

DOI:10.19651/j.cnki.emt.2210014

融合注意力机制的 BiLSTM 网络实现无创血压测量

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: 血压是人体的重要生理指标特征,血压的准确测量对心血管类疾病的诊断和治疗有重要意义。提出了基于注意力机制的双向长短记忆网络用于无创血压测量的方法。由于注意力机制可以根据特征的重要性来分配权重系数,所以方法将其引入到双向长短记忆网络中从脉搏波中计算出血压。试验结果表明引入注意力机制的双向长短记忆网络相较于双向长短记忆网络,MSE 值和 MAE 值都得到了大幅度的降低,分别降低了 18.29% 和 21.27%,R 方值提高了 0.17%。方法提高了无创血压测量的精度。

关键词: 血压测量;脉搏;双向长短记忆网络;注意力机制

中图分类号: TN911.7 文献标识码: A 国家标准学科分类代码: 52020

Noninvasive blood pressure measurement based on BiLSTM network with attention mechanism

Chen Xiao^{1,2} Yang Yao¹

(1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China;
2. Jiangsu 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 physiological index of human body. It can judge the cardiovascular function and heart condition of the body. Many diseases are closely related to blood pressure. Therefore, the correct determination of blood pressure is of great significance for the diagnosis and treatment of cardiovascular diseases. We proposed a noninvasive blood pressure measurement method based on BiLSTM network. Firstly, taking the BiLSTM network and the traditional LSTM as the experimental model, and comparing the output evaluation index coefficients, it is found that the BiLSTM network has a better effect on blood pressure measurement. Because the attention mechanism can assign weight coefficients from rows according to the importance of features, it is introduced into the BiLSTM network with good measurement effect for experiments. According to the results, it is found that compared with the original BiLSTM model, the MSE value and Mae value of the introduced attention mechanism model are greatly reduced by 18.29% and 21.27% respectively, and the R-square value is increased by 0.17%.

Keywords: blood pressure measurement;pulse;bidirectional long short memory network;attention mechanism

0 引言

社会的发展不仅提高了人们的生活环境质量,也使得日常的饮食变得丰富多元化起来。但是随之而来健康的问题就变得越来越突出。根据近几年来的调查统计数据,心血管疾病正危害着全球人民的公共健康。该疾病致死率较高,高血压则是导致该类疾病的主要原因^[1]。因此,早期预警监控对于后期的治疗有十分重要意义^[2],不仅可以提醒自己身体的健康状况,也可以避免就医不及时造成严重的

后果,方便了医生的病情查询和具体治疗方案的实施。

随着人们对血压测量的进一步探究,许多学者开展了应用脉搏信号^[3-6]进行连续血压测量的研究。随着智能算法^[7-14]的发展,一些学者开展了应用学习算法进行连续血压测量的工作。雷苏力提出了 BP 神经网络的学习模型^[11],实现血压的连续检测并可视化展现,但检测的误差较大。王月猛提出了利用 Elman 网络^[14]的记忆功能和时间特性,采用 BP 与 Elman 网络分别进行实验研究,结果显示 Elman 网络的整体检测效果优于 BP 神经网络。李帆提

出了基于 PPG 信号的长短记忆 (LSTM) 网络同步动脉血压测量方法^[15], 将 RNN 与 LSTM 作为实验的模型对象进行对比, 发现无论是在训练过程还是在血压测量的精度上, LSTM 网络都远超了传统的 RNN 网络。但 LSTM 网络是单向的结构^[16], 即时状态只能按照时间的序列从之前的信息中获取。在实际应用中, 对于信号的处理依赖于以前和未来两个方面的信息, 这样可以更加准确的获取信息。

基于以上分析, 用双向的长短期记忆 (BiLSTM) 网络通过两个方向来对信息进行处理, 分别是从左到右和从右到左这两个方向, 从而可以获得更加完整的序列特征。在长时间序列的短子序列中各个特征的重要程度存在差异性, 重要的特征往往包含着更多的信息量, 对结果的影响更大。因此, 在双向长短记忆网络中加入注意力机制, 可以更好的提升特征提取的能力, 实现高效获取更多重要信息的目的, 进而提升对血压测量的准确性。

1 实验数据

1.1 数据来源

在实验研究中, 主要是通过从 MIMIC 数据库中下载并建立本实验需要的数据库, 根据单路的 PPG 信号来进行实时血压的测量。为此需要建立一个符合本次实验要求的小型数据库, 其中每个小组的信号数据包括 PPG 信号和 ABP 信号。ABP 信号用于模型训练中和评判模型好坏的标准值。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。实验数据都来自于第一代 MIMIC 数据库中 mimicdb。mimicdb 中收录了 90 名 ICU 患者的真实数据, 可以通过登陆 PhysioBank ATM 在线查询, 也能够实现数据的下载。

MIMIC 数据库中数据的都是重症的监护室的病人的数据, 所以需要对数据筛选。在 Signals 选项中查找该标签是否有同一时间段内的 PPG 信号和血压信号, Length 选项上选择数据长度为 1 min, Toolbox 中选定数据的输出方式为将信号导出为 CSV, 然后进行下载。将下载好的数据进行人工筛选, 删除那些不需要的其它指标数据, 只留下需要的 PPG 信号和血压信号。此次实验的数据库主要是通过在 MIMIC 数据库中筛选出 13 条同时拥有光电容积脉搏波信号数据和血压信号数据的标签, 并进行下载存储, 建立 YY1 数据库, 每个便签的编号分别为 039、041、055、211、216、219、221、224、230、476、480、484、和 485, 且每个标签只取了 5 000 组数据, 共 65 000 组血压和脉搏数据用作实验。

1.2 数据处理

1) 归一化

归一化操作是为了消除数据间量纲影响, 让后面实验处理的数据指标处于同一数量。归一化公式如式(1)所示。经过归一化处理后的数据, 信号幅值都在 [0, 1] 之间。

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

其中, M_{\max}, M_{\min} 分别为数据的最大值和最小值。

2) 特征参数

特征点提取的算法很多, 如阈值法、极值法、微分法等。微分法的整体比较简单, 是对信号进行求导, 根据过零点来检测出拐点, 再利用拐点来获取脉搏波特征点。算法整体思路简单但局限性大, 求导信号之后往往会出现较多的极值点, 部分极值点不是真实的而是噪声干扰造成, 所以微分法不太能够排除噪声的干扰。差分阈值法的基本原理是: 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。实验时选用的是差分阈值法对脉搏波信号进行特征点的识别, 提取了起始点 a、峰值点 b 和波谷点 c 这三个特征点^[17]。

一般来讲, 脉搏波的特征参数可以分为时域特征和频域特征, 也可以分为幅度特征、时间特征和面积特征。幅度特征通常包括主波高度、降中峡高度、重搏波高度等。时间特征通常包括主波上升时间和脉搏波周期等^[18]。面积特征则通常包括脉搏波面积、收缩期面积占比和 K 值等。K 值可以反应脉搏波的面积变化和人体的一些生理因素。将提出来的两个特征点转换成 2 个时间特征 T_1 和 T_2 、2 个幅度特征 h_1 和 h_2 以及一个面积特征参数 K 。

2 相关基础知识

2.1 BiLSTM

LSTM 网络是单向结构, BiLSTM 网络则是由两个不同方向的 LSTM 组成^[19]。通过两个方向的 LSTM 对信号进行特征提取操作, 从而实现更加完整的提取信号特征。BiLSTM 网络的当前状态 \tilde{h}_t 是由两个不同方向的隐藏状态 \tilde{h}_t 和 \tilde{h}_{t-1} 共同决定的^[19], 如式(2)~(4)所示。

$$\tilde{h}_t = \text{LSTM}(x_t, \tilde{h}_{t-1}) \quad (2)$$

$$\hat{h}_t = \text{LSTM}(x_t, \hat{h}_{t-1}) \quad (3)$$

$$\tilde{h}_t = \lambda \tilde{h}_t + \beta \hat{h}_t + b_t \quad (4)$$

式中: x_t 为 t 时的输入, λ 为 t 时 BiLSTM 网络前向隐藏层的权重, β 为 t 时刻 BiLSTM 网络的后向隐藏层的权重, b_t 则是 t 时刻 BiLSTM 网络隐藏层所对应的偏置。

2.2 注意力机制

注意力机制模型最初是用于机器翻译领域, 无论在神经网络的领域还是在人工智能领域, 该模型都有关键的地位并成为了重要的组成部分^[20]。注意力机制在自然语言信息处理、统计学习、语音和计算机等领域也都有着大量的实际应用。它的原理主要是通过模拟人脑来对不同的行为产生出不一样的反映, 分辨行为的重要性, 从而进行注意力的加强与减弱, 对关键行为进行加强, 对非重要行为的进行减弱^[21]。因为在学习的过程中每个阶段的重要特征都有所不同, 所以对于重要的特征, 该机制会分配更多的权重; 对于非重要的特征, 该机制则会自动分配更少的权重^[20]。

在双向长短期记忆网络中,注意力机制主要是通过调整权重值来实现注意效果。

输入信号为 x_i, c_i 为编码后得到的信号, y_i 为输出信号, 具体的表达式如式(5)~(8)所示。

$$y_1 = f(c_1) \quad (5)$$

$$y_2 = f(c_2, y_1) \quad (6)$$

$$y_3 = f(c_3, y_1, y_2) \quad (7)$$

$$c_i = \sum_{j=1}^L a_{ij} h_j \quad (8)$$

式中: L 是序列的长度, i 为当前时刻, j 为元素序列号, a_{ij} 代表的是在 i 时刻第 j 个元素的注意力分配系数, h_j 则是整个序列中第 j 个元素的编码。

2.3 损失函数

为了评价方法的性能, 准确的反映模型测量值与真实值之间的误差, 更好的去提高模型的泛化能力, 采用损失函数 LOSS 来进行评估。ABP 的 MSE 值作为损失值, 如式(9)所示。

$$LOSS = \frac{1}{n} \sum_{i=1}^n (ABP_{xi} - ABP_{yi})^2 \quad (9)$$

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

2.4 评价指标

评价指标用来评估提出的血压测量方法有效性。为了判断提出的网络测量的准确度, 选取了均方误差、平均绝对误差和确定性相关系数这 3 种评价指标。

均方误差(mean square error, MSE)是通过网络模型检测出血压测量值与数据库中血压真实值之间差的平方和的平均值, 与标准差相比, 它反映了测量值与实际值之间的偏差而不是平均值之间的偏差。均方误差越小, 血压测算模型拟合的就越好。均方误差公式如式(10)所示。

$$MSE = \frac{1}{T} \sum_{t=1}^T (Y^t - \hat{Y}_t)^2 \quad (10)$$

其中, Y^t 表示真实值, \hat{Y}_t 表示测量值。

平均绝对误差(mean absolute error, MAE)是通过网络模型检测出血压测量值与数据库中血压真实值之间差的绝对值的平均值, 平均绝对误差越小, 血压模型拟合的就越好。计算公式如式(11)所示。

$$MAE = \frac{1}{T} \sum_{t=1}^T |Y^t - \hat{Y}_t| \quad (11)$$

确定性相关系数(R^2 score)是一种用来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(12)所示。

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

其中, \bar{Y}^t 表示原始数据均值。

3 基于注意力机制的 BiLSTM 网络

3.1 网络模型

为了提高血压测量的精确度, 通过将注意力机制引入到双向长短期记忆网络中, 利用 BiLSTM 神经网络的输出将左右向传播层与注意力层进行连接, 这样就可以根据注意力机制来实现权重的分配任务。具体网络结构如图 1 所示, 由输入层、BiLSTM 层、注意力机制层和输出层组成。该网络将 BiLSTM 神经网络的输出值 \vec{h}_t 作为注意力机制层的输入, 从而实现权重的分配。

注意力机制层的计算过程为:

$$\mathbf{E}_t = \tanh(\vec{V}_t \vec{h}_t + \vec{b}_t) \quad (13)$$

式中: \mathbf{E}_t 为双向长短期记忆网络输出值 \vec{h}_t 决定的能量值, \vec{V}_t 为 t 时刻时隐藏层 \vec{h}_t 的权重, \vec{b}_t 则为 t 时刻时隐藏层 \vec{h}_t 所对应的偏置。

$$u_t = \exp(\mathbf{E}_t^\top \mathbf{E}_a) / \sum_t \exp(\mathbf{E}_t^\top \mathbf{E}_a) \quad (14)$$

式中: u_t 为根据隐藏层状态决定的权重系数, \mathbf{E}_a 为随机初始注意力矩阵, 随着网络的学习不断的更新。式中, R_t 为注意力机制层的输出。

$$R_t = \sum_t u_t \vec{h}_t \quad (15)$$

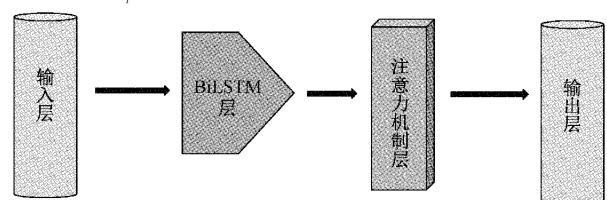


图 1 融合注意力机制的 BiLSTM 网络结构

3.2 实验设置

实验数据用前文介绍的 MIMIC 数据集中下载的数据对提出的算法进行评估。把数据集中的数据经过差分阈值处理, 提取特征参数作为网络的输入。对比实验的数据采用的是 039 号的 PPG 信号数据和 ABP 数据, 训练集与测试集的比例为 8 : 2。实验中 LSTM 的单元个数选择了 128, 滑动窗口的长度选择了 32。训练过程中设置学习率为 0.001, 采用了 Adam 算法在反向传播的过程中进行优化, 迭代次数设置为 100, 激活函数使用 ReLU。用均方误差、平均绝对误差和确定性相关系数评价测量的结果。

3.3 BiLSTM 对比实验

BiLSTM 相较于 LSTM 能够更加充分的获得序列中特征的有效信息, 通过计算双向特征之间关联减少特征的丢失。为单独评估 BiLSTM 测量血压的准确度, 与单向的 LSTM 网络进行对比。实验结果如表 1 和图 2 所示。

根据表中数据可知, BiLSTM 网络的均方误差和平均绝对误差相比于单一的 LSTM 网络分别降低了 26.89% 和 11.12%, 而确定性相关系数的指标比 LSTM 网络指标高

表 1 039 号实验结果表

模型	MSE	MAE	R ²
LSTM	1.954 58	0.899 93	0.992 53
BiLSTM	1.428 93	0.799 89	0.993 84

了 0.13%, 说明 BiLSTM 网络测量的血压精度高于 LSTM 网络所测量的。根据图 2 中的 3 个评价指标系数的趋势可以发现 MSE 得到了大幅度的降低, MAE 值也出现了明显的降低, 折线图表示的 R 方值呈增长趋势。

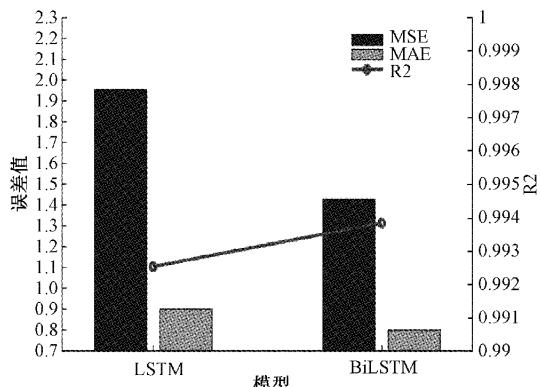


图 2 LSTM 和 BiLSTM 网络的实验结果

3.4 融入注意力机制的 BiLSTM 网络

虽然 BiLSTM 神经网络能够双向学习特征的相关性, 但不能够辨别特征信息的重要性。于是在 BiLSTM 神经网络中引入注意力机制结构, 通过根据不同特征的重要性来不断的更新权值, 从而提高血压测量的准确性。具体的操作如下:

1) 将经过差分阈值处理后得到的数据分别输入 BiLSTM 神经网络和注意力机制-BiLSTM 神经网络这两个模型中进行血压的检测。

2) 通过实验输出的损失值图, 来分析各个模型的训练情况, 且根据三个评价指标数来进一步分析各个模型对血压测量的状况。

3) 输出测量血压的波形图, 从而根据真实血压波形与测量血压波形的拟合度, 来分析模型的检测精度。

1) 收敛速度对比

注意力机制可以自动分配网络中的权重, 根据特征的重要性来给予关键性特征更多的权重, 给非关键性特征则分配的更少。将脉搏数据输入 BiLSTM 网络和注意力机制-BiLSTM 网络中, 通过训练的效果来比较收敛的快慢。BiLSTM 网络和注意力机制-BiLSTM 网络的具体训练结果如图 3 和 4 所示。

根据表中数据可知, BiLSTM 网络的均方误差和平均绝对误差相比于单一的 LSTM 网络分别降低了 26.89% 和 11.12%, 而确定性相关系数的指标比 LSTM 网络指标高了 0.13%, 说明 BiLSTM 网络测量的血压精度高于 LSTM 网络所测量的。根据图中的三个评价指标系数的趋势可以

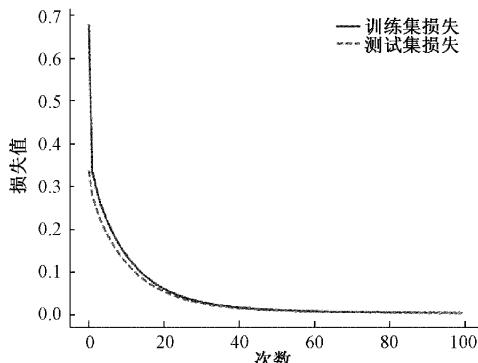


图 3 BiLSTM 网络的损失值

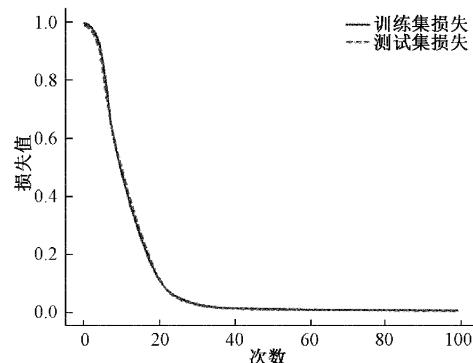


图 4 注意力机制-BiLSTM 网络的损失值

发现 MSE 得到了大幅度的降低, MAE 值也出现了明显的降低, 折线图表示的 R 方值呈增长趋势。

2) 连续测量血压效果

为了评价无创测量血压的效果, 用注意力机制 BiLSTM 对血压进行连续测量。通过输出的评价指标系数和血压波形图对测量效果进行展示, 其中 039 号标签基于注意力机制 BiLSTM 和 BiLSTM 效果如表 2 所示。每个模型的最终结果是将分别训练 5 次后的数据进行平均。

表 2 实验结果表

模型	MSE	MAE	R ²
BiLSTM	1.428 93	0.799 89	0.993 84
注意力机制-BiLSTM	1.167 54	0.629 75	0.995 54

根据表 2 中数据分析可知: 加入注意力机制的 BiLSTM 神经网络模型与 BiLSTM 神经网络模型相比, MSE 值低了 0.261 3, MAE 值低了 0.170 1, R² 值高了 0.001 7。由此可以看出注意力机制-BiLSTM 网络模型根据脉搏波进行血压测量的整体效果较好。图 5 也可以看出 BiLSTM 网络的平均绝对误差值和均方误差都是高于注意力机制-BiLSTM 网络的测试值, 且 R 方值呈递增趋势, 说明提出网络血压测量的精确度高。

根据图 6 和 7 可知, 在血压测量方面, 相比 BiLSTM, 引入注意力机制的 BiLSTM 的血压波形重合度更高, 真实

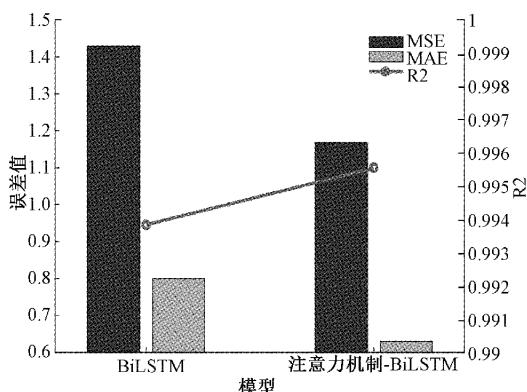


图 5 BiLSTM 和注意力机制-BiLSTM 网络的实验结果

值与测量值之间的误差更低,整体波形较为光滑。

3.5 鲁棒性

为了衡量网络的鲁棒性,我们把模型结构在 13 个标签上进行了测试。具体实验结果如表 3 所示。

总体来说,模型在 039、041、055、211、216、219、221、224、230、476、480、484、和 485 这 13 个标签上的测试结果基本都满足要求,且测试结果的误差平均值也在最优范围之内。根据表中数据可知,MSE 和 MAE 的平均值较低,R² 的平均值为 0.9991,当值达到 1 时,测量值与真实值没有误差。测试的数值接近于 1,说明该模型效果理想,网络对样本数据的整体测量效果较好。

根据图 8~10 可以看出注意力机制-BiLSTM 网络进

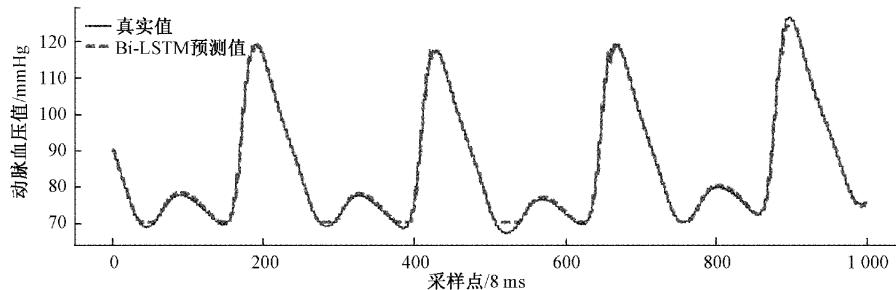


图 6 BiLSTM 网络得到的血压波形可视化

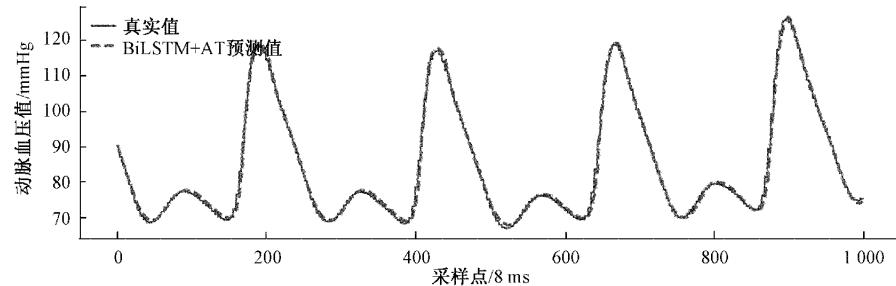


图 7 注意力机制-BiLSTM 网络得到的血压波形可视化

表 3 注意力机制-BiLSTM 网络在 13 个标签上测试结果

标签号	MSE	MAE	R2
039	1.1675	0.6298	0.9955
041	0.3071	0.3219	0.9989
055	0.0325	0.1306	0.9998
211	0.6381	0.5016	0.9996
216	0.3822	0.4187	0.9989
219	0.3411	0.3958	0.9992
221	0.4193	0.4608	0.9996
224	0.0684	0.2185	0.9997
230	0.0871	0.2227	0.9997
476	0.4084	0.5234	0.9994
480	0.2814	0.3178	0.9989
484	0.1234	0.2335	0.9994
485	0.2084	0.3215	0.9997
平均值	0.3435	0.3613	0.9991

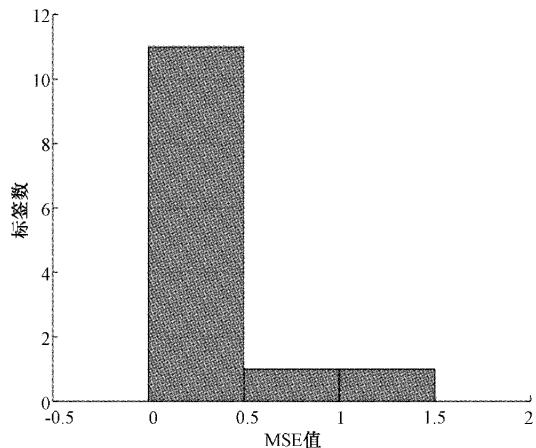


图 8 注意力机制-BiLSTM 网络 13 个标签 MSE 直方图

行实验的 13 个标签的均方误差结果主要集中在 0~0.5 区

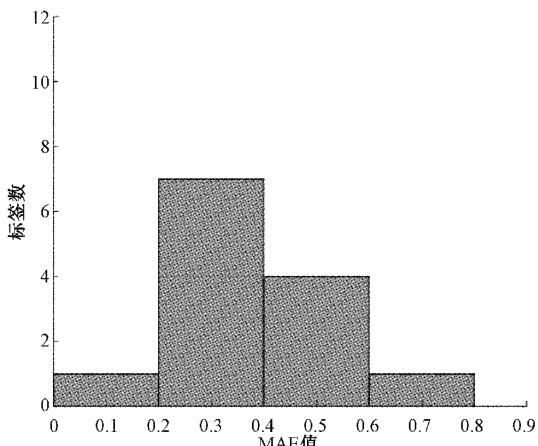
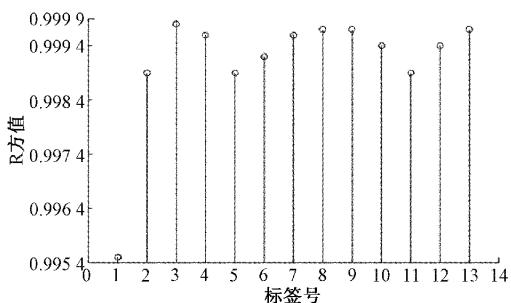


图9 注意力机制-BiLSTM网络13个标签 MAE 直方图

间内,平均绝对误差值有7个集中在0.2~0.4区间,则认为该网络结构测量的误差较小;且确定性相关系数值有8个标签集中在0.9994~0.9999之间,说明该网络测量样本的效果较好。

图10 注意力机制-BiLSTM网络13个标签的 R² 茎叶图

4 结 论

无创连续血压测量方法对血压相关疾病的预防有着十分重要的意义。本文把注意力机制引入BiLSTM网络实现从脉搏波无创连续测量血压。实验结果表明测量精度符合美国医疗仪器促进协会对于“血压测量的测量偏差小于5 mmHg”的金标准。在未来的研究中,可以通过获得更多的脉搏信号扩大实验的数据样本并对信号用算法去噪^[22-23]和分离^[24-25];在数据的特征点提取上,结合其它算法^[26-32]尝试识别更多的特征点,从而提高模型的泛化能力。

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] 张琪, 王太宏, 段小川. 基于压电薄膜的非接触式人体生理信号监测椅[J]. 压电与声光, 2020, 42(4): 515-518.
- [3] 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.
- [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] 陈晓, 杨瑶. 基于长期递归卷积网络的无创血压测量[J]. 电子测量技术, 2022, 45(4): 139-146.
- [6] 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.
- [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] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 李帆, 程云章, 边俊杰, 等. 基于PPG信号的LSTM网络同步动脉血压测量[J]. 软件导刊, 2020, 19(8): 44-48.
- [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] 李万万. 基于深度学习的脉搏波连续血压测量[D]. 曲阜: 曲阜师范大学, 2017.
- [18] 淳新益, 郑秀娟, 张畅, 等. 遗传算法优化BP神经网络的非接触式血压估计方法[J]. 电子测量与仪器学报, 2021, 35(7): 53-59.
- [19] 王义, 刘欣, 高德欣. 基于BiLSTM神经网络的锂电池SOH估计与RUL预测[J]. 电子测量技术, 2021, 44(20): 1-5.
- [20] 杨瑶. 基于深度学习的无创血压测量方法研究[D]. 南京: 南京信息工程大学, 2022.
- [21] 崔江波, 侯兴松. 基于注意力机制的YOLOv4输电线故障检测算法[J]. 国外电子测量技术, 2021, 40(7): 24-29.
- [22] 陈晓, 汪陈龙. 基于赛利斯模型和分数阶微分的兰姆波信号消噪[J]. 物理学报, 2014, 63(18): 1-9.
- [23] 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.

- [24] 陈晓,倪龙. 用分数阶微分实现时频重叠多模式兰姆波的模式分离[J]. 声学学报, 2020, 45(2): 205-214.
- [25] 倪龙,陈晓. 基于频散补偿和分数阶微分的多模式兰姆波分离[J]. 物理学报, 2018, 67(20): 204301-1-10.
- [26] 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.
- [27] 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.
- [28] 赵苏徽, 陈晓. 基于树莓派和云平台的智能灌溉系统[J]. 计算机系统应用, 2022, 31(4): 127-133.
- [29] 陈晓, 荆茹韵. 单图像超分辨率方法综述[J]. 电子测量技术, 2022, 45(9): 104-112.
- [30] 陈晓, 毛烨炳. ADS-B 技术在低空空域安全中的现状与展望[J]. 电子测量技术, 2022, 45(20): 61-67.
- [31] 任晓晔, 陈晓, 郭妍. 超声波测风换能器对风速的影响研究[J]. 电子测量技术, 2019, 42(7): 118-124.
- [32] 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.

作者简介

杨瑶,硕士,主要研究方向为智能信号处理。

E-mail:1476514079@qq.com

陈晓(通信作者),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