowdhury等^[18]从PPG信号中提取107个形态学参数、时频域统计特征和人口统计学特征参数,以估计血压,其结果标准差(STD)达到9.29 mmHg,误差较大。2020年,Lee等^[19]从PPG信号和ECG信号中提取7个幅度、时间参数,并采用循环神经网络进行血压估计,收缩压的平均绝对误差(MAE)为5.82 mmHg,STD为6.82 mmHg,误差较大。

为了获得精确的血压估计值,以上研究均使用大量的特征参数,这必然导致血压估计模型的复杂度大幅度提升,不利于在ARM、FPGA以及DSP等计算资源有限的设备上使用。因此,本研究提出一种基于PPG信号极简特征的血压估计模型。该模型从单路PPG信号中提取4个特征参数,并使用回归树建立血压估计模型。研究结果表明,本研究提出的极简特征回归树血压模型达到AAMI标准。

1 极简特征的回归树血压估计模型设计

1.1 回归决策树

决策树是一种用于分类和回归分析的机器学习算法,它具有可解释性、易理解和易实现等主要优点^[20-22]。决策树以树状结构表示决策规则的模型,包含根结点、内部结点和叶节点。根结点是决策树的起始点,包含整个样本集;内部结点表示分类的特征或属性;叶结点表示决策结果。构建决策树的过程从根结点开始,根据特征对数据集进行划分,并建立决策规则。常用的划分准则包括信息增益(information gain)、增益率(gain ratio)以及基尼指数(Gini index)。

在决策树构建过程中,常用信息熵(information entropy)来度量样本纯度。信息熵是一个表示数据集的不确定性和混乱程度的指标,其公式如下所示^[22]:

$$\text{Ent}(D) = - \sum_{k=1}^{|Y|} pr_k \log_2 pr_k \quad (1)$$

其中, $pr_k (k = 1, 2, \dots, |Y|)$ 是第 k 类样本在样本集合 D 中的概率, $\text{Ent}(D)$ 的值越小,则 D 的纯度越高。信息增益就等于划分前后信息熵之差,信息增益越大,表示划分后的样本更趋向于同一类别,其公式如下所示^[22]:

$$\text{Gain}(D, a) = \text{Ent}(D) - \sum_{v=1}^V \frac{|D^v|}{|D|} \text{Ent}(D^v) \quad (2)$$

其中, a 是离散属性, V 是样本集合 D 划分产生的分支

结点, D^v 是 D 在 a 上取值的样本集合, $\frac{|D^v|}{|D|}$ 是权重。

信息增益会偏好属性取值较多的属性,这种偏好会使模型的泛化能力减弱,不能有效地对新样本进行估计。为了减少这种偏好带来的影响,往往采用增益率来做划分准则,增益率通过将属性的信息增益与属性的固有信息量进行比较,以便更公平地评估属性的重要性。其公式如下所示^[22]:

$$\text{Gainratio}(D, a) = \frac{\text{Gain}(D, a)}{\text{IV}(a)} \quad (3)$$

其中,

$$\text{IV}(a) = - \sum_{v=1}^V \frac{|D^v|}{|D|} \log_2 \frac{|D^v|}{|D|} \quad (4)$$

除了上述两种指标外,还可以用基尼指数作为划分准则,用基尼值来度量样本集 D 的纯度。基尼指数通过计算每个属性划分后的加权基尼指数,来评估属性的划分能力。其公式如下所示^[22]:

$$\begin{aligned} \text{Gini}(D) &= \sum_{k=1}^{|Y|} \sum_{k' \neq k} pr_k pr_{k'} \\ &= 1 - \sum_{k=1}^{|Y|} pr_k^2 \end{aligned} \quad (5)$$

基尼指数越小,划分效果越好,本研究将采用基尼指数作为划分准则。属性 a 的基尼指数定义为^[22]:

$$\text{Gini_index}(D, a) = \sum_{v=1}^V \frac{|D^v|}{|D|} \text{Gini}(D^v) \quad (6)$$

本研究使用回归决策树即回归树构建血压模型,回归树通过输入的特征将训练集分成多个区域,并为每个区域分配一个输出值。训练完成后,可以得到一棵构建好的回归树,其中每个叶结点都对应一个输出值。当测试集输入到回归树中时,回归树可以根据训练好的标准来估计血压^[23-24]。构建回归树血压模型时,可以分为以下4个步骤:(1)首先,根据划分标准将训练集划分为两个不同的子区间,每个子区间对应一个新的节点;(2)然后,对于每个子区间,将采用步骤(1)的方法递归地划分为不同的子区间,直到满足条件为止;(3)接着,根据每个叶节点的样本数据,以平均值作为输出值;(4)最后,将训练集划分为 M 个区间(R_1, R_2, \dots, R_M),每个区间对应一个输出值 C_1, C_2, \dots, C_M 。完成上述步骤后,就可构建一颗回归树,得到一个可用于估计的回归树模型。在上述步骤中,划分标准将采用最小二乘法,通过遍历划分变量 j ,获得最优的划分变量 j 和划分点 s ,公式如下所示^[23-24]:

$$\begin{aligned} &\sum_{x_1 \in R_1(j, s)} (y_1 - c_1)^2 + \sum_{x_2 \in R_2(j, s)} (y_2 - c_2)^2 \\ &\leq \sum_{x_1 \in R_1(j', s')} (y_1 - c'_1)^2 + \sum_{x_2 \in R_2(j', s')} (y_2 - c'_2)^2 \end{aligned} \quad (7)$$

其中, $(j', s') \neq (j, s)$, (j', s') 是除了 (j, s) 以外的任何划分变量和划分点组合, x, y 为输入变量和输出变量, c_1 、 c_2 和 c'_1 、 c'_2 分别是基于 (j, s) 和 (j', s') 划分后两个区间中目标变量的平均值。每个区间对应的输出值将采用如下公式计算^[23-24]:

$$\hat{c}_m = \frac{1}{N_m} \sum_{x_i \in R_m(j, s)} y_i \quad (8)$$

其中, $x \in R_m, m=1, 2, 3, \dots, n, N_m$ 是每个划分区间中的样本总数。

1.2 超参数选取

在构建回归树模型时,超参数的选择会影响模型的性能、泛化能力和复杂度,因此选择合适的超参数是构建模型过程中的关键步骤之一。在决策树中,超参数主要包括最大深度、节点和叶节点。其中,最大深度决定决策树的层数。增加最大深度会增加模型的复杂度,提高模型的拟合能力,但同时也增加了过拟合的风险。节点和叶节点的选择也会对模型的性能产生一定的影响。因此,在选择决策树的超参数时,需要根据特征的数量、数据集的规模等进行合理的选择。为了选择最佳的超参数,本研究使用 Python 中 scikit-learn 库中的 RandomizedSearchCV。选择超参数的具体步骤如下所示:(1)创建回归树模型;(2)定义参数空间,使用 randint 函数指定最大深度、节点分裂的最小样本数和叶节点所需的最小样本数的取值范围;(3)创建 RandomizedSearchCV 对象,传入基本模型、参数空间、迭代次数和交叉验证的折数作为参数;(4)使用训练集的特征和标签进行参数搜索,RandomizedSearchCV 遍历参数空间中的不同组合;(5)超参数搜索完成后,使用 random_search.best_params_ 获取超参数;(6)通过 random_search.best_estimator_ 获取具有最佳参数的模型;(7)使用最佳模型对测试集的特征进行估计,并计算平均误差 (Mean Error, ME) 和 STD,判断 ME 和 STD 是否小于预期期望,如果不小于则返回第三步重新进行超参数搜索,直到满足预期期望为止。通过上述步骤,可以获取决策树回归模型的最佳超参数数值,其中最大深度为 159、节点分裂的最小样本数为 19 以及叶节点所需的最小样本数为 1。

1.3 评估指标

血压估计模型性能主要体现在准确度和稳定性方面。为了评估血压估计模型的性能,需要借助相关指标进行判断,并考察这些指标是否符合 AAMI 标准或英国高血压协会标准等规范。本研究采用 AAMI 标准作为基准来评估血压模型性能,并使用 ME、MAE、STD 以及皮尔森相关系数(r)等指标进行评估。

ME 是估计值与实际值的差的平均值,该值越小,则代表模型性能的准确度越好。公式如下所示:

$$ME = \frac{1}{N'} \sum_{i=1}^{N'} (Y_{pr}^{(i)} - Y_{tr}^{(i)}) \quad (9)$$

其中, N' 表示测试集样本个数, Y_{tr} 表示实际值, Y_{pr} 表示估计值。MAE 是估计值与实际值之差的绝对值的平均值。与 ME 一样,值越小表示模型的拟合效果越好,唯一不同的是加上绝对值之后,避免了正负抵消的情况,其公式如下所示:

$$MAE = \frac{1}{N'} \sum_{i=1}^{N'} |Y_{pr}^{(i)} - Y_{tr}^{(i)}| \quad (10)$$

STD 是估计值与实际值之差的平方的平均值再开平方,表示估计值与实际值之间的离散程度,该值越小,则模型的拟合效果越好,其公式如下所示:

$$STD = \sqrt{\frac{1}{N'} \sum_{i=1}^{N'} (Y_{pr}^{(i)} - Y_{tr}^{(i)})^2} \quad (11)$$

ME 和 STD 经常用来评估模型的性能,值越接近 0 代表估计值越接近真实值,其模型性能的准确度越好。其中, AAMI 标准规定血压测量的 ME 应小于 ± 5 mmHg, STD 应小于 ± 8 mmHg。

2 结果与分析

2.1 PPG 信号与血压数据来源

本研究使用的数据是 Kachuee 等^[20]从重症监护智能监测(MIMIC)II 数据库^[21]中获得的数据,波形信号的采样频率为 125 Hz。因此,在本研究中不再进行数据预处理操作。从数据库中筛选 699 组数据,每组数据包括一个 PPG 信号周期以及对应的收缩压 (Systolic Blood Pressure, SBP) 和舒张压 (Diastolic Blood Pressure, DBP)。SBP 最低为 98.22 mmHg, 最高为 160.06 mmHg; DBP 最低为 50.26 mmHg, 最高为 84.16 mmHg。

2.2 特征参数提取

PPG 传感器将光线照射到皮肤表面,其中一部分光线被皮肤吸收,一部分光线被反射,通过光电传感器测量反射光和透射光的强度便可获取 PPG 信号。皮肤吸收光的程度与血液流动密切相关。当心脏收缩时,血管中血液增多,导致皮肤吸收光增加,反射光减少;相反,当心脏舒张时,血管中血液减少,导致皮肤吸收光减少,反射光增加。而血压是血液对血管壁施加的压力,PPG 信号与血压存在一定关系。因此,可以从 PPG 信号中提取相关特征并构建机器学习模型用以估计血压。

为了提高模型准确性,本研究将结合形态学特征参数和统计特征参数联合建模估计血压。从 PPG 信号中提取部分与血压相关的形态学特征参数和统

计特征参数,为进一步筛选特征参数奠定基础。如图1所示,本研究选取峰值点(f1)、波谷点(f2)、幅度(f3)、波谷上升至峰值所需时间(f4)、峰值下降至波谷所需时间(f5)、幅度与波谷上升至峰值所需时间的比值(f3/f4)、幅度与峰值下降至波谷所需时间的比值(f3/f5)、上升支面积(f6)和下降支面积(f7)共9个形态学特征参数。




Figure 1 Schematic diagram of PPG signal characteristic parameters

本研究还选取PPG信号周期内的平均值(f8)、中位数(f9)、方差(f10)、标准差(f11)、偏度(f12)和峰度(f13)共6个统计特征参数。

(1)平均值(Mean)的计算公式如下所示:

$$\bar{p} = \frac{1}{n} \sum_{i=1}^n p_i$$

(12)

其中, n 表示PPG信号周期内的样本总数, p_i 表示PPG信号周期内的数据点。

(2)中位数(median)又称中点数、中值,是一组数据从小到大排列 P_1, P_2, \dots, P_n ,取中间位置的数, n 取奇数时为 $P_{(n+1)/2}$, n 取偶数时为 $(P_{n/2}+P_{(n/2+1)})/2$ 。

(3)方差(Variance)的计算公式如下所示:

$$\sigma^2 = \frac{\sum_{i=1}^n (p_i - \bar{p})^2}{n - 1}$$

(13)

(4)标准差(Standard Deviation)的计算公式如下所示:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (p_i - \bar{p})^2}{n - 1}}$$

(14)

(5)偏度(Skewness)是描述数据分布偏离对分布的程度,计算公式如下所示:

$$S = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{p_i - \bar{p}}{\sigma} \right)^3 \right]$$

(15)

(6)峰度(Kurtosis)是描述数据分布形状的尖端程度,其计算公式如下所示:

$$K = \frac{1}{n} \sum_{i=1}^n \left[\left(\frac{p_i - \bar{p}}{\sigma} \right)^4 \right]$$

(16)

2.3 特征优化

为进一步优化特征参数,本研究分别计算15个特征与SBP和DBP的斯皮尔曼相关系数(Spearman),其计算公式如下所示:

$$\rho = 1 - \frac{6 \sum_{i=1}^m d^2}{m(m^2 - 1)}$$

(17)

其中, ρ 是斯皮尔曼相关系数, m 是样本总数, $\sum_{i=1}^m d^2$ 表示所有样本秩次的平方总和。

计算结果如表1所示。从特征参数与SBP的斯皮尔曼相关系数中,筛选出相关性最强的4个特征参数纳入极简特征簇,4个特征参数分别为f4(上升时间)、f3/f4(上升斜率)、f5(下降时间)和f12(偏度)。

表1 特征参数与血压之间的斯皮尔曼相关系数

Table 1 Spearman correlation coefficient between characteristic parameters and blood pressure

血压	f4	f3/f4	f5	f12	f3/f5	f10	f11	f1	f3	f8	f13	f2	f7	f6	f9
SBP	-0.25	0.21	-0.18	0.16	0.15	0.11	0.11	0.11	0.10	0.06	0.06	0.05	0.04	-0.02	0.01
DBP	-0.52	0.65	-0.46	-0.28	0.72	0.55	0.55	0.60	0.57	0.63	-0.36	0.69	0.51	0.53	0.63

2.4 模型性能评估

本研究将数据集随机分成两组,一组作为训练集和验证集占80%,另一组作为测试集占20%。训练集和验证集使用5折交叉验证,以防止模型在训练过程中出现过拟合和欠拟合现象。为分析不同特征数量对血压

估计的影响,本研究选择用极简特征簇(4个特征)、10个特征和15个特征进行模型构建,并用模型进行血压估计,估计结果如表2所示。其中,用4个特征构建的血压模型,其预测SBP的ME为-0.02 mmHg,MAE为2.65 mmHg,STD为3.63 mmHg。预测DBP的ME

为-0.04 mmHg,MAE为1.50 mmHg,STD为2.10 mmHg。本研究构建的血压模型性能满足AAMI标准。由表2可知,本研究选择的极简特征簇估计结果优于10个特征和15个特征的估计结果。说明本研究通过Spearman相关系数筛选出来的4个特征,对单通道PPG信号血压估计有一定的研究价值。

表2 不同特征数量下的模型性能对比(mmHg)
Table 2 Comparison of model performance under different number of features (mmHg)

特征数量	血压	ME	MAE	STD
4个	SBP	-0.02	2.65	3.63
	DBP	-0.04	1.50	2.10
10个	SBP	-0.56	2.98	4.55
	DBP	0.26	1.81	2.89
15个	SBP	-0.05	2.93	4.82
	DBP	-0.07	1.69	2.67

用回归树模型估计的SBP和DBP与实际SBP和DBP的皮尔森相关性分析结果如图2所示。SBP和DBP的皮尔森相关系数分别为0.97和0.95,其结果非常接近1,这表明实际SBP和DBP与估计的SBP和DBP之间存在较强的相关性。

2.5 不同模型的性能对比

结果与Hsu等^[17]、Song等^[25]、Khalid等^[26]、El-Hajj等^[27]构建的模型进行对比,结果如表3所示。本研究提取PPG信号中的极简特征簇(4个),并使用回归树构建血压模型,其结果符合AAMI标准。Hsu等^[17]从PPG信号中提取59个形态学参数,用ANN构建血压模型,其SBP和DBP的估计结果(ME±STD)达到(3.21±3.35) mmHg和(2.23±2.44) mmHg,该模型估计SBP的STD比本研究估计结果降低0.28 mmHg,但是ME却比本研究提高3.19 mmHg。Khalid等^[26]从PPG信号中提取16个时间参数和面积参数,构建回归树血压模型估计SBP的ME比本研究提高0.05 mmHg,STD也比本研究提高3.47 mmHg。

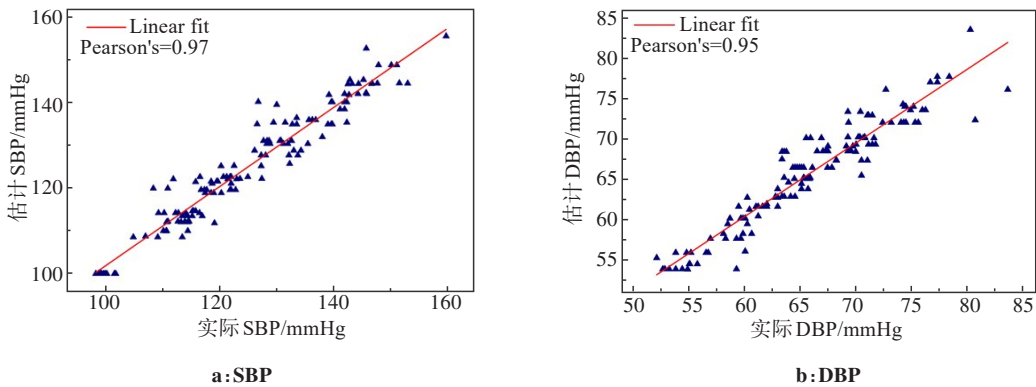


图2 决策树模型估计血压和实际血压的皮尔森相关性分析结果
Figure 2 Pearson correlation analysis results of blood pressure estimated by decision tree model and actual blood pressure

Song等^[25]从PPG、ECG中提取18个时间参数、人口统计学特征参数,构建ANN血压模型,其估计结果的ME和STD均比本研究高。El-Hajj等^[27]从PPG中提取7个时间参数,构建的RNN血压模型,其估计结果只有DBP的STD比本研究低0.03 mmHg,其余估计结果均比本研究高。

综上所述,本文方法构建的模型准确度较高且使用的特征参数最少仅为4个,使得模型的结构进一步简化,从而更容易在可穿戴设备上实现。

3 讨论与结论

基于深度学习的血压估计模型,通常具有复杂的神经网络结构,包括多个隐藏层和大量参数^[27-29]。

虽然有较高的准确性,但在可穿戴设备上的适应性受限于设备的处理能力。支持向量机、随机森林、线性回归等传统机器学习血压估计模型^[26,30-33],结合PPG、ECG信号并且特征数量较多,模型复杂,这虽然可以在一定程度上提高模型的精度,但是增加了模型的复杂性。而本研究的极简特征选取和回归树模型在计算效率和适用性方面显示出显著优势,这对于资源受限的环境有重要意义。

Kim等^[34]构建的深度学习神经网络,输入层有7个节点,隐藏层有3层,每层分别有30、12、8个节点,输出层有1个节点,虽然其构建的模型精度较高,但是模型的复杂性导致其在实时应用中受到限制。Liu等^[35]构建的随机森林回归模型,虽然预测精度表现

表 3 不同模型的性能对比
Table 3 Performance comparison of different models

模型	监测型号	特征数量/个	回归器	血压	ME/mmHg	STD/mmHg
本文方法	PPG	4	决策树	SBP	-0.02	3.63
				DBP	-0.04	2.10
Hsu 等 ^[17] , 2020 年	PPG	59	ANN	SBP	3.21	3.35
				DBP	2.23	2.44
Song 等 ^[25] , 2020 年	PPG、ECG	18	ANN	SBP	-3.00	6.00
				DBP	-1.50	6.00
Khalid 等 ^[26] , 2020 年	PPG	16	回归树	SBP	0.07	7.10
				DBP	-0.08	6.00
El-Hajj 等 ^[27] , 2021 年	PPG	7	RNN	SBP	-0.52	4.22
				DBP	-0.66	2.07

良好,但是其从 PPG、ECG 信号中提取 15 个特征,特征参数较多且 ECG 信号的采集过于繁琐,不利于可穿戴设备的实现。相对于上述研究,本研究通过从单路 PPG 信号中提取并筛选出最具有影响力的 4 个特征,采用简单的回归树模型,利用 Python 中 scikit-learn 库中的 RandomizedSearchCV 模块,选取回归树模型中最佳的超参数,不仅保持良好的准确性,而且简化模型的复杂度并提高计算效率。

本研究的创新性包括:(1)提出基于 PPG 信号的极简特征回归树血压估计模型,与传统的血压监测方法相比,基于 PPG 的血压监测方法具有非接触、无创伤、便捷式等优点;(2)在特征选择上进行精细的筛选,通过计算斯皮尔曼相关系数,仅选择与血压高度相关的 4 个参数,使得模型具有更高的简洁性,这种特征选择方法的创新在于不仅简化了模型,还提高了模型的稳定性和准确性;(3)选择回归树作为建模技术,相比于其他复杂的机器学习算法,回归树具有更好的解释性和易用性,使得模型更易于理解和应用;(4)利用 Python 中 scikit-learn 库中的 RandomizedSearchCV 模块,筛选回归树中最佳的超参数,这使得模型的精度进一步得到提高。

综上所述,本研究构建的极简特征回归树血压估计模型具有独特的创新性和价值,对于推动血压监测技术的发展具有重要意义,未来将进一步优化模型,提高准确性和稳定性。

【参考文献】

[1] Ikramov A, Mukhtarova S, Trigulova R, et al. Prediction of glycosylated hemoglobin level in patients with cardiovascular diseases and type 2 diabetes mellitus with respect to anti-diabetic medication [J]. Front Endocrinol (Lausanne), 2024, 15: 1305640.
[2] Nishan A, Raju SM, Hossain MI, et al. A continuous cuffless blood

pressure measurement from optimal PPG characteristic features using machine learning algorithms[J]. Heliyon, 2024, 10(6): e27779.
[3] Ito A, Nagumo K, Oiwa K, et al. An optimization for resting blood pressure estimation model based on independent components of facial thermal images [J]. IEEJ Trans Electr Electron Eng, 2024, 19(5): 700-706.
[4] Asowata OJ, Okekunle AP, Akpa OM, et al. Risk assessment score and chi-square automatic interaction detection algorithm for hypertension among Africans: models from the SIREN study [J]. Hypertension, 2023, 80(12): 2581-2590.
[5] Zhang GJ, Shin S, Jung J. Cascade forest regression algorithm for non-invasive blood pressure estimation using PPG signals[J]. Appl Soft Comput, 2023, 144: 110520.
[6] Schallmoser S, Zueger T, Kraus M, et al. Machine learning for predicting micro- and macrovascular complications in individuals with prediabetes or diabetes: retrospective cohort study [J]. J Med Internet Res, 2023, 25: e42181.
[7] Sweeney HE, Bainvoll L, Mandelbaum RS, et al. Uptake of postplacental intrauterine device placement at cesarean delivery [J]. AJOG Glob Rep, 2023, 3(1): 100157.
[8] Rastegar S, Gholam Hosseini H, Lowe A. Hybrid CNN-SVR blood pressure estimation model using ECG and PPG signals [J]. Sensors, 2023, 23(3): 1259.
[9] Hoang SV, Tran HP, Nguyen KM, et al. Prediction of obstructive coronary artery disease in patients undergoing heart valve surgery: a cross-sectional study in a tertiary care hospital [J]. J Cardiovasc Thorac Res, 2023, 15(1): 57-64.
[10] Vallée A. Arterial stiffness and biological parameters: a decision tree machine learning application in hypertensive participants [J]. PLoS One, 2023, 18(7): e0288298.
[11] Sumwiza K, Twizere C, Rushingabigwi G, et al. Enhanced cardiovascular disease prediction model using random forest algorithm [J]. Inform Med Unlocked, 2023, 41: 101316.
[12] Gu J, Ma XS, Epland M, et al. A machine-learning algorithm using claims data to identify patients with homozygous familial hypercholesterolemia (HoFH) [J]. J Clin Lipidol, 2023, 17(4S): e24.
[13] Duan KF, Qian ZL, Atef M, et al. A feature exploration methodology for learning based cuffless blood pressure measurement using photoplethysmography [C]//2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Piscataway, NJ, USA: IEEE, 2016: 6385-6388.
[14] Kachuee M, Kiani MM, Mohammadzade H, et al. Cuffless blood pressure estimation algorithms for continuous health-care monitoring [J]. IEEE Trans Biomed Eng, 2017, 64(4): 859-869.
[15] Wang LD, Zhou W, Xing Y, et al. A novel neural network model for blood pressure estimation using photoplethysmography without electrocardiogram [J]. J Healthc Eng, 2018, 2018: 7804243.
[16] Mousavi SS, Firouzmand M, Charimi M, et al. Blood pressure

- estimation from appropriate and inappropriate PPG signals using a whole-based method[J]. Biomed Signal Process Control, 2019, 47: 196-206.
- [17] Hsu YC, Li YH, Chang CC, et al. Generalized deep neural network model for cuffless blood pressure estimation with photoplethysmogram signal only[J]. Sensors, 2020, 20(19): 5668.
- [18] Chowdhury MH, Shuzan MN, Chowdhury ME, et al. Estimating blood pressure from the photoplethysmogram signal and demographic features using machine learning techniques[J]. Sensors, 2020, 20(11): 3127.
- [19] Lee D, Kwon H, Son D, et al. Beat-to-beat continuous blood pressure estimation using bidirectional long short-term memory network[J]. Sensors, 2020, 21(1): 96.
- [20] Kachuee M, Kiani MM, Mohammadzade H, et al. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time [C]//2015 IEEE International Symposium on Circuits and Systems (ISCAS). Piscataway, NJ, USA: IEEE, 2015: 1006-1009.
- [21] Saeed M, Villarroel M, Reisner AT, et al. Multiparameter intelligent monitoring in intensive care II: a public-access intensive care unit database[J]. Crit Care Med, 2011, 39(5): 952-960.
- [22] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 73-92.
Zhou ZH. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 73-92.
- [23] 蒲彦安. 基于PPG信号的无创连续血压预测方法研究[D]. 重庆: 西南大学, 2022.
Pu YA. Research on noninvasive continuous blood pressure prediction method based on PPG signal[D]. Chongqing: Southwest University, 2022.
- [24] 陆一乾. 基于多波长光电容积脉搏波的无创连续血压检测技术[D]. 深圳: 中国科学院大学(中国科学院深圳先进技术研究院), 2022.
Lu YQ. Non-invasive continuous blood pressure detection technology based on multi-wavelength photoplethysmography[D]. Shenzhen: University of Chinese Academy of Sciences (Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences), 2022.
- [25] Song K, Chung KY, Chang JH. Cuffless deep learning-based blood pressure estimation for smart wristwatches[J]. IEEE Trans Instrum Meas, 2020, 69(7): 4292-4302.
- [26] Khalid SG, Liu HP, Zia T, et al. Cuffless blood pressure estimation using single channel photoplethysmography: a two-step method[J]. IEEE Access, 2020, 8: 58146-58154.
- [27] El-Hajj C, Kyriacou PA. Deep learning models for cuffless blood pressure monitoring from PPG signals using attention mechanism[J]. Biomed Signal Process Control, 2021, 65: 102301.
- [28] 樊艳梦, 杨学志, 王定良, 等. 基于潜在空间特征的无袖带血压估计方法[J]. 合肥工业大学学报(自然科学版), 2022, 45(9): 1182-1190.
Fan YM, Yang XZ, Wang DL, et al. A cuff-less blood pressure estimation method based on latent space features[J]. Journal of Hefei University of Technology (Natural Science), 2022, 45(9): 1182-1190.
- [29] 樊艳梦. 基于PPG信号的无袖带血压检测方法研究[D]. 合肥: 合肥工业大学, 2021.
Fan YM. Research on cuff-less blood pressure detection method based on PPG signal[D]. Hefei: Hefei University of Technology, 2021.
- [30] Zhang YM, Ren XL, Liang X, et al. A refined blood pressure estimation model based on single channel photoplethysmography[J]. IEEE J Biomed Health Inform, 2022, 26(12): 5907-5917.
- [31] Zhou K, Yin ZX, Guo F, et al. Application of combined prediction model based on core and coritivity theory in continuous blood pressure prediction[J]. Comb Chem High Throughput Screen, 2022, 25(3): 579-585.
- [32] Liu Q, Zheng YL, Zhang YT, et al. Beats-to-beats estimation of blood pressure during supine cycling exercise using a probabilistic nonparametric method[J]. IEEE Access, 2021, 9: 115655-115663.
- [33] 刘增丁, 陈骥. 脉搏波传导时间的血压估计模型[J]. 中国医学物理学杂志, 2017, 34(2): 199-203.
Liu ZD, Chen J. Blood pressure estimation model using pulse transit time[J]. Chinese Journal of Medical Physics, 2017, 34(2): 199-203.
- [34] Kim H, Lim DH, Kim Y. Classification and prediction on the effects of nutritional intake on overweight/obesity, dyslipidemia, hypertension and type 2 diabetes mellitus using deep learning model: 4-7th Korea national health and nutrition examination survey[J]. Int J Environ Res Public Health, 2021, 18(11): 5597.
- [35] Liu ZD, Zhou B, Li Y, et al. Continuous blood pressure estimation from electrocardiogram and photoplethysmogram during arrhythmias[J]. Front Physiol, 2020, 11: 575407.

(编辑:陈丽霞)