

DOI:10.19651/j.cnki.emt.2517860

# 基于 Conformer-LSTM 模型的连续无创血压 预测方法\*

陈欣<sup>1</sup> 刘立程<sup>1</sup> 王小林<sup>2</sup>

(1. 广东工业大学信息工程学院 广州 510006; 2. 中国科学院北京纳米能源与系统研究所 北京 101400)

**摘要:** 本研究提出了一种基于 Conformer-LSTM 模型的连续无创血压预测方法,模型包括卷积支路、Transformer 支路、两个多尺度交叉注意力模块、自适应空间特征融合模块和两层 LSTM。通过该方法,仅通过输入 PPG 信号即可预测对应的 ABP 波形,收缩压和舒张压通过预测的 ABP 波形得出。此外,该方法在较大的数据集中取得较小的预测误差,实验结果表明,本文提出的模型在 MIMIC 数据集中预测的 ABP 波形与实际波形的拟合程度较好,SBP 和 DBP 的预测误差分别为 $(3.68 \pm 5.60)$  mmHg 和 $(2.16 \pm 3.72)$  mmHg,该方法符合美国医疗仪器促进协会(AAMI)标准,并在英国高血压协会(BHS)标准中获得 A 级评价。

**关键词:** 血压预测;多尺度特征融合;Conformer;PPG 信号

**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

## Continuous non-invasive blood pressure prediction method based on Conformer-LSTM

Chen Xin<sup>1</sup> Liu Licheng<sup>1</sup> Wang Xiaolin<sup>2</sup>

(1. College of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China;

2. Institute of Nanoenergy and Nanosystem, Chinese Academy of Sciences, Beijing 101400, China)

**Abstract:** We propose a continuous, non-invasive blood pressure prediction method using the Conformer-LSTM model, which integrates a convolutional branch, Transformer branch, multi-scale cross-attention modules, adaptive spatial feature fusion, and a two-layer LSTM. This method predicts the ABP waveform from the PPG signal, from which systolic and diastolic blood pressures are derived. The model demonstrates minimal prediction error across a large dataset. Experimental results show a high correlation between the predicted ABP waveform from the MIMIC dataset and the actual waveform, with SBP and DBP prediction errors of  $(3.68 \pm 5.60)$  mmHg and  $(2.16 \pm 3.72)$  mmHg, respectively. The method complies with the American Association for the Advancement of Medical Devices (AAMI) standards and achieves an A-level rating according to the British Hypertension Society (BHS).

**Keywords:** blood pressure prediction; multi-scale feature fusion; Conformer; PPG signal

## 0 引言

心血管疾病(cardiovascular disease, CVD)对人类的生命健康构成了重大威胁,每年全球因 CVD 死亡的人数达到了 1 040 万<sup>[1]</sup>,CVD 的患病率和死亡率逐年上升。高血压作为最常见的慢性疾病,已被确认为心脑血管疾病的主要病因。借助实时监测与控制血压,能够大幅降低心血管并发症的发生几率以及死亡风险。

光体积描记术(photoplethysmography, PPG)是一种非

侵入性光学技术,随着心脏的跳动,血管中的血容量会脉动波动,产生 PPG 信号,提供有价值的心血管信息。此外,PPG 已显示出连续、无干扰的血压监测的前景<sup>[2]</sup>,因为研究表明这些信号包含与血压相关的因素,使 PPG 成为持续血压估计的可行选择。

针对 PPG 信号,人们开展了许多研究。文献[3]提出了一种 Transformer 预测 ABP 波形的模型,由编码器提取 PPG 信号的特征,并由线性层输出完整的 ABP 波形。Baker 等<sup>[4]</sup>在 CNN-LSTM 模型中结合了 PPG 和 ECG 信

收稿日期:2025-01-09

\* 基金项目:广东省教育厅自然科学基金(2019KZDZX1040)项目资助

号,收缩压的平均绝对误差为 4.41 mmHg,舒张压的平均误差为 2.91 mmHg。文献[5]提出了一种结合 SE 注意力机制的时域卷积网络(temporal convolutional network-SE, TCN-SE)模型,旨在使模型能够有效过滤掉杂质信息,专注于 PPG 信号中的细微特征。文献[6]在被试者不同的实验状态下(平躺、坐立、深呼吸等),使用支持向量回归和随机森林回归两种方法构建血压预测模型,测试集的预测结果符合 AAMI 标准。文献[7]提出了一种基于二维卷积的连续血压预测模型,将 PPG 信号与人体心电图(electrocardiogram, ECG)信号转换为图像,用二维卷积提取其空间特征,并通过剪枝操作将已经训练好的模型进行裁剪,达到降低模型计算量的目的。文献[8]通过分阶段构建多模态、多阶段的血压预测模型,采用数据增强的裁剪方法对训练集进行处理,并融合了 ECG 信号特征。文献[9]使用由多尺度卷积网络和长短期记忆网络构成的改进型长期循环卷积网络,以 PPG 和 ECG 数据作为输入,获得了优异的预测效果。文献[10]结合了 PPG 和 ECG 信号,利用贝叶斯优化算法建立 BO-XGBoost 血压预测模型,预测结果满足 AAMI 的标准。

但是上述研究方法存在一些不完善:1)由于 PPG 信号这一时间序列在不同的时间尺度上显示出不同的模式和波动,因此在进行时间序列预测时需要多尺度建模。CNN 擅长捕捉局部特征,但难以解决全局依赖性问题。Transformer 中串联的自注意力模块可以捕获信号远距离的特征依赖,但不幸的是会破坏局部特征细节。因此文献[3]仅通过编码器提取特征会导致模型不擅长捕捉信号的局部特征。同理,文献[4]仅通过卷积神经网络(convolutional neural networks, CNN)提取特征会导致模型不擅长捕捉信号的全局特征。2)文献[5]收缩压的预测精度还有待提高,并需降低数据噪声对结果的影响。3)文献[6]由于采用人工提取特征的方法,且人群具有多样性,特征提取的准确性难以保持稳定,因此该方法存在一定局限性。4)文献[7-10]引入了其他输入信号如 ECG,增加了模型的复杂度。

针对上述研究方法的不完善之处,本文将一种提出基于 Conformer-LSTM 模型的连续无创血压预测方法,较上述文献中的研究方法进行如下的改善:1)将 Conformer 模型首次作为血压预测模型的特征提取模块,它能有效地提取信号局部特征和全局特征;2)此方法仅利用单通道 PPG 信号预测 ABP 波形,并通过 ABP 波形推算出 SBP、DBP 等血压参数;3)此方法不需要人工提取特征且能够有效地降低收缩压的误差,提高预测精度。

## 1 Conformer-LSTM 模型的基本理论分析

### 1.1 局部特征与全局特征

PPG 信号是反映心脏活动和血管健康的重要时间序列。现实世界的时间序列在不同的时间尺度上显示出不同

的模式和波动。这种可变性要求在时间序列预测中进行多尺度建模,以捕捉不同尺度的时间特征。在分析时间序列时,时间距离的概念变得至关重要。时间距离是指时间依赖性的显式建模和时间步长之间距离的测量。在图 1 中,实线箭头表示相邻时间步长之间的关系,代表局部特征,而虚线箭头则模拟长期依赖关系,代表全局特征<sup>[11]</sup>。

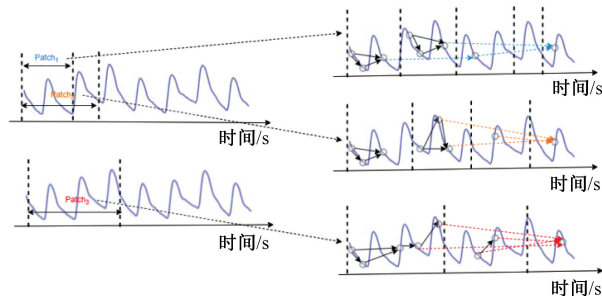


图 1 局部特征和全局特征

Fig. 1 Local and global features

### 1.2 Conformer 模型

Conformer 架构<sup>[12]</sup>将基于 CNN 的局部特征提取与基于 Transformer 的全局特征相结合,以增强表示学习。通过有效整合局部和全局特征,Conformer 网络为未来研究提供了有前景的方向。然而,Conformer 模型在卷积支路中使用串行卷积块,这限制了模型提取多个尺度局部特征的能力。相比之下,采用并行卷积块可以让各支路独立提取不同尺度的特征,互不干扰。在 Conformer 模型中,FCU 模块实现了两条支路的信息融合,但该方案仅适用于串行卷积块的结构。

### 1.3 交叉注意力

交叉注意力通过计算注意力权重建立两个输入序列之间的联系,主要用于捕获输入间的依赖关系。它通过对齐模态,帮助模型捕捉跨模态的相互关系<sup>[13]</sup>。该机制有效融合 CNN 提取的局部特征和 Transformer 提取的全局特征,增强 PPG 信号中不同尺度的相关性和信息交互,从而帮助模型捕捉时间序列中的复杂信息。

### 1.4 改进后的 Conformer 模型

针对上述分析,本文对 Conformer 模型进行了以下改进:1)在卷积支路引入 SE-MSFE 模块,该模块并行 4 个不同卷积核大小的卷积块,赋予模型多个感受野,提取不同尺度的局部特征;2)去除 FCU 模块,采用两个多尺度交叉注意力模块(MSCA),融合两个支路的特征,并增强不同尺度特征间的信息交互。

## 2 实验数据与预处理方法

MIMIC 数据集是指麻省理工学院开发的公共多参数重症监护数据库<sup>[14]</sup>,该数据库存有重症监护室的生理数据,包含 PPG 和 ABP 信号,采样率达 125 Hz。为构建符合要求的数据集,对数据进行了筛选。先是剔除了质量不佳

以及时长过短的样本,从中选取了 1 434 名受试者约 135 h 的数据。每个数据片段的时长设置为 4.992 s(即 624 个采样点),这个时长可以在极低心率情况下稳定计算 SBP、DBP 等血压参数。经过筛选处理后,最终获得了 97 000 组数据,血压值分布如图 2 所示。最后,按照 7 : 1 : 2 的比例,随机将数据集分为训练集、验证集和测试集。




图 2 血压值分布

Fig. 2 Blood pressure value distribution

PPG 信号易受噪声(例如基线漂移和电力线干扰)影响的弱电信号。上述噪声干扰将改变信号的形状,因此在分析之前应对信号进行滤波和降噪。在本研究中,PPG 信号使用四阶巴特沃斯带通滤波器进行滤波。由于基线漂移和电力线干扰在频谱上分别表示为低频和高频分量,因此带通滤波器的截止频率设置为 $[0.5, 20]$ Hz。此外,PPG 信号的直流分量包含了平均血容量的信息<sup>[15]</sup>,仅使用上述滤波器会丢失这些信息。因此,本文使用 0.05 Hz 截止频率的窄带低通滤波器对信号进行预处理,相加两个滤波器处理后的信号,得到去噪后的 PPG 信号。在输入模型之前,数据应被归一化,以使训练过程更加稳定,并提高收敛速度。在这项研究中,采用 Min-Max 方法使 PPG 信号的幅度落在 $[0, 1]$ 区间内。式(1)为归一化公式。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

其中,  $x_{\max}$ 、 $x_{\min}$  分别为信号的最大值和最小值。

### 3 血压预测模型

#### 3.1 Conformer-LSTM 模型

本文提出的 Conformer-LSTM 模型如图 3 所示。首先,将预处理后的 PPG 信号输入模型,模型由两条支路组成:Transformer 支路和 CNN 支路,在 Transformer 分支中,信号被嵌入到高维空间,并使用编码器提取特征。CNN 分支包括 SE-MSFE 和自注意力模块。然后,使用两个 MSCA 模块融合两条支路的特征,增强局部和全局特征之间的信息交互。最后,使用自适应特征融合模块将 4 个分支的特征拼接并融合,再用两个 LSTM 层对时间序列特征进行建模,并通过线性层生成完整的 ABP 波形。该方法

仅通过单路 PPG 信号预测 ABP 波形,进而计算 SBP、DBP 等血压参数,无需辅助信号或人工特征提取,可直接预测完整的 ABP 波形。预测的 ABP 波形不仅能获得 SBP 和 DBP,还能提供更全面的血压数据。以下将详细介绍模型各个模块。

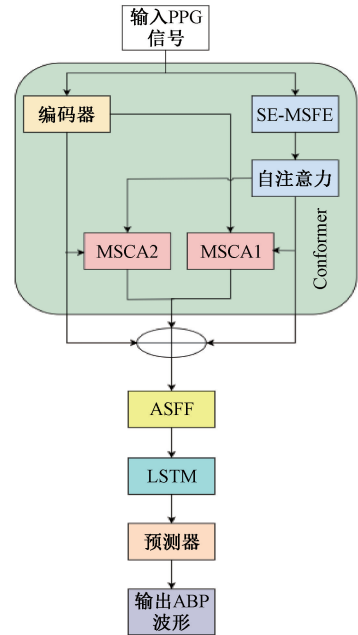


图 3 Conformer-LSTM 结构

Fig. 3 Conformer-LSTM structure

#### 1) 编码器

Transformer 模型<sup>[16]</sup>基于编码器-解码器架构。编码器由  $N$  个相同的子层组成,每个子层包含多头注意力机制和前馈神经网络。这些组件通过残差连接和层归一化来处理数据。本研究使用的编码器架构如图 4 所示。

#### 2) SE-MSFE 模块

单尺度特征提取依赖于固定大小的卷积核,这可能会导致特征提取不足,无法捕获深度复杂的信息。多尺度特征提取(multi-scale feature extraction, MSFE)模块通过使模型具有不同尺度的感受野来解决这一局限性。基于先前的研究<sup>[17]</sup>,本文设计了 SE-MSFE 模块,主要改进之处为:在拼接操作后结合了挤压和激励(squeeze and excitation, SE)模块和自适应空间特征融合(adaptively spatial feature fusion, ASFF)模块。

ASFF 模块通过挤压和扩展操作消除不同尺度特征在空间维度的冗余信息,从而提高了模型预测的准确性。另一方面,SE 模块能够通过以视觉方式对卷积特征通道之间的相互依赖性进行建模来进一步提高性能<sup>[18]</sup>。本研究中开发的 SE-MSFE 模块的框图如图 5 所示。

#### 3) 多尺度交叉注意力模块

为了融合模型捕获的多尺度特征,引入了两个多尺度交叉注意力模块(MSCA1 和 MSCA2)来加强这些特征之




图 4 编码器  
Fig. 4 Encoder




图 5 SE-MSFE 结构  
Fig. 5 SE-MSFE structure

间的信息交互。为了方便,这里使用全局-局部关系描述交叉注意力模块的结构,如图 6 所示。MSCA 通过计算全局和局部子序列的相关特征矩阵来实现信息融合,从而帮助模型挖掘更深层次的特征。交叉注意力机制能够捕捉序列中各点间的相关性,即注意力机制中的 Q 和 K。由于 PPG 信号中各点的相关性存在差异,这些差异可作为预测 ABP 波形的关键因素。

图 6 中 A 为全局特征的相关信息, B 为局部特征的相关信息。特征矩阵  $\mathbf{X}_A$  对  $\mathbf{X}_B$  的交叉注意力通过  $\mathbf{X}_A$  的查询矩阵  $\mathbf{Q}_A$  计算与  $\mathbf{X}_B$  相关性,此操作增强了两个特征矩阵间的信息交互,可以实现更好的信息融合。 $\mathbf{X}_A$  对  $\mathbf{X}_B$  的交叉注意力输出为:




图 6 MSCA 结构  
Fig. 6 MSCA structure

$$MSCA_{A \rightarrow B}(\mathbf{X}_A, \mathbf{X}_B) = \text{softmax}\left(\frac{\mathbf{Q}_A \mathbf{K}_B^T}{\sqrt{d_K}}\right) \mathbf{V}_B \quad (2)$$

其中,  $\mathbf{K}_B = \mathbf{X}_B \mathbf{W}_K^B$  和  $\mathbf{V}_B = \mathbf{X}_B \mathbf{W}_V^B$  分别为  $\mathbf{X}_B$  的键矩阵和值矩阵,  $\mathbf{W}_K^B$  和  $\mathbf{W}_V^B$  为  $\mathbf{X}_B$  到  $\mathbf{K}_B$  和  $\mathbf{V}_B$  的线性变换参数。最后的输出  $Y_{A,B}$  为全局和局部信息交互的交叉注意力与各自注意力的叠加:

$$Y_{A,B} = MSCA_1 + MSCA_2 + IMHA(\mathbf{X}_A) + IMHA(\mathbf{X}_B) \quad (3)$$

其中,  $Y_{A,B}$  包含了信号在全局和局部两个特征的强交互信息,输入到后面的模块中用于 ABP 波形的预测。

#### 4) 自适应空间特征融合模块

交叉注意力机制生成的特征融合了全局和局部的交互信息。为了充分利用自注意力和交叉注意力输出特征,需进行特征融合,以优化 ABP 波形预测。常见的融合方法包括拼接、求和和全局平均池化,但这些方法未考虑特征尺度差异,难以充分挖掘具有高区分度的信息。本文引入 ASFF 模块,旨在解决该问题,通过去除冗余信息来增强特征融合效果。对于不同模块输出的特征矩阵,首先在第一个维度上拼接,形成 ASFF 模块的输入  $\mathbf{Y}_{\alpha,\beta} = [\mathbf{F}^1, \mathbf{F}^2, \mathbf{F}^3, \mathbf{F}^4]$ ,  $\mathbf{F}^i$  表示第  $i$  个特征矩阵,这里表示有 4 个特征矩阵。 $\mathbf{Y}_{\alpha,\beta}$  首先经过全局平均池化操作得到特征向量  $\mathbf{Z} = [\mathbf{Z}^1, \mathbf{Z}^2, \mathbf{Z}^3, \mathbf{Z}^4]$ ,然后将特征向量  $\mathbf{Z}$  通过一层线性变换将  $\mathbf{Z}$  的特征维数压缩 1/4,接着,经过 ReLU 激活函数处理后,通过一层线性变换对特征向量进行膨胀,恢复到原始维度。最后,使用 Sigmoid 激活函数将特征值映射到  $[0, 1]$  区间,并通过学习得到的融合权重与原始矩阵相乘,从而获得最终融合的特征结果:

$$\mathbf{Z}_{cmps} = \text{ReLU}(\text{FC}(\mathbf{Z}, \mathbf{W}_{cmps})) \quad (4)$$

$$\mathbf{Z}_{exc} = \sigma(\text{FC}(\mathbf{Z}_{cmps}, \mathbf{W}_{exc})) \quad (5)$$



$$\hat{y} = \sum_{i=1}^4 Z_{exc}^i F^i \quad (6)$$

其中,FC(fully connected)为全连接层,  $W_{cmps}$  和  $W_{exc}$  为线性变换参数,  $ReLU(x) = \max(0, x)$  为非线性激活函数,  $W_{cmps}$  是可学习的,因此在反向传播过程中可动态调整参数,从而减少特征集合间的冗余信息,  $\sigma(x) = \frac{1}{1 + e^{-x}}$  为 Sigmoid 激活函数。

### 5) LSTM 神经网络

在对特征信息进行特征融合之后,采用两层 LSTM 对时间序列的特征进行建模。LSTM 单元的结构如图 7 所示。其中,第 1 层 LSTM 的输入为自适应特征融合模块的输出,神经元数量为 64;第 2 层 LSTM 的输入为前一层 LSTM 的输出,神经元数量为 64。在时间间隔  $t$  中,LSTM 单元的输入为  $y^t$ ,输出为  $h^t$ ,对于 LSTM 单元,它由一个输入门  $g^i$ ,一个遗忘门  $g^f$ ,一个输出门  $g^o$ ,一个映射函数  $m_t$  和一个记忆单元  $c_t$  组成。




图 7 LSTM 结构  
Fig. 7 LSTM structure

数学上,这些 LSTM 单元的组件中的每个向量可以计算如下:

$$\gamma = y_t \oplus h_{t-1} \quad (7)$$

$$g_t^i = \sigma(W^i \gamma + b^i) \quad (8)$$

$$g_t^f = \sigma(W^f \gamma + b^f) \quad (9)$$

$$g_t^o = \sigma(W^o \gamma + b^o) \quad (10)$$

$$m_t = \tanh(W^m \gamma + b^m) \quad (11)$$

$$c_t = g_t^f \odot c_{t-1} + g_t^i \odot m_t \quad (12)$$

$$h_t = g_t^o \odot \tanh(c_t) \quad (13)$$

$\sigma(\cdot)$  和  $\odot$  是 sigmoid 函数和元素乘法。 $W^i, W^f, W^o$  和  $W^m$  为加权矩阵,  $b^i, b^f, b^o$  和  $b^m$  为偏置向量,这些参数是在训练过程中学习的。3 个门有各自的权重,然后每个 LSTM 单元像一个状态机一样工作。因此,LSTM 网络可以很好地处理时间序列问题。

### 6) 预测器

本模型的预测器是一个线性层,主要作用是将各模块提取的特征转换为动脉血压波形的子序列。获取子序列后,通过拼接它们可以重建完整的动脉血压波形。

## 3.2 模型的参数设置

信号经过预处理后,624 个采样点的 PPG 信号经过分段处理,形成  $8 \times 78$  大小的 PPG 信号作为模型输入。编码器部分的输入线性层包含 128 个神经元,编码器由 4 层组成,每层具有 2 个注意力头。两个线性层组成前馈网络,每层分别具有 1 024 个和 128 个神经元。Dropout 层以 0.1 的概率随机丢弃神经元,激活函数采用 ReLU,输出线性层包含 78 个神经元。

## 4 实验结果与分析

### 4.1 实验设置

实验在 NVIDIA RTX 3090 GPU 上进行,使用基于 cuda 11.1、pytorch 1.10 和 python 3.8 的软件平台。每次迭代的批大小设置为 256。使用 Adam 优化器,初始学习率设置为 0.001,损失函数使用均方误差 (mean-square error, MSE)。此外,设置了 200 个迭代周期,每轮后通过验证集计算损失值 (Loss) 和平均绝对误差 (mean absolute error, MAE)。若当前 MAE 低于历史最小值,则保存模型并更新最小 MAE。Loss 用于动态调整学习率,防止过拟合。如果 Loss 在连续 8 轮未下降,学习率将减少至当前值的 1/4;若 15 轮内 Loss 未降低,则停止训练。

### 4.2 评价指标及实验结果分析

本文构建的模型将 PPG 信号转化为 ABP 信号,并计算 SBP、DBP 等参数。为直观展示预测的 ABP 波形的质量,比较了输入的 PPG 信号、模型预测的 ABP 与真实 ABP 波形,具体如图 8 所示。结果表明,Conformer-LSTM 能够精准地预测 ABP 波形。虽然 PPG 信号与真实 ABP 波形存在相位滞后,但 Conformer-LSTM 仍能有效客服这一问题,避免手动校正。




图 8 模型预测结果可视化

Fig. 8 Visualization of model predictions

为评估模型的预测精度,采用 MAE 和标准差 (standard deviation, STD) 作为指标。此外,还根据英国高

血压协会(British Hypertension Society, BHS)和美国医疗器械发展协会( Association for the Advancement of Medical Instrumentation, AAMI)的血压测量仪器标准,以及 Bland-Altman 分析法对实验结果进行了评估。


1) MAE 和 STD

MAE 和 STD 计算公式为:

$$MAE = \frac{1}{m} \sum_{i=0}^m |y'_i - y_i| \quad (14)$$

$$STD = \sqrt{\frac{1}{m-1} \sum_{i=0}^m (e_i - \bar{e}_i)^2}, e_i = y'_i - y_i \quad (15)$$

在测试集上,模型预测的 ABP 波形误差为(3.78 ± 5.68)mmHg,通过该波形计算得到的 SBP 误差为(3.68 ±




(a) 预测SBP的误差分布  
(a) Predict the error distribution of SBP

5.60)mmHg, DBP 误差为(2.16 ± 3.72)mmHg。

2) BHS 标准

由于 MAE 和 STD 容易受到异常值的影响,英国高血压学会(BHS)设计了一种替代方案,通过计算预测值的绝对误差低于 5、10 和 15 mmHg 各阈值的百分比,将精度分为 A、B、C 3 个等级。若精度为 A 或 B 级,则符合临床使用要求。

预测的 SBP 和 DBP 误差分布如图 9(a)和(b)所示,接近高斯分布。通过计算误差的绝对值低于 5、10 和 15 mmHg 的样本比例,并与 BHS 标准对比,结果如表 1 所示。采用的 Conformer-LSTM 模型对 SBP 和 DBP 的预测均达到了 A 级精度。



(b) 预测DBP的误差分布  
(b) Predict the error distribution of DBP

图 9 SBP 和 DBP 误差分布

Fig. 9 SBP and DBP error distribution

表 1 BHS 标准与实验结果

Table 1 BHS standards and experimental results %

累计误差		<5mmHg	<10mmHg	<15mmHg
BHS 标准	A 级	60.0	85.0	95.0
	B 级	50.0	75.0	90.0
	C 级	40.0	65.0	85.0
本文结果	SBP	77.3	93.9	98.0
	DBP	91.9	97.8	99.2

3) AAMI 标准

医疗器械进步协会(AAMI)已经制定了国际公认的血压误差标准。预测的收缩压和舒张压的平均误差应 <5 mmHg,标准偏差应 <8 mmHg。本文在 AAMI 标准下的结果如表 2 所示,模型预测的 SBP 和 DBP 均符合该标准。

4) Bland-Altman

Bland-Altman 图是评估两个连续变量度量一致性的常用方法。用于比较的两种测量方法通常包括一种需要研究的新方法和一种公认的标准方法。SBP 和 DBP 的结果分别展示在图 10(a)和(b)中。图 10 中显示,大部分

SBP 和 DBP 值位于 95% 置信区间内,表明 Conformer-LSTM 模型与动脉内测量结果具有较好的预测一致性。

表 2 AAMI 标准与本文结果

Table 2 AAMI standards and experimental results

评价指标	ME/mmHg	STD/mmHg	受试者人数
AAMI 标准	<5mmHg	<8mmHg	>85
本文结果	SBP	3.68	5.60
	DBP	2.16	3.72

5) 相关系数

相关系数是衡量变量之间关系强度和紧密程度的统计指标。图 11(a)、(b)给出了收缩压与舒张压预测值与真实值的回归图,收缩压的相关系数约为 0.95,舒张压的相关系数约为 0.97,当相关系数在区间[0.8, 1.0]内,表明两个变量的相关程度为极强相关,因此可以说明本模型的血压预测值与真实值趋势一致,相关性显著。

4.3 消融实验

本文基于 Conformer 模型,提出了一种改进的 Conformer-LSTM 模型。具体而言,采用 Conformer 作为特征提取模块,并进行了以下改进:在卷积支路引入 SE-




图 10 Bland-Altman 分析  
Fig. 10 Bland-Altman analysis




图 11 血压预测的回归图  
Fig. 11 Regression plot of blood pressure prediction

MSFE 模块,加入自注意力机制,并增加两个多尺度交叉注意力(MSCA)模块,以增强不同尺度特征间的信息交互。为了验证改进的有效性,本文进行了消融实验,结果如表 3 所示,其中“√”表示采用了改进策略。实验结果表明,基准模型 Conformer-LSTM 的收缩压 MAE 为 5.95 mmHg,舒张压 MAE 为 3.23 mmHg。在加入 SE-MSFE 模块后,收缩压和舒张压的预测误差分别降低了 0.47 mmHg 和 0.83 mmHg,性能显著提升。进一步加入自注意力模块后,收缩压和舒张压的误差分别减少了 0.20 和 0.07 mmHg。接着,加入 MSCA1 模块后,收缩压和舒张压的误差分别下降了 0.84 和 0.53 mmHg;加入 MSCA2 模块后,收缩压和舒张压误差分别减少了 0.77 和 0.50 mmHg。最终,合并所有改进模块后,模型性能进一步提升,收缩压和舒张压的 MAE 分别降至 3.68 和 2.16 mmHg,验证了提出方法的有效性。

#### 4.4 方法对比

表 4 比较了本文方法与其他无创血压估计方法的性能。对比模型的选取基于近三年内的最新研究成果,并尽量使用相同的数据集。为了保证公平性,所有方法均采用 MAE 作为评价指标。根据表中的数据,本文方法仅使用 PPG 信号作为输入,SBP 和 DBP 的 MAE 均小于其他方法。结合 PPG 和 ECG 信号的模型通过引入更多的生理信息,提升了准确性。然而,这种方法存在一定的局限性,如需要两种传感器,难以在智能手机等移动设备上实现,因为现有硬件无法进一步修改;同时,信号对齐也较为复杂。尽管本文提出的网络模型较为复杂,但仅使用 PPG 信号作为输入,在较大数据样本中仍能取得较小的 MAE 值,表现出较好的准确性。总体而言,本研究利用易于获取的 PPG 信号,在大数据集上实现了较为准确的血压预测,充分证明了 PPG 信号结合深度学习网络在连续血压预测中的潜力与可行性。

表 3 消融实验结果  
Table 3 Ablation test results

方法	基准模型	SE-MSFE	SA	MSCA <sub>1</sub>	MSCA <sub>2</sub>	SBP MAE	DBP MAE
Conformer-LSTM	√					5.95	3.23
Conformer-LSTM+SE-MSFE		√				5.12	2.76
Conformer-LSTM+SA			√			5.75	3.16
Conformer-LSTM+MSCA1				√		5.01	2.70
Conformer-LSTM+MSCA2					√	5.08	2.73
Proposed Method	√	√	√	√	√	3.68	2.16

表 4 本文方法与其他方法比较  
Table 4 The method in this paper is compared with other methods

方法	数据集	输入信号	结果/mmHg	
			SBP	DBP
基于小波包的模态分解 <sup>[19]</sup>	MIMIC III 5 776 组数据	PPG, ECG	MAE:4.69	MAE:2.53
MSA-ResNet <sup>[17]</sup>	MIMIC III 12 000 组数据	PPG	MAE:5.98	MAE:3.24
PPG2ABP <sup>[20]</sup>	MIMIC III 24 000 组数据	PPG	MAE:5.72	MAE:3.45
TCN-SE <sup>[5]</sup>	MIMIC III 19 946 组数据	PPG	MAE:5.09	MAE:2.96
Transformer <sup>[3]</sup>	MIMIC III 92 000 组数据	PPG	MAE:3.76	MAE:2.20
CNN-SVR <sup>[21]</sup>	MIMIC III 22 247 组数据	PPG, ECG	MAE:1.23	MAE:3.08
本文	MIMIC III 97 000 组数据	PPG	MAE:3.68	MAE:2.16

## 5 结 论

本文提出了一种基于 PPG 信号预测 ABP 波形的方 法。该方法采用基于 Conformer 模型的双支路结构,分别 提取信号的局部特征和全局特征。在 CNN 支路运用了 SE-MSFE 模块;提出了两个融合多尺度特征的 MSCA 模 块。模型仅通过 PPG 信号预测 ABP 波形,并计算 SBP、 DBP 等血压参数,无需单独构建预测模型。

在 MIMIC 公共数据库上的实验结果表明,SBP 和 DBP 的预测误差符合 AAMI 标准,DBP 和 SBP 的准确性 达到 BHS 标准的 A 级,所提出的方法仅使用 PPG 信号, 这是可行和有前景的。

## 参考文献

- [1] ZHOU B, PEREL P, MENSAH G A, et al. Global epidemiology, health burden and effective interventions for elevated blood pressure and hypertension[J]. Nature Reviews Cardiology, 2021, 18(11): 785-802.
- [2] ZHOU B, CARRILLO-LARCO R M, DANAEI G, et al. Worldwide trends in hypertension prevalence and progress intreatment and control from 1990 to 2019: A pooled analysis of 1201 population-representative studies with 104 million participants[J]. The Lancet, 2021, 398(10304): 957-980.
- [3] 田俊豪,刘立程,王小林,等. 基于 Transformer 模型

的连续无创血压预测方法[J]. 电子测量技术, 2024, 47(3):102-108.

TIAN J H, LIU L CH, WANG X L, et al. Continuous non-invasive blood pressure prediction method based on Transformer model[J]. Electronic Measurement Technology, 2024, 47(3): 102-108.

- [4] BAKER S, XIANG W, ATKINSON I. A hybrid neural network for continuous and non-invasive estimation of blood pressure from raw electrocardiogram and photoplethysmogram waveforms[J]. Computer Methods and Programs in Biomedicine, 2021,207:106191.
- [5] 熊嘉豪,姜晨希,陈永毅,等. 基于 TCN-SE 神经网络模型的智能连续血压估计方法[J]. 传感技术学报, 2022,35(11): 1499-1505.
- XIONG J H, JIANG CH X, CHEN Y Y, et al. Intelligent and continuous estimation of blood pressure method based on TCN-SE neural network model[J]. Chinese Journal of Sensors and Actuators, 2022, 35(11): 1499-1505.
- [6] 黄晓祥. 血压与多生理参数的关联性及无创连续血压测量模型的研究[D]. 济南:山东大学,2021.
- HUANG X X. The research of the correlation between BP and multiple physiological parameters and non-invasive continuous BP measurement models[D]. Jinan: Shandong University, 2021.



- [7] 崔守毅,杨国伟,何羽恒,等. 基于二维卷积的连续血压预测系统[J]. 集成电路与嵌入式系统, 2024, 24(8): 1-6.  
CUI SH Y, YANG G W, HE Y H, et al. Continuous blood pressure prediction system based on two-dimensional convolution[J]. Integrated Circuits and Embedded Systems, 2024, 24(8): 1-6.
- [8] 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 Y AN. Research on noninvasive continuous blood pressure prediction method based on PPG signal[D]. Chongqing: Southwest University, 2022.
- [9] YEN C, CHANG S, LIAO C. Estimation of beat-by-beat blood pressure and heart rate from ECG and PPG using a finetuned deep CNN model[J]. IEEE Access, 2022, 10: 85459-85469.
- [10] 孙斌,储芳芳,陈小惠. 基于贝叶斯优化 XGBoost 的无创血压预测方法[J]. 电子测量技术, 2022, 45(7): 68-74.  
SUN B, CHU F F, CHEN X H. Non-invasive blood pressure prediction method based on Bayesian optimized XGBoost [J]. Electronic Measurement Technology, 2022, 45(7): 68-74.
- [11] PENG CH, ZHANG Y Y, CHENG Y Y, et al. Pathformer: Multi-scale transformers with adaptive pathways for time series forecasting [J]. ArXiv preprint arXiv:2402.05956, 2024.
- [12] PENG ZH L, HUANG W, GU SH ZH, et al. Conformer: Local features coupling global representations for visual recognition[C]. IEEE/CVF International Conference on Computer Vision, 2021: 367-376.
- [13] LIN H ZH, CHENG X, WU X Y, et al. CAT: Cross attention in vision transformer [C]. 2022 IEEE International Conference on Multimedia and Expo (ICME). IEEE, 2022.
- [14] JOHNSON A E, POLLARD T J, SHEN L, et al. MIMIC-III, a freely accessible critical care database[J]. Scientific Data, 2016, 3(1): 1-9.
- [15] ESMAELPOOR J, MORADI M H, KADKHODAMOHAMMADI A. A multistage deep neural network model for blood pressure estimation using photoplethysmogram signals[J]. Computers in Biology and Medicine, 2020, 120: 103719.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. ArXiv preprint arXiv: 1706.03762, 2017.
- [17] QIN C J, LI Y, LIU CH B, et al. Cuff-less blood pressure prediction based on photoplethysmography and modified ResNet[J]. Bioengineering, 2023, 10(4): 400.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] 胡军锋,郑彬. 基于深度学习的 ECG/PPG 血压测量方法[J]. 生物医学工程研究, 2022, 41(1): 46-54.  
HU J F, ZHENG B. ECG/PPG blood pressure measurement method based on deep learning [J]. Journal of Biomedical Engineering Research, 2022, 41(1): 46-54.
- [20] IBTEHZE N, MAHMUD S, CHOWDHURY M E, et al. PPG2ABP: Translating photoplethysmogram (PPG) signals to arterial blood pressure (ABP) waveforms[J]. Bioengineering, 2022, 9(11): 692.
- [21] 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.

### 作者简介

陈欣, 硕士研究生, 主要研究方向为机器学习与深度学习。

E-mail: 485815956@qq.com

刘立程(通信作者), 博士, 副教授, 硕士生导师, 主要研究方向为人工智能在图像处理方面的技术研究与应用。

E-mail: 361556773@qq.com

王小林, 博士, 教授, 博士生导师, 主要研究方向为中医数字化、人工智能、机器人和智能车辆建模和控制等。

E-mail: wangxiaolin@binn. cas. cn