

DOI:10.19651/j.cnki.emt.2108418

基于长期递归卷积网络的无创血压测量

陈晓^{1,2} 杨瑶¹

(1.南京信息工程大学电子与信息工程学院 南京 210044; 2.南京信息工程大学大气环境与装备技术协同创新中心 南京 210044)

摘要: 血压是能够反映人们身体健康的一个重要指标,随着高血压人群分布范围日益增大,连续血压的监测变得愈发重要。本文提出了基于长期递归卷积网络对光电容积脉搏波进行血压连续无创测量的方法。首先将利用光电容积法采集到的脉搏波信号归一化、阈值处理和特征提取,然后用长期递归卷积网络从脉搏波中计算出血压。实验表明,当光电容积脉搏波信号直接输入时,所提方法比长短期记忆网络的平均绝对误差和均方误差分别提升了56.00%和73.25%。将特征参数作为输入时,该实验比光电容积脉搏波信号直接输入时的平均绝对误差和均方误差提升了59.55%和87.41%,相比直接输入,特征参数输入的实验效果更好,实现了血压的精确测量。

关键词: 血压测量;脉搏波;长期递归卷积网络;卷积神经网络;长短期记忆网络

中图分类号: TN911.7 文献标识码: A 国家标准学科分类代码: 520.20

Noninvasive blood pressure measurement based on long-term recursive convolution network

Chen Xiao^{1,2} Yang Yao¹

(1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Collaborative Innovation Center of Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Blood pressure is an important indicator of people's health. With the increasing distribution of hypertension, continuous blood pressure monitoring becomes more and more important. This paper presents a method for continuous noninvasive measurement of blood pressure based on long-term recursive convolution network. Firstly, the pulse wave signal collected by optical capacitance product method is normalized, threshold processing and feature extraction, and then the blood pressure is calculated from the pulse wave by long-term recursive convolution network. The experimental results show that when the pulse wave signal of optical capacitance product is directly input, the average absolute error and mean square error of the method are increased by 56.00% and 73.25% respectively. When the characteristic parameters are used as input, the average absolute error and mean square error of the experiment are increased by 59.55% and 87.41% compared with the direct input of optical capacitance product pulse wave signal. Compared with the direct input, the experimental effect of characteristic parameter input is better, and the accurate measurement of blood pressure is realized.

Keywords: blood pressure measurement; pulse wave; long term recursive convolution network; convolutional neural network; short and long term memory network

0 引言

近几年来的调查统计数据表明,心血管疾病⁻¹正危害着全球人民的公共健康,该疾病致死率较高,高血压则是心血管疾病的首要致病因。根据世界卫生组织的统计报告,每年全球约有1 790万人死于心血管疾病。人们的生活压

力随着社会经济的快速发展也逐步增加,高血压疾病也逐步开始年轻化。

血压是人体心血管系统的主要特征之一,不仅可用于表征人体的健康程度,而且也作为临床医师对病情判断的重要参数⁻²。近年来,通过脉搏^[3-6]提取并测量血压数值的研究越来越多。随着智能算法⁻⁷⁻¹²的发展,一些学者已

经开展了应用智能学习算法进行连续血压测量的研究工作,例如:文献[13]提出了 BP 神经网络方法、文献[14]提出了 Elman 神经网络方法、文献[15]提出了循环神经网络(recurrent neural network, RNN)方法等。通过利用 PPG 信号和 ABP 信号,对血压进行测量,但是测量值与真实值的拟合度在波形较浮动的地方较低,造成了误差的偏大。长短期记忆网络(long short term memory, LSTM)^[16]虽然具有一定解决循环神经网络长期依赖的能力,但随着时间序列的过长,输入信息的变多,单一的 LSTM 模型训练难以收敛至全局最优。

在此背景下,本文提出了长期递归卷积网络的血压测量模型。该模型主要是通过卷积神经网络结构将脉搏信号序列中的高维特征提取出来,而后再利用长短期记忆网络结构对上一层所提取的高维特征进行流量的预测,从而减少特征的丢失。除此之外,本文还利用了差分阈值的方法对单一的 PPG 信号进行人工提取,通过识别起始点和峰值点这两个特征点,从而形成特征参数峰值时间 T_1 、谷值时间 T_2 、峰值高度 h_1 、谷值高度 h_2 、 K 值,将其作为模型输入,进行对比实验。

1 长期递归卷积网络

长期递归卷积网络是通过将 CNN 和 LSTM 两种模型

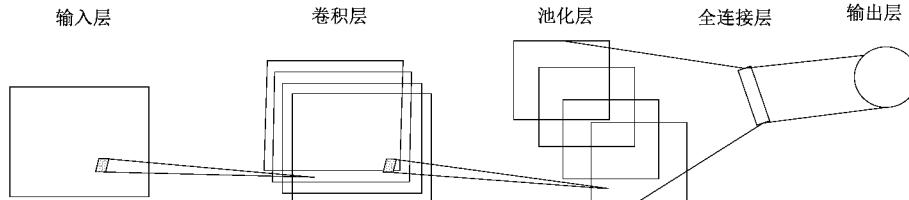


图 1 CNN 结构

发生梯度消失问题和梯度爆炸问题,不适用于处理长时间的依赖。

LSTM 通过门的结构,克服 RNN 长序列依赖问题,构造更大的深度网络。这个网络结构中的隐含层是由一个个特殊的细胞结构组成,细胞结构中的输入门可以进行信息的流入、输出门可以实现信息的流出、遗忘门可以对以前状态进行更新。各门计算公式如式(1)~(4)所示。

结合起来,利用 CNN 网络的权值共享优势提取数据的局部特征,并结合 LSTM 网络的记忆优势提取数据的时序特征,从而提高模型整体的训练能力。

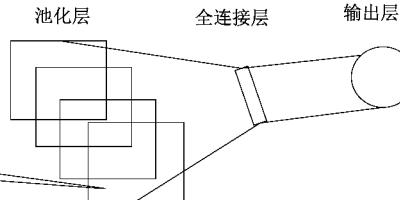
1.1 卷积神经网络

卷积神经网络(convolutional neural network, CNN)^[17]是一类通常用于视觉图像分析的深度神经网络,它的主要优势是参数的共享性、感受范围的宽大性和平移的不变性,从而使得 CNN 能够获得比较厉害的特征学习能力,同时可以实现多层的监督功能,可用来处理网络结构型的数据,并且这个网络在分类图像、识别语音等领域获得比较显著的成果。整体主要由卷积层、池化层和全连接层这 3 部分组成^[18]。卷积层可以用来进行局部的特征提取,池化层主要用于对特征值进行池化。1D-CNN 是用于处理序列数据的一种特殊神经网络。与 2D-CNN 不同的是,1D-CNN 的卷积核只需朝着一个维度滑动进行卷积^[19]。

CNN 的主要流程是:第 1 步,将输入的特征数据形成卷积层;第 2 步,将卷积层中的数据特征进行第 2 次的采样操作并进行池化过程;第 3 步,全连接池化层的神经元。其结构如图 1 所示。

1.2 长短时记忆网络

长短时间记忆神经网络^[19]是基于循环神经网络改进的神经网络。RNN 建立的网络结构在训练的过程中容易



$$I_t = \text{Sigmoid}(W_i \cdot [h_{t-1}, X_t]) \quad (1)$$

$$F_t = \text{Sigmoid}(W_f \cdot [h_{t-1}, X_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W \cdot [I_t * h_{t-1}, X_t]) \quad (3)$$

$$h_t = (1 - F_t) * h_{t-1} + F_t * \tilde{h}_t \quad (4)$$

其中, I_t 、 F_t 分别表示输入门和遗忘门, h_t 表示输出门输出的隐含层, X_t 为当前时刻的外部输入, h_{t-1} 为前一时刻网络的输出。LSTM 网络结构如图 2 所示。

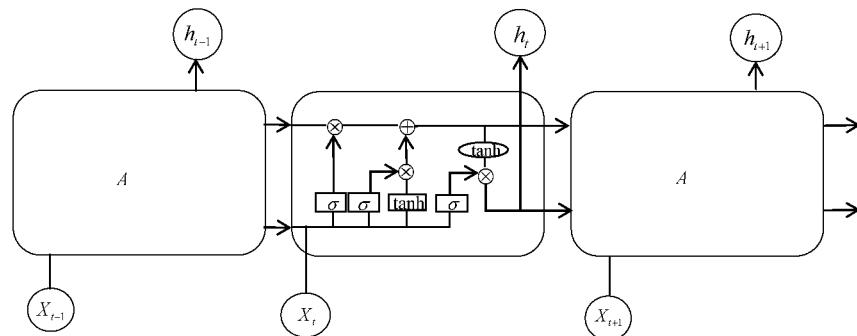


图 2 LSTM 网络的内部结构

2 脉搏波信号原理、获取及处理

2.1 信号原理

光电容积脉搏波^[20]是基于朗伯比尔定律借助光电转换的方式进行脉搏波信号采集的,通常在人体末端部位进行检测,如耳垂、手指、脚趾处,该检测方式被称为光电容积脉搏描记法(photoplethysmography,PPG)。

1)朗伯比尔定律

当一束单色的光遇到一个均匀的不具有散射性的吸光物质时,吸光度 A 与吸收层厚度 b 及吸光物质浓度 c 成正相关关系,与透光度 T 成反相关关系^[21]。公式如式(5)所示。

$$A = \lg(1/T) = Kbc \quad (5)$$

式中: $T = I/I_0$; A 为吸光度; T 为透射比; I 为出射光强度; I_0 为入射光强度; K 为摩尔吸光系数; c 为吸光物质浓度; b 为吸收层厚度。

2)光电容积脉搏描记法

皮肤组织受到一束特定波长的光束照射时,光束可以经历透射或反射这两种方式,将光传送到光电接收器。浅层皮肤组织会产生反射部分光,深层皮肤组织和血液会吸收部分光,所以检测到光的强度将会降低。另外,皮肤组织吸收的光在整个循环系统上是保持不变的,反馈到光电接收器中转换为直流分量;皮肤内血液对光的吸收是有变化的,反馈到光电接收器中转换为交流分量,具体原理如图 3 所示。

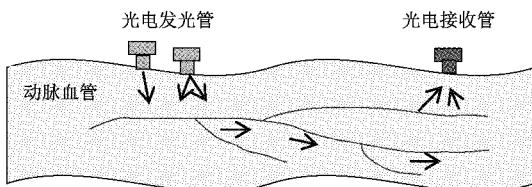


图 3 光电容积描记法原理

2.2 脉搏信号获取

通过低成本的嵌入式系统^[22-24]可以方便地实现信号的采集。在本文的实验研究中,选择了第一代的 MIMIC 数据库 mimicdb 作为实验数据。MIMIC 数据库是一个公开的医学数据库,由美国麻省理工学院和飞利浦医疗联合建立。mimicdb 中包括了 90 名 ICU 患者的真实数据,可以通过访问 PhysioBank ATM 在线查看,该站的网址为: (<https://archive.physionet.org/cgi-bin/atm/ATM>), 用户通过设置 Input 部分的选项 Database 选项、Record 选项、Signals 选项、Annotations 选项来确定所需信息的数据来源。通过设置 Output 部分的 Length 选项、Time format 选项、Data format 选项来确定数据的长度和精度。在 Toolbox 中选定数据的输出方式,并进行下载。具体操作界面如图 4 所示。

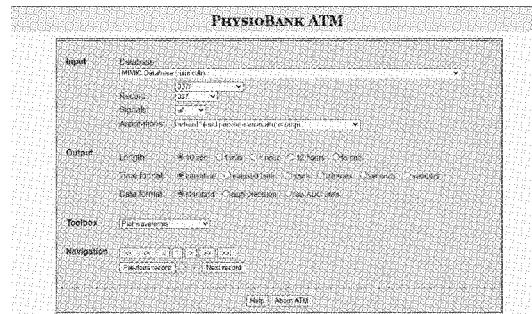


图 4 PhysioBank ATM 操作界面图

2.3 数据处理

1)数据归一化

对样本数据进行归一化操作,主要是为了消除数据间量纲影响,让后期实验结果分析的指标数据处于同一数量。归一化公式如式(6)所示。

$$M'(t) = \frac{2(M(t) - M_{\min})}{M_{\max} - M_{\min}} + 1 \quad (6)$$

其中, M_{\max} 、 M_{\min} 分别为流量数据的最大值和最小值。

2)特征点提取

特征点提取的算法很多,如阈值法、极值法、微分法等,本文主要采用的是差分阈值法,对脉搏波信号进行特征点的提取。差分阈值法^[25]的基本原理是:进行一阶微分运算,从得到的信号中选取过零点,在每个周期中选取一阶微分信号最大幅点前最接近的过零点,其对应的就是脉搏波信号的起点。提取算法如式(7)所示。

$$\begin{aligned} &Diff(j) < 0 \\ &Diff(k) > 0 \end{aligned} \quad (7)$$

脉搏波的峰值点提取方式如式(8)所示。

$$\begin{aligned} &Diff(j) > 0 \\ &Diff(k) < 0 \end{aligned} \quad (8)$$

脉搏波的峰值点是 j 和 k 之间最大的振幅点。其中 j 和 k 的确定如式(9)所示。

$$Diff(index - 1) \times Diff(index + 1) \leqslant 0 \quad (9)$$

令 $j = index - 5, k = index + 5$, 在信号周期内调整 j 和 k 值。

根据条件对所得点进行筛选,标记结果如图 5 所示。

由图 5 可以看出,利用差分阈值法对 MIMIC 数据库的脉搏波进行了处理,提取了起始点和峰值点这两个特征点。

根据这两个特征点,转换成新的 5 个特征加入数据集:峰值时间 T_1 、谷值时间 T_2 、峰值高度 h_1 、谷值高度 h_2 、 K 值。 K 值可以反映脉搏波的面积变化和人体的一些生理因素。定义如式(10)所示。

$$K = \frac{P_m - P_d}{P_s - P_d} \quad (10)$$

其中, P_m 为平均压, P_d 为舒张压, P_s 为收缩压。

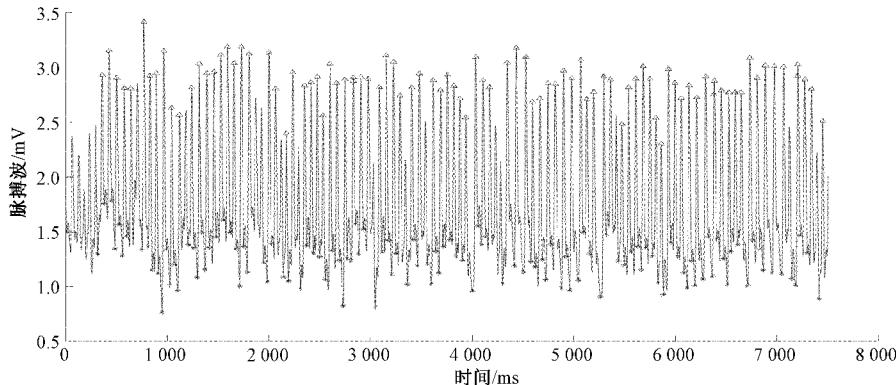


图 5 脉搏波特征点标记结果

3 基于长期递归卷积网络的血压测量

3.1 长期递归卷积网络模型结构

长期递归卷积网络通过结合 CNN 的权值可共享和 LSTM 的记忆特征^[26]来更好地处理脉搏波数据和血压数据。长期递归卷积网络血压测量模型的过程可以描述如下。

步骤 1: 对原始脉搏波数据和血压数据进行归一化处理。

步骤 2: 处理后数据作为 CNN 网络的输入值, 将时间序列的高维特征提取出来。

步骤 3: 将上一层输出数据输入到 LSTM 层, 对上一层所提取的高维特征进行测量。

步骤 4: 进入全连接层, 进行反归一化处理, 得到最终的测量值。

模型结构如图 6 所示。

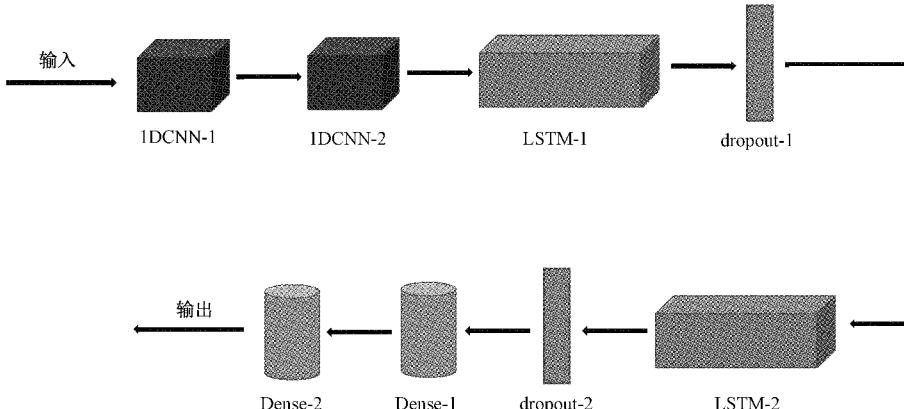


图 6 长期递归卷积网络模型结构框架图

其中, 主要采用了两层卷积(conv1D)、两层 LSTM, 每层 LSTM 用 dropout 防止过拟合, 两层全连接层, 最后一层全连接测量结果值。此外, 本次实验的激励函数选择了 ReLU 函数。

3.2 训练过程

利用损失函数 LOSS 计算损失值, 定义为 ABP 的 MSE 值, 且损失函数如式(11)所示。

$$LOSS = \frac{1}{n} \sum_{i=1}^n (ABP_{xi} - ABP_{yi})^2 \quad (11)$$

其中, ABP_{xi} 测量值, ABP_{yi} 为目标值, n 为样本数量。

学习率在本实验中设置为 0.001, 将 Adam 优化算法用于反向传播的过程, 训练过程的迭代次数 epoch 设置为 200。为了减轻过拟合现象, 神经元的丢弃算法 dropout 设为 0.2。

3.3 实验与结果讨论

本文主要是采用了神经网络中的 LSTM、长期递归卷积网络这两个模型对光电容积脉搏波进行血压的测量, 主要分为 3 个实验: 实验 1 是 PPG 和 ABP 归一化操作后的数据输入 LSTM 网络, 计算 loss 值, 再进行反归一化得到测量值; 实验 2 是对 PPG 和 ABP 信号进行处理, 输入长期递归卷积网络模型测量; 实验 3 则是 PPG 信号差分阈值处理, 将特征归一化后输入长期递归卷积网络模型, 与归一化后真实的 ABP 计算 loss 值, 训练权重, 保存模型。再将测试集的特征输入模型, 得到测量结果, 反归一化后并与真实 ABP 比较。

1) 实验数据

此次实验的数据库主要由 039、041、055、211、216、219、221、224、225、230、476、480、484、485 共 14 个标签的血压数据和光电容积脉搏数据组成, 每个标签只取了

5 000 组数据,共 70 000 组血压和脉搏数据可以用作实验,数据量达到了本实验的要求。

实验对比的数据用了 039 号标签的 5 000 个 PLETH、ABP(动脉血压)数字信号。其中 PLETH 数据的 20% 作为测试集,80% 作为训练集。在初次训练时,验证集的数据主要来自于训练集数据中的 10%,将训练的最好模型进行保存,后续再用完整的训练集数据进行训练。

2)评价指标

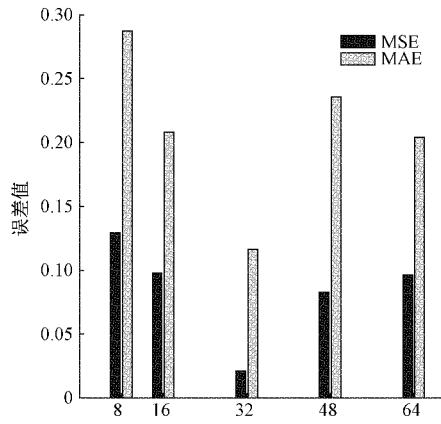
评价指标就是用来评估血压测量模型有效性的指标。为了判断测量的准确度,可以利用一些指标来表示测量的准确率。本文主要选取了 3 种评价指标,具体定义如下。

(1)均方误差(mean square error, MSE),是测量值与真实值之差的平方和的平均值,公式如式(12)所示。

$$MSE = \frac{1}{T} \sum_{t=1}^T (Y^t - \hat{Y}^t)^2 \quad (12)$$

其中, Y^t 表示真实值, \hat{Y}^t 表示预测值。

(2)平均绝对误差(mean absolute error, MAE),是将



(a) 滑窗长度评价指标MSE、MAE实验图

测量误差取绝对平均值后计算的平均误差,公式如式(13)所示。

$$MAE = \frac{1}{T} \sum_{t=1}^T |Y^t - \hat{Y}^t| \quad (13)$$

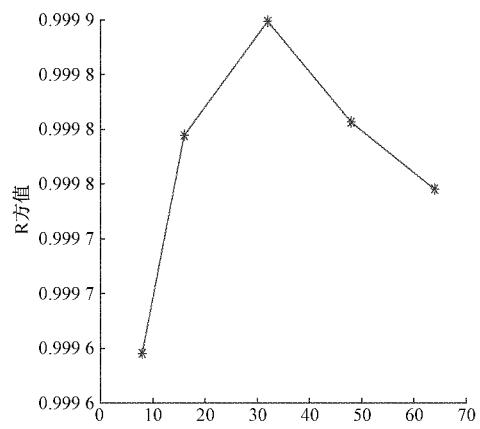
(3)确定性相关系数(R^2 score),是一种衡量模型测量未知样本效果的指数,数值越高越好,计算公式如式(14)所示。

$$R^2 = 1 - \frac{\sum_{t=1}^T (Y^t - \hat{Y}^t)^2}{\sum_{t=1}^T (\bar{Y}^t - \hat{Y}^t)^2} \quad (14)$$

其中, \bar{Y}^t 表示原始数据均值。

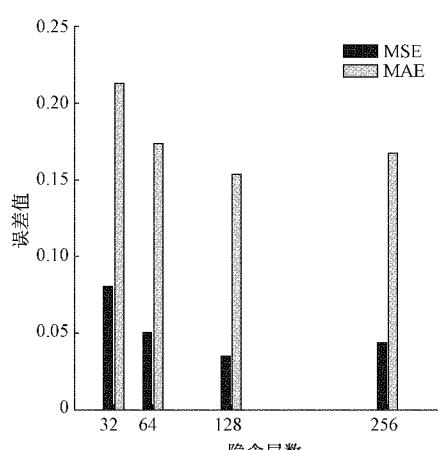
3)LSTM 网络的参数选择

针对不同的参数进行选择,评价指标依旧使用均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)和确定性相关系数(R^2 score)。具体的实验结果如图 7 和 8 所示。

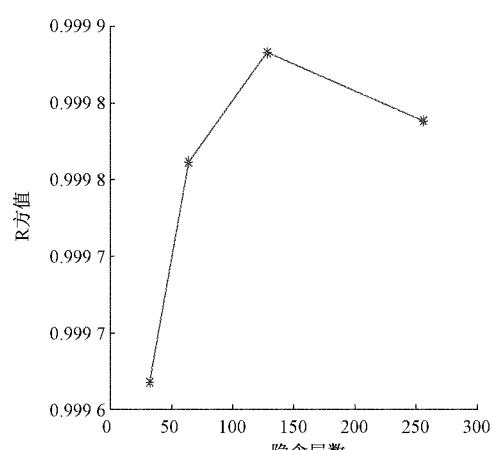


(b) 滑窗长度评价指标 R^2 实验图

图 7 滑窗长度评价指标图



(a) 隐含层评价指标MSE、MAE实验图



(b) 隐含层评价指标实验图

图 8 隐含层评价指标图

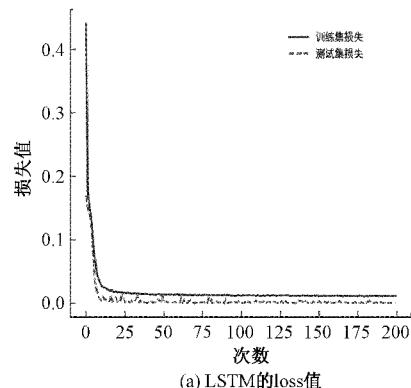
根据上述实验结果,本文选择 LSTM 层的隐含层数量为 128 层,理论上滑窗的长度越长,感受野越大,每次获取的特征也会更多,但是长的滑窗会导致模型参数和计算难度增加,因此会影响测量精度,因此滑动窗口的长度为 32。

4) 实验结果与分析

将原始 PPG 信号直接输入模型传统的 LSTM 模型和长期递归卷积网络模型进行实验对比,再将阈值处理后得到的特征值输入长期递归卷积网络模型进行实验,分析各个模型对血压检测的精确度是否得到提升。具体实验结果的数据如表 1 所示。

表 1 实验结果

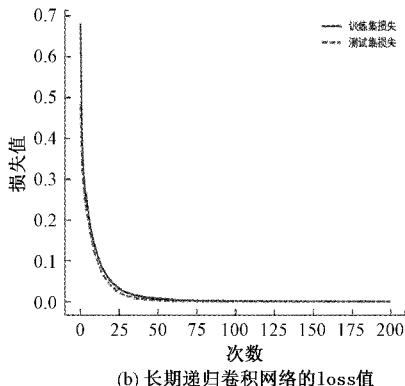
| 模型 | MSE | MAE | R^2 |
|---------------|---------|---------|---------|
| LSTM | 0.634 2 | 0.653 0 | 0.997 0 |
| 长期递归卷积网络 | 0.169 6 | 0.287 3 | 0.999 2 |
| 差分阈值+长期递归卷积网络 | 0.021 4 | 0.116 | 0.999 9 |



(a) LSTM 的 loss 值

每个模型的最终结果是将分别训练 5 次后的数据进行均分,分析表 1 可知,长期递归卷积网络模型与传统的 LSTM 模型相比,MSE 值低了 0.464 6,MAE 值低了 0.365 7, R^2 值高了 0.002 2,则长期递归卷积网络模型效果较好;差分阈值+长期递归卷积网络模型与长期递归卷积网络模型相比,可知 MSE 值低了 0.148 2,MAE 值低了 0.171 1, R^2 值高了 0.000 7,所以人工提取的特征参数作为网络的输入能够更加精准的完成血压值测量。

如图 9~13 所示,在训练集损失和测试集损失方面,长期递归卷积网络模型比传统的 LSTM 模型效果要好。另外,在血压测量方面,两种模型的拟合效果整体都挺好。只是在活动较为频繁的部位,可以很清晰地看出长期递归卷积网络模型的前后波形更,加的拟合,测量的更加精准。此外,将人工提取参数作为模型的输入,也提高了血压测量的精确度。



(b) 长期递归卷积网络的 loss 值

图 9 LSTM 和长期递归卷积网络模型的 loss 值

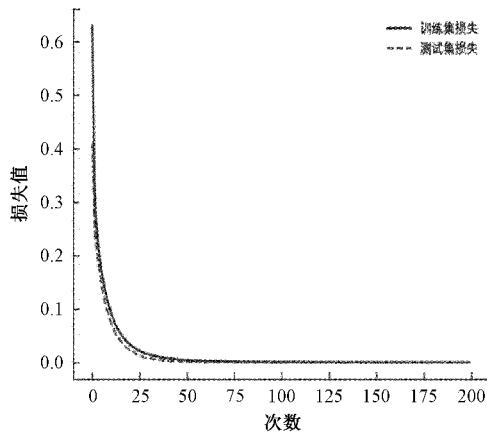


图 10 差分阈值+长期递归卷积网络的 loss 值

根据上述实验结果,最终以差分阈值+长期递归卷积网络为实验模型,整体数据库的实验结果如表 2 所示。分析表 2 可知,MSE 的平均值是 0.163 61,数值相对较小,意味着实验测量出的血压值和真实值之间的误差就越小,整体的误差平均值也越来越低,测量结果较好。MAE 的平

表 2 其他标签实验结果

| 标签 | MSE | MAE | R^2 |
|-----|----------|----------|----------|
| 039 | 0.021 4 | 0.116 2 | 0.999 9 |
| 041 | 0.318 5 | 0.378 6 | 0.998 5 |
| 055 | 0.080 6 | 0.205 7 | 0.999 4 |
| 211 | 0.117 5 | 0.205 2 | 0.999 5 |
| 216 | 0.309 0 | 0.341 6 | 0.998 8 |
| 219 | 0.246 9 | 0.199 9 | 0.999 2 |
| 221 | 0.119 3 | 0.302 5 | 0.999 6 |
| 224 | 0.107 6 | 0.252 3 | 0.999 6 |
| 225 | 0.101 7 | 0.267 9 | 0.999 8 |
| 230 | 0.089 8 | 0.250 7 | 0.999 8 |
| 476 | 0.146 7 | 0.323 4 | 0.999 6 |
| 480 | 0.310 4 | 0.328 3 | 0.998 3 |
| 484 | 0.167 7 | 0.139 3 | 0.999 5 |
| 485 | 0.153 4 | 0.194 0 | 0.999 5 |
| 平均值 | 0.163 61 | 0.250 40 | 0.999 35 |

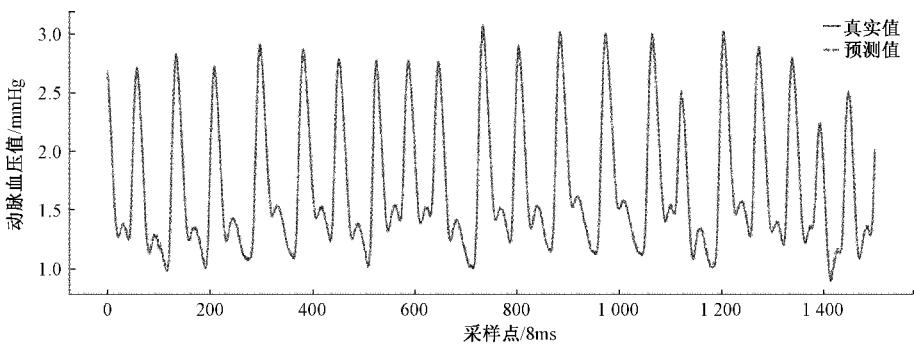


图 11 LSTM 的血压波形可视化

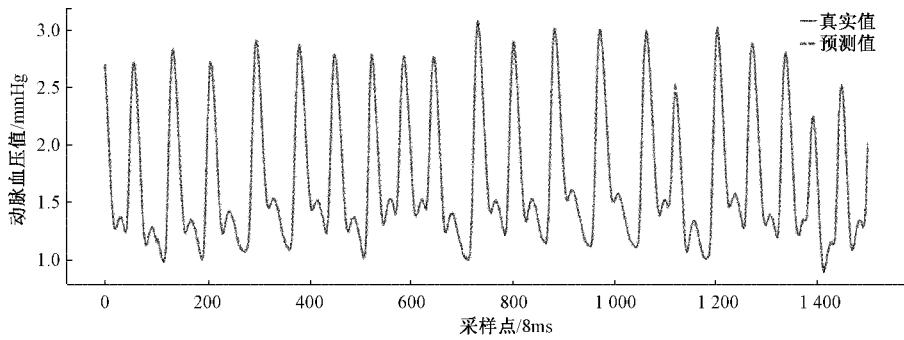


图 12 长期递归卷积网络的血压波形可视化

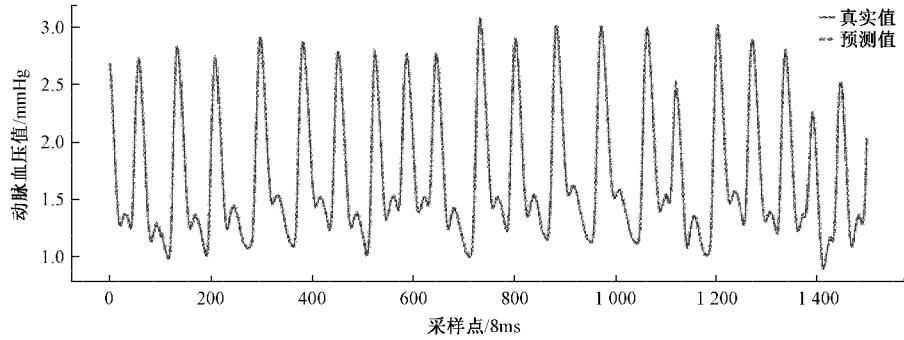


图 13 差分阈值 + 长期递归卷积网络的血压波形可视化

均值是 0.250 40, 说明了平均误差的平均值较低, 说明了检测出的血压精确度较高。 R^2 的平均值是 0.999 35, 表示了血压的测量值与真实值的一个拟合程度, 当值达到 1 时, 测量值与真实值完全相等, 没有误差存在, 本文数值更接近于 1, 说明模型较为理想。本文使用的测量方法效果良好, 模型的拟合度较高, 对血压检测的准确率较高。

4 结 论

鉴于高血压人群分布范围日益增大以及无创血压监测的迫切需求, 本文主要利用了长期递归卷积网络的方法完成了对连续血压测量模型的构建。此外, 还在 MIMIC 公共数据库上进行实验, 实现了无创、高精度的血压测量。但由于患者的信息参数不够完善, 缺少部分有价值的参数, 比如身高、体重、年龄等, 在未来的实验中, 可以将这些

背景信息特征添加到神经网络的输入中, 从而获得更加精确的结果。未来可以结合其他智能算法^[27-30] 来进一步提高血压测量的精度。

参 考 文 献

- [1] 《中国心血管健康与疾病报告 2020》要点解读[J]. 中国心血管杂志, 2021, 26(3): 209-218.
- [2] RONG M, LI K. A multi-type features fusion neural network for blood pressure prediction based on photoplethysmography [J]. Biomedical Signal Processing and Control, 2021, 68(1), DOI: 10.1016/j.bspc.2021.102772.
- [3] 吴海燕, 季忠, 李孟泽. 基于脉搏波的无创连续血压监测模型簇研究[J]. 仪器仪表学报, 2020, 41(7): 224-234.

- [4] 陈剑虹, 郭亚亚, 郑铱, 等. 基于光电容积脉搏波特征参数的血管弹性检测[J]. 电子测量与仪器学报, 2021, 35(3): 11-17.
- [5] 张畅, 陈辉, 郑秀娟. 基于优化脉搏波特征的无袖带血压检测方法[J]. 电子测量技术, 2021, 44(24): 1-7.
- [6] 杨应鹏, 陈晓. 基于蓝牙的可穿戴式脉搏波形采集系统设计[J]. 激光杂志, 2018, 39(6): 74-77.
- [7] 杨瑶, 陈晓. 基于神经网络的说话人识别实验设计[J]. 实验室研究与探索, 2020, 39(9): 38-41.
- [8] 沈千里, 陈晓, 支亚京, 等. 一种新的人脸图像去噪算法[J]. 传感器与微系统, 2015, 34(11): 133-136.
- [9] 沈千里, 陈晓. 一种新型目标图像去模糊方法[J]. 电视技术, 2016, 40(6): 17-21.
- [10] 郭妍, 陈晓, 任晓晔. 一种优化随机森林模型的室内定位方法[J]. 激光杂志, 2018, 39(10): 70-74.
- [11] 朱娟, 陈晓. 改进胶囊网络的有序重叠手写数字识别方法[J]. 激光杂志, 2019, 40(7): 43-46.
- [12] 徐畅, 陈晓, 季仟亿. 基于稀疏编码的 Shearlet 域图像去噪[J]. 激光杂志, 2017, 38(10): 96-100.
- [13] 李万万. 基于深度学习的脉搏波连续血压测量[D]. 济宁: 曲阜师范大学, 2017.
- [14] 王月猛. 基于 Elman 神经网络的无创连续血压测量方法研究[D]. 长春: 吉林大学, 2018.
- [15] GONG L, YU M, JIANG S, et al. Deep learning based prediction on greenhouse crop yield combined TCN and RNN[J]. Sensors, 2021, 21(13), DOI: 10.3390/s21134537.
- [16] 任晓晔, 陈晓, 郭妍. 基于 Fluent 和 LSTM 神经网络的超声波测风仪阴影效应补偿研究[J]. 计算机应用与软件, 2019, 36(7): 89-98.
- [17] SUCHETHA M, MADHUMITHA R, SORNA M M, et al. Sequential convolutional neural networks for classification of cognitive tasks from EEG signals[J]. Applied Soft Computing, 2021, DOI: 10.1016/j.asoc.2021.107664.
- [18] 石晨宇, 周春, 斯鸿, 等. 基于卷积神经网络的农作物病害识别研究[J]. 国外电子测量技术, 2021, 40(9): 93-99.
- [19] 孙超文, 陈晓. 基于多尺度特征融合反投影网络的图像超分辨率重建[J]. 自动化学报, 2021, 47(7): 1689-1700.
- [20] YANG S, MORGAN S P, CHO S Y, et al. Non-invasive cuff-less blood pressure machine learning algorithm using photoplethysmography and prior physiological data [J]. Blood Pressure Monitoring, 2021, DOI: 10.1097/MBP.0000000000000534.
- [21] HU Q, DENG X, WANG A, et al. A novel method for continuous blood pressure estimation based on a single-channel photoplethysmogram signal [J]. Physiological Measurement, 2020, 41(12): 1-8.
- [22] 陈晓, 张凯. 嵌入式自动气象站故障检测系统研究[J]. 电子测量技术, 2021, 44(23): 158-164.
- [23] 荣百川, 陈晓. 基于蓝牙的智能防摔监测系统设计[J]. 激光杂志, 2019, 40(7): 32-34.
- [24] 邢玉晶, 陈晓. 基于 TDC-GP22 的超声波测风仪设计[J]. 现代电子技术, 2018, 41(21): 128-131.
- [25] 袁春雨. 基于 GA-Elman 神经网络的无创连续血压测量方法的研究[D]. 长春: 吉林大学, 2019.
- [26] ALMUTAIRI H, HASSAN G M, DATTA A. Classification of obstructive sleep apnoea from single-lead ECG signals using convolutional neural and long short term memory networks[J]. Biomedical Signal Processing and Control, 2021, 69: 8-10.
- [27] 陈霞, 陈晓, 邹胜男. 基于正态检验的室内定位算法[J]. 激光杂志, 2017, 38(3): 41-45.
- [28] 邹胜男, 陈晓, 陈霞. 基于改进的 UKF 算法的室内测距定位[J]. 激光杂志, 2017, 38(4): 61-65.
- [29] 胡春杰, 陈晓, 陈霞. 基于改进广义 Arnold 映射的多混沌图像加密算法[J]. 包装工程, 2017, 38(3): 144-149.
- [30] 胡春杰, 陈晓, 郭银. 基于多混沌映射的光学图像加密算法[J]. 激光杂志, 2017, 38(1): 110-114.

作者简介

陈晓, 博士, 教授, 主要研究方向为信号与信息处理、图像处理、超声成像等。

E-mail: chenxiao@nuist.edu.cn

杨瑶, 硕士, 主要研究方向为智能信号处理。

E-mail: 1476514079@qq.com