



一种基于端到端神经网络的连续血压估计模型

万 培^a, 桑胜波^{a,b}, 张成然^{a,b}, 张 博^{a,b}

(太原理工大学 a. 信息与计算机学院; b. 新型传感器与智能控制教育部和山西省重点实验室, 山西 晋中 030600)

摘 要: 传统基于脉搏波传导时间法及脉搏波特征参数法的血压测量模型存在精度较低及普适性差等不足。构建一种新的连续血压估计模型, 通过自动提取必要的波形形态特征及其时域变化, 以无创连续的方式估计血压, 其由两个层次组成, 较低层次使用人工神经网络从光电容积脉搏波 (PPG) 和心电图 (ECG) 波形中提取必要的形态特征, 较高层次使用长短期记忆网络层来说明较低层次提取特征的时域变化。依据医疗器械发展协会标准, 对 69 名受试者的采样数据进行模型评估, 实验结果证明, 与基于 ECG 和 PPG 特征参数的 Deep-RNN 血压估计模型相比, 该模型具有更高的预测精度。

关键词: 端到端神经网络; 人工神经网络; 长短期记忆; 光电容积脉搏波; 连续血压

开放科学(资源服务)标志码(OSID):



中文引用格式: 万培, 桑胜波, 张成然, 等. 一种基于端到端神经网络的连续血压估计模型[J]. 计算机工程, 2020, 46(12): 270-275.

英文引用格式: WAN Pei, SANG Shengbo, ZHANG Chengran, et al. A continuous blood pressure estimation model based on end-to-end neural network[J]. Computer Engineering, 2020, 46(12): 270-275.

A Continuous Blood Pressure Estimation Model Based on End-to-End Neural Network

WAN Pei^a, SANG Shengbo^{a,b}, ZHANG Chengran^{a,b}, ZHANG Bo^{a,b}

(a. College of Information and Computer Science;

b. Key Laboratory of Advanced Transducers and Intelligent Control System of Ministry of Education and Shanxi Province, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China)

[Abstract] The traditional Blood Pressure (BP) measurement model based on pulse wave transit time method and pulse wave characteristic parameter method has disadvantages such as low accuracy. This paper proposes a new continuous blood pressure estimation model. The model can automatically extract the necessary features and their time-domain changes, and reliably estimate blood pressure in a non-invasive and continuous manner. The model consists of two layers. The lower layer uses Artificial Neural Network (ANN) to extract necessary morphological features from Electrocardiogram (ECG) and photo Photoplethysmographic (PPG) waveforms. The higher layer uses the Long Short-Term Memory (LSTM) network layer to account for the time domain changes of the features extracted by the lower layer. The proposed model is evaluated on 69 subjects under the standard of the Association for the Advancement of Medical Instrumentations (AAMI). Experimental results show that the proposed model has higher prediction accuracy than Deep-RNN and other BP estimation models based on ECG and PPG feature parameters.

[Key words] end-to-end neural network; Artificial Neural Network (ANN); Long Short Term Memory (LSTM); Photoplethysmography (PPG); continuous Blood Pressure (BP)

DOI: 10.19678/j.issn.1000-3428.0056449

0 概述

近年来, 伴随着中国经济的发展以及人口老龄

化速度的加快, 心血管疾病的患者日益增多, 心血管健康的管理对连续血压监测的要求越来越高。连续血压测量可通过持续反馈显著降低血液循环系统的

基金项目: 国家自然科学基金青年科学基金项目(61703298)。

作者简介: 万 培(1993—), 男, 硕士研究生, 主研方向为人工智能; 桑胜波, 教授; 张成然, 硕士研究生; 张 博, 副教授。

收稿日期: 2019-10-30 修回日期: 2019-12-13 E-mail: 22238161@qq.com

风险,它能够通过慢性高血压、压力和急性血压变化等疾病的即时护理来提高生活健康质量。基于袖带加压系统的传统血压测量不适合连续测量和普遍使用,特别是在可穿戴的小型传感应用中。

使用心电图 (Electrocardiogram, ECG) 和从容积脉搏波 (Photoplethysmography, PPG) 获取脉搏波传输时间 (Pulse Transmit Time, PTT) 估计血压方法,和基于 PPG 波形特征参数估计血压方法在测量动脉僵硬或发现动脉疾病的背景下被广泛研究,单个动脉部位的脉搏波传导速度可用于连续血压估计^[1-2]。收缩压上升时间、舒张压时间、2/3 宽度、1/2 脉搏振幅等多项脉搏波传导参数被认为是从单个 PPG 信号中估计血压的可能候选者。文献[3-4]验证了使用以 PTT 作为主要特征,从 PPG 信号中提取的参数作为辅助特征,运用神经网络算法估计血压的模型比仅使用 PTT 的模型^[5]具有更高的精度。文献[6]使用传统的决策树和 boosting 等时域方法对 PPG 波形进行建模。文献[7]使用频域方法从 PPG 波形中提取必要的特征。与基于 ECG 和 PPG 特征参数工程的方法相比,这些方法在性能上没有明显的改进。最近的研究表明,神经网络可以自动提取必要的特征,而无需任何复杂的特征工程^[8]。

上文讨论的模型均未考虑提取特征参数相对时间的变化。人体的动脉压力由自主神经系统和肾-体液机制调节,该机制包括多个反馈控制回路^[9],其效果也可以在 ECG 和 PPG 信号中被视为调制^[10],同时考虑它们的相关特征和时域变化可以提高 BP 的估计精度。对于复杂时间序列的建模,研究人员发现长短期记忆网络 (LSTM)^[11]非常有效。文献[12]研究结果表明,通过识别 ECG 和 PPG 的特征参数与使用深层 LSTM 网络分析参数可以提高血压估计的准确性。本文构建一个基于 ECG 和 PPG 波形的端到端神经网络的连续血压估计模型,该模型可以自动提取 ECG 和 PPG 波形必要的特征,其中较低层次提取必要的特征,较高层次提取特征的时域变化。

1 数据收集和预处理

1.1 数据源

本文利用 Physionet 的重症监护多参数智能监测 (MIMIC) I 数据库收集 ECG、PPG 和相应的动脉血压 (ABP) 信息^[13],总共收集并预处理来自不同年龄组和性别的 ICU 的 69 名患者的数据。以 125 Hz 的采样频率对 ECG 和 PPG 信号进行采样,表 1 为患者的简要描述。从表 1 可以明显看出,该数据以 60 岁~80 岁年龄组内的患者为主。在 40 岁~60 岁和 60 岁~80 岁年龄组中 SBP 的标准偏差高于 DBP 的相应标准偏差。

表 1 Mimic I 数据库患者数据
Table 1 Patient data of MIMIC I database

年龄分组 /岁	病人 数量	男性 病人 数量	女性 病人 数量	SBP Mean \pm SD /mmHg	DBP Mean \pm SD /mmHg
20 ~ 40	6	5	1	121.62 \pm 12.28	75.39 \pm 6.12
40 ~ 60	9	7	2	135.67 \pm 26.63	68.64 \pm 9.62
60 ~ 80	41	27	14	124.63 \pm 30.54	61.68 \pm 11.29
80 ~ 100	13	08	05	113.47 \pm 15.45	58.43 \pm 8.33

1.2 预处理

为消除基线漂移和噪声,使用 Tunable-Q 小波变换 (TQWT) 对加窗信号进行带通滤波^[14]。TQWT 拥有小波去噪的所有优点^[15]以及小波基的可调性。在 TQWT 中使用 Q 值生成的 Daubechies 小波基来执行离散小波变换 (DWT)。通过改变 Q 值,可以在频域内对小波分解子带进行移位,在尽可能保留形态轮廓的同时有效地去除基线漂移。 Q 选择和滤波过程如图 1 所示,ECG 信号和 PPG 信号使用相同的方法。

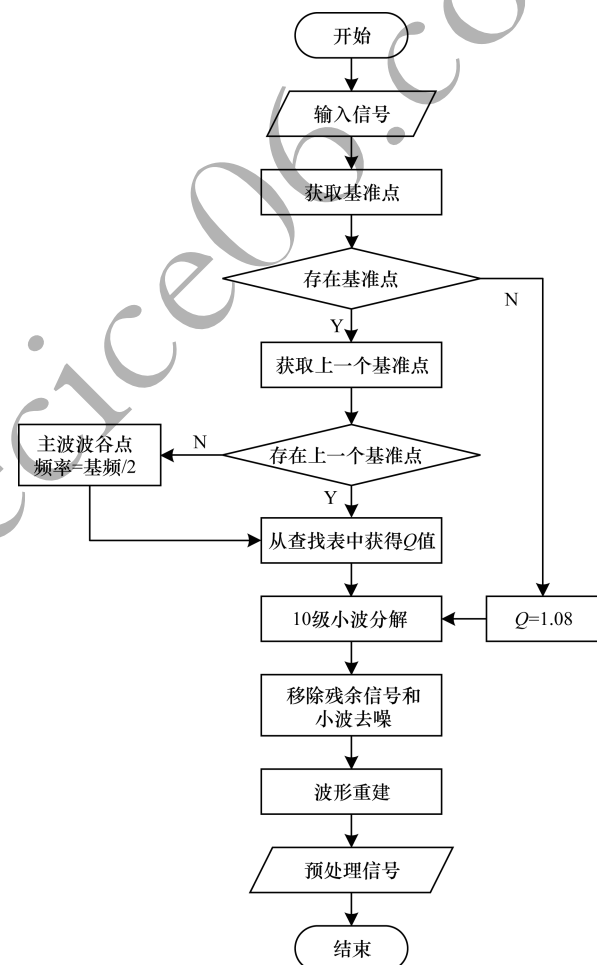


图 1 预处理方法流程

Fig. 1 Procedure of preprocessing method

Q 选择和滤波过程如下:

1) 对加窗的 ECG 或 PPG 信号进行傅里叶变换,并归一化处理幅度。

2) 选择频率为 1.0 Hz ~ 3.5 Hz 范围内的峰值, 选择标准化值大于 0.4 的第 1 个峰值作为基准点。

3) 选择在步骤 2) 中的基准点频率以下的凹拐点, 并选择左端最近的凹拐点作为主波波谷点。如果没有找到凹拐点, 则简单地选择基频的一半作为主波波谷点。

4) 使用选择的基准点频率以及主波波谷点的频率从查找表中选择 Q 值。查找表包括扫描范围 1.0 ~ 1.4 内的 Q 值计算的 10 级子带(小波分解)的中心频率和 -3 dB 位置截止频率。对于 $Q = 1.0$, 10 级子带的中心频率和 -3 dB 位置截止频率分别为 0.812 9 Hz 和 0.430 9 Hz, 对于 $Q = 1.4$, 10 级子带的中心频率和 -3 dB 位置截止频率分别为 1.949 1 Hz 和 1.339 7 Hz。

5) 选择提供最接近基准点的中心频率的 Q 值作为 Q 值的上限 Q_{\max} 。然后在 1.0 ~ Q_{\max} 范围内选择另一个 Q 值, 该值对应于最接近左端的凹拐点频率的 -3 dB 位置截止频率, 该 Q 值即为需要的 Q 值。这样既不衰减基波峰值, 又保留了 ECG 和 PPG 信号的振幅。

6) 如果没有检测到基准点, 则选择 Q 值为 1.08。对于 $Q = 1.08$, 第 10 级子带的中心频率和 -3 dB 位置截止频率分别为 1.002 0 Hz 和 0.573 5 Hz。在这种情况下, 很可能 ECG 或 PPG 信号被伪像严重破坏, 并且可能无法提取到需要波形的大多数特征。去除含有直流分量和基线漂移的剩余信号, 使用预先设置的软 Rigrsure 阈值^[16]的小波去噪。最后得到了既无基线漂移又无高噪噪声的 ECG 和 PPG 信号。

2 连续血压估计模型

本文构建的基于端到端神经网络的人体血压估计模型包含两个层次结构, 下层使用 ANN 从 ECG 和 PPG 波形的单个实例中学习波形特征, 上层使用 LSTM 学习下层提取的特征之间的时间关系。图 2 为 ECG 和 PPG 波形特征提取示意图, 图 3 为输入数据准备过程的流水线, 图 4 为基于 ECG 和 PPG 波形的端到端神经网络的连续血压估计模型。




图 2 ECG 和 PPG 波形特征提取示意图

Fig. 2 Schematic diagram of ECG and PPG waveform feature extraction

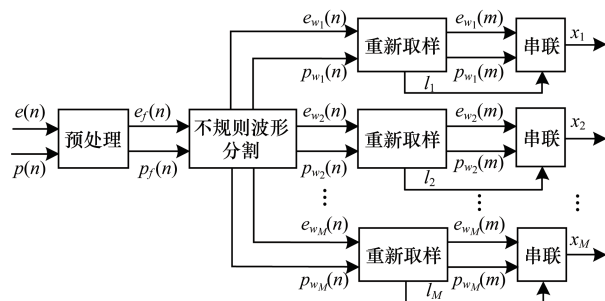


图 3 输入数据准备过程的流水线框图

Fig. 3 Block diagram of input data preparation process

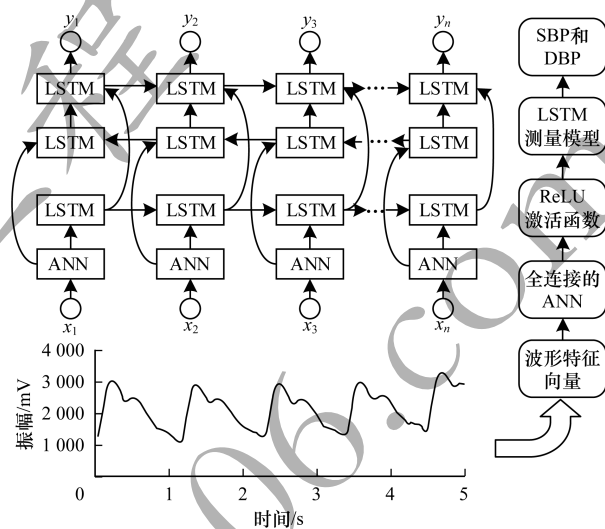


图 4 基于端到端神经网络的连续血压估计模型

Fig. 4 Continuous blood pressure estimation model based on end-to-end neural network

2.1 特征变量选择

根据血流动力学理论, 当外周阻力较低及血管弹性较好时, 脉搏波波形特征是主波窄而高, 重搏波波峰和波谷都很突出。随着外周阻力和血管壁硬化程度的增加, 重搏波的波峰和波谷相对主波的位置逐渐抬高, 最后混为一体不易区分, 使整个脉搏波波形呈馒头形。

本文基于脉搏波分析, 从 PPG 和 ECG 的每一拍中计算出 10 个信息特征, 如表 2 和图 2 所示。依据血流动力学理论确定 10 项与血压相关性较好的特征参数作为血压估计模型中的特征变量。

表 2 ECG 和 PPG 波形中选定特征的定义

Table 2 Definitions of selected features in ECG and PPG

参数名称	参数描述
T_1	连续两次心跳的间隔
T_2	心电图 R 峰值到 PPG 波形主波波峰的间隔
T_3	连续 2 个 PPG 波形主波波峰之间的间隔
T_4	一个 PPG 波形的波谷到主波波峰的间隔
T_5	一个 PPG 波形的主波波峰到降中峡最低点的间隔
T_6	一个 PPG 波形的波谷到最大斜率点的间隔
T_7	一个 PPG 波形的波谷到重搏波波峰的间隔
P_1	一个 PPG 波形的重搏波波峰的幅值
P_2	一个 PPG 波形的主波波峰的幅值
P_1/P_2	一个 PPG 波形的重搏波波峰与主波波峰幅值比

2.2 非均匀波形分割

本文算法对 PPG 和 ECG 波形进行非均匀波形分割, 用于训练神经网络, 分割的主要原因是 ECG 和 PPG 信号频率的变化。心率可以低于每分钟 60 次 (对于心动过缓患者), 由于强烈的共感神经刺激^[17], 心率可以上升到每分钟 200 次。例如, 取一个长度恒定 2 s (250 个样本) 的窗口, 该窗口内波形的周期数可能在 2 个 ~ 6 个周期内变化。这种不同的循环次数将在提取特征时对高 HR 的信号产生更大的误差。因此, 使用一个长度为连续 3 个心电或 PPG 峰 (2 个周期) 的可变窗口, 然后重新采样到 256 个样本。为了训练学习模型, 准备好输入波形, 然后反馈给神经网络。

输入数据的准备过程如下:

1) PPG 节段长度为连续 3 个收缩峰 (2 个周期) $p_{w_i}(n), i=1, 2, \dots, M$, 其中 M 为序列波形段数, 对应 ECG 段 $e_{w_i}(n), i=1, 2, \dots, M$, 分别从预处理后的 PPG 和 ECG 信号 $p_f(n)$ 和 $e_f(n)$ 中提取, 也可以用 $3r$ 峰长度的心电段代替相应的 PPG 信号。

2) 段长 $l_i, i=1, 2, \dots, M$ 由提取的 ECG 和 PPG 波形计算得到, 并除以 256 进行归一化。将 ECG 和 PPG 信号重采样至 256 个样本, 将 ECG 与 PPG 重采样波形 $e_{w_i}(m_i), p_{w_i}(m_i)$ 、归一化段长 l_i 串联, 得到具有 512 个特征的向量 \mathbf{x}_i , 该向量是基于波形的特征向量。

该模型需要 M 个连续的特征向量序列 $[\mathbf{x}_1^T \mathbf{x}_2^T \dots \mathbf{x}_M^T]^T$, 编制顺序如下:

1) 对由 3 个连续峰值偏移一个峰值的 M 组进行上述处理, 形成 M 个特征向量。峰的选择为 0-1-2、1-2-3、2-3-4, 直到 $(M-1)-M-(M+1)$ 。

2) 提取 M 个特征向量, 生成端到端神经网络模型的特征向量序列, 然后取由 SBP 和 DBP 组成的相应序列向量 $[\mathbf{y}_1^T \mathbf{y}_2^T \dots \mathbf{y}_M^T]^T$ 作为输出。

2.3 血压估计模型处理

在准备模型的输入和输出后, 每个患者的数据分为 70% 用于训练, 10% 用于验证, 20% 用于测试。数据准备短 ($M=10$, 从 16 s 窗口提取, 或 2 000 个样本 125 Hz) 和长 ($M=32$, 从 40 s 窗口提取, 或 5 000 个样本 125 Hz) 序列, 并且对两者进行训练。端到端神经网络主要由两个堆叠的 LSTM 层组成, 并与它们连接了呈时间分布的 ANN。ANN 由 128 个具有 ReLU 激活功能的神经元的隐藏层组成。损失函数使用均方误差 (MSE), 梯度优化使用 Adam 优化器^[18], 初始学习率为 0.001。对于正则化, $M=10$ 和 $M=32$, 梯度的 L_2 范数被约束为 3 和 5。第 1 个 LSTM 层是双向的^[19], 用于模拟 2 个方向的时间变化。

完全连接网络的主要目的是从特征向量序列中提取必要的特征 $[\mathbf{x}_1^T \mathbf{x}_2^T \dots \mathbf{x}_i^T \dots \mathbf{x}_M^T]^T$, 其中每个 \mathbf{x}_i 为 1×512 特征向量。堆叠的 LSTM 层学习在不同时间尺度上提取的特征变量的变化以改进 BP 估计。第 2 个 LSTM 层输出向量序列 $[\mathbf{y}_1^T \mathbf{y}_2^T \dots \mathbf{y}_i^T \dots \mathbf{y}_M^T]^T$, 其中每个 \mathbf{y}_i 是一个 1×2 的特征向量, 包含估计的 SBP 和 DBP。

3 血压估计模型的评估

使用平均绝对误差 (MAE) 和均方根误差 (RMSE) 作为度量来评估本文提出的模型。MAE 和 RMSE 定义为:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |z_{iM} - y_{iM}| \quad (1)$$

$$\text{RMSE} = \frac{1}{N} \sqrt{\sum_{i=1}^N |z_{iM} - y_{iM}|^2} \quad (2)$$

其中, y_M 和 z_M 分别是时间序列的第 M 个元素的实际值和估计的 BP (SBP 或 DBP)。对本文模型的性能在 AAMI 标准上进行评估, 同时对血压估计模型进行 Bland-Altman 分析和 Pearson 相关系数分析。

3.1 与其他模型比较

表 3 为不同神经网络架构的对比分析。从表 3 可以看出, AdaBoost 模型对于 DBP 估计具有可接受的误差, 但是对于 SBP 估计具有较高的误差。基于 LSTM 的模型可以对时间特征的变化进行建模, 从而提高精度。在 MAE 和 RMSE 方面, 本文端到端神经网络模型比其他模型表现更好。

表 3 不同血压估计模型的比较分析
Table 3 Comparative analysis of different blood pressure estimation models

模型	SBP		DBP	
	MAE	RMSE	MAE	RMSE
P-AdaBoost ^[7]	7.418 5	15.495 2	3.562 2	7.752 2
W-AdaBoost ^[7]	9.443 2	17.705 1	4.183 1	7.811 9
Deep-RNN ^[17]	1.689 5	2.475 4	1.027 2	1.514 0
端到端神经网络	1.539 4	2.142 8	1.005 0	1.101 8

3.2 AAMI 标准的绩效评估

医学仪器促进协会 (AAMI) 标准要求血压测量装置的误差 (ME) 和误差标准偏差 (SDE) 值分别低于 5 mmHg 和 8 mmHg^[20]。表 4 显示了根据 AAMI 标准对不同模型的评估, 从表 4 可以看出, 端到端神经网络模型满足 SBP 估计的 AAMI 标准, 所提出的模型具有可忽略的 ME 和最小的 SDE。随着 2 个模型的序列长度 M 从 10 增加到 32, 端到端神经网络模型的预测能力明显增加。

表 4 基于 AAMI 标准 ($ME < 5 \text{ mmHg}$, $SDE < 8 \text{ mmHg}$) 的性能评估Table 4 Performance evaluation based on AAMI standard ($ME < 5 \text{ mmHg}$, $SDE < 8 \text{ mmHg}$) mmHg

模型	$M = 10$				$M = 32$			
	SBP		DBP		SBP		DBP	
	ME	SDE	ME	SDE	ME	SDE	ME	SDE
Deep-RNN-4L ^[17]	0.017 5	2.806 5	0.023 1	1.683 2	0.077 8	2.144 3	0.004 6	1.344 8
端到端神经网络	0.025 1	1.584 5	0.012 5	0.898 7	0.016 4	1.284 5	0.002 5	0.735 1

3.3 统计分析

对短序列数据 ($M = 10$) 进行 Bland-Altman 检验和 Pearson 相关检验。图 5 为基于端到端神经网络模型 SBP 和 DBP 估计的 Bland-Altman。对于本文提出的模型,发现 SBP 和 DBP 的一致性极限 $[\mu - 1.96, \mu + 1.96]$ 分别为 $[-4.076, 4.933]$ 和 $[-4.816, 4.736]$,这意味着 95% 的估计 SBP 误差小于 4.78 mmHg, 95% 的测量 DBP 值误差小于 4.50 mmHg,表明该模型是一个好的估计模型。图 6 为基于端到端神经网络模型 SBP 和 DBP 估计的回归示意图。SBP 和 DBP 的 Pearson 相关系数分别为 $r = 0.990$ 和 $r = 0.991$, 2 个系数都非常接近 1.0,表明目标和估计的 BP 之间存在高线性。

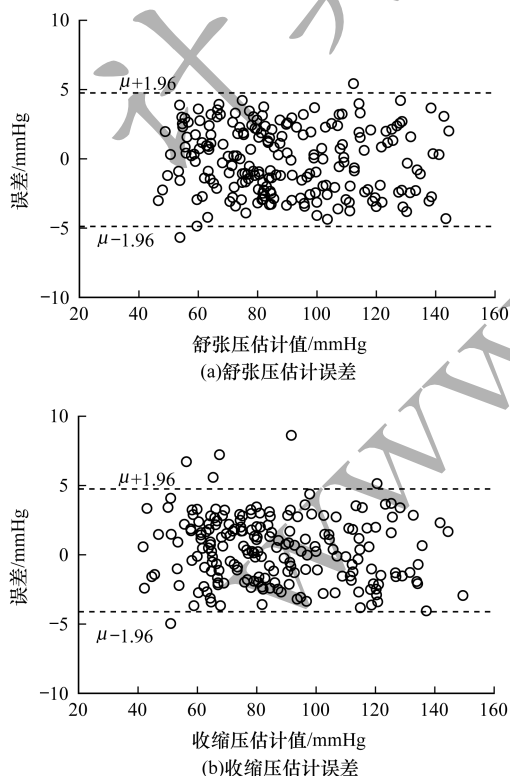




图 5 SBP 和 DBP 估计的 Bland-Altman 示意图

Fig. 5 Bland-Altman schematic diagram of SBP and DBP estimation



(a) 舒张压估计值与实际值的关系



(b) 收缩压估计值与实际值的关系

图 6 SBP 和 DBP 估计的回归示意图

Fig. 6 Regression diagram of SBP and DBP estimation

3.4 实验分析

为验证所建立的血压估算模型的可靠性,本文对采用欧姆龙 HEM-7136 型电子血压计与本文系统测试者同时进行检测以分析该设计的准确性。其中,以欧姆龙 HEM-7136 型电子血压计测得数据作为标准值,本文设计测量数据为估计值。实验基于计算机平台,组合使用桡动脉脉搏传感器(合肥华科电子技术研究所的 HK-2000B 型传感器)、心电图机(三锐科技医用 ECG-2301 单道心电图机)对年龄在 21 岁~35 岁之间的健康男性 7 名和女性 6 名进行检测,采样频率设置为 400 Hz,记录被测者的脉搏波和心电信号,使用基于端到端神经网络的连续血压估计模型对信号进行处理,得到血压估计值,同时使用欧姆龙 HEM-7136 型电子血压计测量被测者的收

缩压和舒张压各3次,取平均值作为血压计测量值。连续测量5天,共65组可对比数据,具体数据情况如表5所示。基于端到端神经网络模型的连续血压估计模型的舒张压和收缩压的平均绝对误差分别为3.037 3 mmHg和2.504 9 mmHg,测量结果满足BP估计的AAMI标准,具有一定的临床意义。

表5 血压估计模型的测量数据分析

Table 5 Analysis of measured data of blood pressure estimation model mmHg

测试者	SBP		DBP	
	MAE	RMSE	MAE	RMSE
Test_1	1.638 0	3.962 3	1.695 3	3.110 2
Test_2	3.314 2	6.758 1	2.698 3	4.913 2
Test_3	2.368 2	5.364 9	3.657 2	5.227 6
Test_4	4.257 2	7.965 3	3.167 0	6.298 7
Test_5	2.395 1	5.362 1	1.652 0	3.654 8
Test_6	5.236 5	9.365 8	3.963 5	5.634 0
Test_7	3.258 1	7.635 9	2.870 3	4.018 2
Test_8	1.623 5	3.627 0	1.637 2	3.146 7
Test_9	3.653 2	6.900 5	2.951 2	5.467 8
Test_10	2.985 2	5.364 0	3.014 7	5.942 0
Test_11	1.365 4	3.625 4	1.001 5	2.134 5
Test_12	3.021 5	7.365 8	1.620 2	2.001 4
Test_13	4.369 2	9.112 1	2.635 8	3.215 7

4 结束语

本文提出一种新的端到端神经网络模型,对ECG和PPG波形进行无袖连续血压估计。该模型能够在不需要任何特征工程的情况下提取必要的波形特征,以及学习时间特征的变化,满足BP估计的AAMI标准,其Pearson相关性测试显示相关系数接近1.0,表明实际BP和估计BP之间具有高线性。为验证血压模型的有效性,对测试者连续测量5天的实验结果表明,血压估计模型误差在 ± 5 mmHg以内,具有一定的准确性和可靠性,达到了较好的效果。

参考文献

- [1] GAO Ninghua, WANG Heng, FENG Xinghua. Classification method of electrocardiogram signals based on dynamic fuzzy decision tree[J]. Computer Engineering, 2020, 46(1): 80-86. (in Chinese)
高宁化,王恒,冯兴华.基于动态模糊决策树的心电信号分类方法[J].计算机工程,2020,46(1):80-86.
- [2] ZHOU Linyong, XIE Xiaoyao, LIU Zhijie, et al. Research on pooling method of convolution neural network[J]. Computer Engineering, 2019, 45(4): 211-216. (in Chinese)
周林勇,谢晓尧,刘志杰,等.卷积神经网络池化方法研究[J].计算机工程,2019,45(4):211-216.
- [3] 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.
- [4] XU Zhihong, LIU Jiexin, CHEN Xianxiang, et al. Continuous blood pressure estimation based on multiple parameters from electrocardiogram and photoplethysmogram by back-propagation neural network[J]. Computers in Industry, 2017, 89: 50-59.
- [5] HALL J E. Guyton and Hall textbook of medical physiology[M]. [S. l.]: Saunders Press, 2010.
- [6] KUMAR N, AGRAWAL A, DEB S. Cuffless BP measurement using a correlation study of pulse transient time and heart rate[C]//Proceedings of International Conference on Advances in Computing, Communications and Informatics. Washington D. C., USA: IEEE Press, 2014: 1538-1541.
- [7] XING Xiaomen, SUN Mingshan. Optical blood pressure estimation with photoplethysmography and FFT-based neural networks[J]. Biomedical Optics Express, 2016, 7(8): 3007-3020.
- [8] MAO J, JAIN A K. Artificial neural networks for feature extraction and multivariate data projection[J]. IEEE Transactions on Neural Networks, 1995, 6(2): 296-317.
- [9] GUYTON A C, COLEMAN T G, COWLEY A W, et al. Arterial pressure regulation: overriding dominance of the kidneys in long-term regulation and in hypertension[J]. American Journal of the Medical Sciences, 1972, 52(5): 584-594.
- [10] CHARLTON P H, BONNICI T, TARASSENKO T, et al. An assessment of algorithms to estimate respiratory rate from the electrocardiogram and photoplethysmogram[J]. Physiological Measurement, 2016, 37(4): 610-623.
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computing, 1997, 9(8): 1735-1780.
- [12] SU Peng, DING Xiaorong, ZHANG Yuaning, et al. Long-term blood pressure prediction with deep recurrent neural networks[C]//Proceedings of 2018 IEEE EMBS International Conference on Biomedical & Health Informatics. Las Vegas, USA: IEEE Press, 2017: 1-19.
- [13] GOLDBERGER A L, AMARAL L A, GLASS L, et al. Physio bank, physio toolkit, and physio net: components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): 215-220.
- [14] SELESNICK I W. Wavelet transform with tunable Q-factor[J]. IEEE Transactions on Signal Processing, 2011, 59(8): 3560-3575.
- [15] UNSER M, ALDROUBI A. A review of wavelets in biomedical applications[C]//Proceedings of the IEEE, 1996, 84(4): 626-638.
- [16] DONOHO D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory, 1995, 41(3): 613-627.
- [17] ZHAO Bo, HAO Yingdi, LI Xinzhen, et al. Human blood pressure prediction method based on support vector regression[J]. Journal of Yanshan University, 2017, 41(5): 438-443. (in Chinese)
赵博,赫英迪,李信政,等.基于支持向量回归的人体血压预测方法[J].燕山大学学报,2017,41(5):438-443.
- [18] PICKERING T G. Isolated diastolic hypertension[J]. Journal of Clinical Hypertension, 2003, 5(6): 411-413.
- [19] SCHUSTER M, PALIWAL K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.
- [20] ARLINGTON S. Association for the advancement of medical instrumentation[J]. Journal of Clinical Engineering, 2016, 41(2): 59-60.