

DOI:10.19651/j.cnki.emt.2314534

# 基于 Transformer 模型的连续无创血压预测方法\*

田俊豪<sup>1</sup> 刘立程<sup>1</sup> 王小林<sup>2</sup> 刘梅<sup>3</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;  
3. 广州中医药大学基础医学院 广州 510006)

**摘要:** 动脉血压(ABP)波形包含丰富的心血管信息,有助于心血管疾病的预防和诊断。目前大部分基于光电容积脉搏波描记法(PPG)的血压预测方法仅预测收缩压(SBP)和舒张压(DBP),本文提出了一种由 PPG 信号预测 ABP 波形的血压测量方法。首先使用 PPG 信号作为输入,通过线性映射到高维空间,然后利用 Transformer 编码器结构进行特征提取,最后由线性层输出预测的 ABP 波形,由预测的 ABP 波形可计算出 SBP 和 DBP 等血压参数。实验结果显示,Transformer 网络在 MIMIC 数据集中预测的 ABP 波形与实际波形的拟合效果良好,计算得到的 SBP 和 DBP 预测误差分别为 $(3.76 \pm 5.66)$  mmHg、 $(2.20 \pm 3.77)$  mmHg,且该方法符合美国医疗仪器促进协会(AAMI)的标准,同时也在英国高血压协会(BHS)标准中达到 A 级。

**关键词:** 动脉血压;光电容积脉搏波;无创;Transformer;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:** 520.20

## Continuous non-invasive blood pressure prediction method based on Transformer

Tian Junhao<sup>1</sup> Liu Licheng<sup>1</sup> Wang Xiaolin<sup>2</sup> Liu Mei<sup>3</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;  
3. College of Basic Medicine, Guangzhou University of Chinese Medicine, Guangzhou 510006, China)

**Abstract:** Rich cardiovascular information is encompassed within the arterial blood pressure (ABP) waveform, offering valuable insights for the prevention and diagnosis of cardiovascular diseases. Despite the availability of several photoplethysmography (PPG)-based blood pressure prediction methods, they primarily focus on predicting systolic blood pressure (SBP) and diastolic blood pressure (DBP). This paper proposes a novel method for blood pressure measurement that predicts the entire ABP waveform from PPG signals. The proposed approach involves linearly mapping the PPG signal to a high-dimensional space and feature extraction using a Transformer encoder structure. A linear layer is then utilized to output the predicted ABP waveform, enabling the calculation of SBP and DBP. Experimental results demonstrate that the Transformer network provides an accurate fit to the actual ABP waveform in the MIMIC dataset, with predicted SBP and DBP errors averaging  $(3.76 \pm 5.66)$  mmHg and  $(2.20 \pm 3.77)$  mmHg, respectively. Additionally, the proposed method complies with the standards of the Association for the Advancement of Medical Instrumentation (AAMI) and achieves Grade A according to the British Hypertension Society (BHS) criteria.

**Keywords:** arterial blood pressure; photoelectric volume pulse wave; non-invasive; Transformer; attention mechanism

## 0 引言

心血管疾病(cardiovascular disease, CVD)已经严重威胁人类生命健康,每年全球因 CVD 死亡的人数高达 1 040 万<sup>[1]</sup>,高血压是 CVD 的主要危险因素之一。所以,血压监测对于

诊断筛查、监测治疗计划以及指示患者健康状况是非常必要的,通过实时检测血压,及时控制血压,可以大大降低心血管并发症和死亡的风险。

近年来,有研究将光电容积脉搏波描记法(photoplethysmography, PPG)用于无创血压预测。PPG

收稿日期:2023-09-05

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

技术可测量血管和组织中的血容量时间变化相关信号,PPG波形携带反映受试者心血管功能的丰富信息,已有研究证明其形成与血压密切相关<sup>[2]</sup>。且PPG传感器体积小,制造成本低,可嵌入到可穿戴设备中实现日常血压监测。但存在以下问题限制了基于PPG的连续血压检测在临床上的应用,首先基于PPG的血压检测属于间接测量,而血压是一种受多个因素影响的复杂生理参数,仅通过PPG信号很难精确估计血压值,且个体差异较大,进一步限制了精度;其次PPG信号容易受到环境噪声、运动伪影等干扰,从而影响血压值的准确性。

针对PPG信号,人们开展了许多研究,利用各种生理参数连续无创地估计血压。脉搏波速度(pulse wave velocity, PWV)是与血压和动脉刚度有关的重要参数之一,PWV是血压脉冲通过循环系统传播的速度,主要通过测量脉冲传递时间(pulse transit time, PTT)和脉冲到达时间(pulse arrival time, PAT)来表示相应的PWV<sup>[3-4]</sup>。但测量PTT或PAT需要采集两路PPG同步信号或者PPG与心电图(electrocardiography, ECG)同步信号,且仅以PTT或PAT建立的血压预测模型泛化性较差。有研究通过对PPG信号进行特征提取,利用机器学习方法比如线性回归<sup>[5-6]</sup>、支持向量回归<sup>[7]</sup>、随机森林回归<sup>[8]</sup>、AdaBoost<sup>[9]</sup>等建立血压预测模型,进一步提高了血压预测的准确性。但该方法依赖于人工提取的特征,而人群的多样性使得特征提取的准确性不稳定,存在一定的局限性。为了克服人工特征的缺点,有研究通过深度学习建立血压预测模型,如Harfiya等<sup>[10]</sup>使用长短期记忆网络(long short-term memory, LSTM)建立由PPG信号到动脉血压(arterial blood pressure, ABP)波形的转换模型,对比传统方法,该方法可以由PPG信号预测整个ABP波形而不仅是收缩压(systolic blood pressure, SBP)和舒张压(diastolic blood pressure, DBP)两个血压值,且在预测ABP上计算的SBP和DBP精度也有所提升。Tazarv等<sup>[11]</sup>利用卷积神经网络(CNN)作为特征提取模块,并通过LSTM建立血压预测模型,其结果表明该模型比传统模型性能有所提高。但是上述基于深度学习的方法引入了其他输入信号如ECG、PPG一阶导数及二阶导数等,增加了模型的复杂度。

针对上述问题,本文提出了基于Transformer模型的预测连续无创动脉血压方法。该方法只需通过单路PPG信号预测ABP波形,由预测得到的ABP波形可获取SBP、DBP等血压参数。该方法无需其他输入信号辅助,不需要人工提取特征,能预测完整的血压波形,预测的ABP波形不仅能计算出SBP、DBP,还能提供更全面的血压信息。

## 1 预处理方法

PPG信号主要存在高频噪声、基线漂移和运动伪影等噪声干扰,因此需要对PPG信号进行滤波。本文采用四阶巴特沃斯滤波器来滤除高频噪声和基线漂移,滤波器使用

截止频率为0.5~20 Hz的四阶巴特沃斯带通滤波器,除此之外,考虑到PPG信号的直流量中携带有关平均血容量的重要信息<sup>[12]</sup>,仅使用上述滤波器会丢失这部分信息,因此还使用截止频率为0.05 Hz的窄带低通滤波器对PPG信号进行预处理。将PPG信号分别通过这两个滤波器后的输出相加得到去噪后的PPG信号。

为了使训练过程更加稳定,提高收敛速度,将PPG和ABP信号的幅值归一化为 $[0, 1]$ 之间。归一化公式如式(1)所示。

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

其中, $x_{\max}$ 、 $x_{\min}$ 分别为数据的最大值和最小值。

## 2 血压预测模型

### 2.1 Transformer模型

Transformer<sup>[13]</sup>是一种基于编码-解码结构的模型,具体结构如图1所示。编码器由 $N$ 个相同子层构成,每个子层由多头注意力(multi-head attention)和前馈网络两个模块组成,两个模块之间通过残差连接与层归一化操作处理数据。解码器结构与编码器相似,其新增了一组带遮蔽的多头注意力模块。

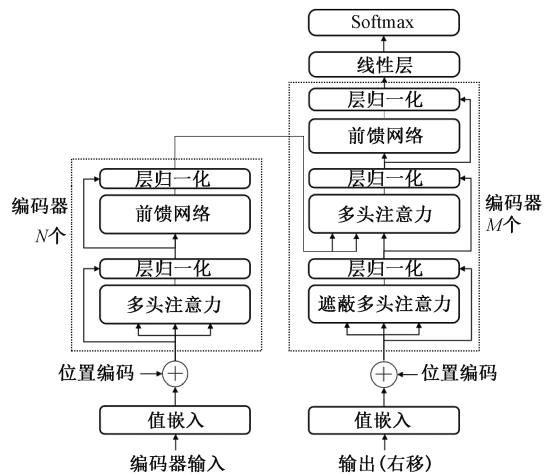


图1 Transformer结构图

注意力机制是Transformer模型的主要构成模块。自注意力机制通过3个线性层将输入映射为请求矩阵 $Q$ 、键矩阵 $K$ 、值矩阵 $V$ ,自注意力计算公式可描述为:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2)$$

其中, $d_k$ 表示 $Q, K, V$ 矩阵每一行的维度。 $Q$ 和 $K^T$ 点乘得到向量的相关性权重分数,通过除以 $\sqrt{d_k}$ 缓解 $softmax$ 函数存在的梯度消失问题,经过 $softmax$ 函数后再与 $V$ 相乘得到注意力矩阵。

多头注意力则是通过对 $Q, K, V$ 矩阵进行多次不同的线性变换,将输入投影到多个不同的子空间,分别进行自注

注意力计算得到多个输出矩阵,将其拼接在一起得到最终的输出,能使模型关联不同方面的信息,提升模型特征提取性能。多头注意力机制可描述为:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^o \quad (3)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (4)$$

其中,  $W_i^Q, W_i^K, W_i^V$  分别是  $Q, K, V$  第  $i$  头的线性变换权重矩阵,  $W^o$  为拼接后的线性变换矩阵,  $Concat$  为拼接函数。

### 2.2 ABP-Transformer 的血压预测模型构建

Transformer 最初用于自然语言处理,本文针对血压预测应用,对传统的 Transformer 进行了一些改进,设计的 ABP-Transformer 血压预测模型如图 2 所示。主要的改进之处有:

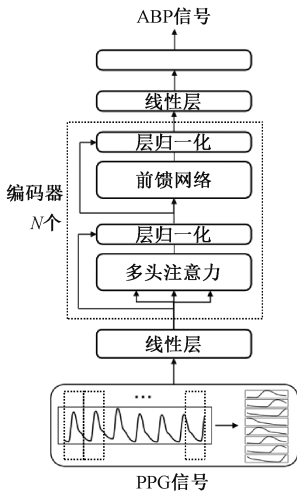


图 2 ABP-Transformer 血压预测模型

1) 基于血压预测的特点,只通过编码器部分进行特征提取,简化了 Transformer 结构。

2) 改进输入部分,一个 PPG 信号样本包含多个心动周期的波形,每个周期之间波形的相关性很高,通过固定长度窗口将 PPG 信号分割成多个子序列,引入局部信息,降低冗余性,便于注意力机制集中在子序列上,提高特征提取能力。

3) 通过线性层将原始 PPG 信号线性映射转换为适合 Transformer 编码器输入的形式。

ABP-Transformer 进行血压预测主要步骤如下:

步骤 1) 对 PPG 信号按固定长度分割成多个子序列。分割的长度影响模型的精度,过长或过短都会导致模型精度降低。较长的子序列包含多个心动周期,冗余度高;较短的子序列携带的信息不全。因此需要选择合适的分割长度。当子序列只包含一个心动周期时,既能控制冗余度,也能保证信息全面。

步骤 2) 采用线性层将每个子序列映射到高维空间。

步骤 3) 通过编码器对输入数据进行特征提取。

步骤 4) 采用线性层将提取的特征映射为 ABP 波形子序列。

步骤 5) 拼接子序列得到完整 ABP 波形。

### 2.3 模型参数设置

经过预处理得到的 PPG 信号长度为 624 个采样点,通过分割得到尺寸为  $8 \times 78$  的 PPG 信号作为 ABP-Transformer 的输入。在 ABP-Transformer 中,输入线性层神经元个数为 128,编码器层数为 6,每层注意力头个数为 4,前馈网络中两个线性层神经元个数分别为 1 024 和 128,dropout 层按 0.1 的比例随机丢弃神经元,激活函数选择 Leaky ReLu,输出线性层神经元个数为 78。

## 3 实验结果与分析

### 3.1 实验数据

本文采用 MIMIC<sup>[14]</sup> 数据库进行实验研究。MIMIC 数据库提供了从重症监护室病房收集的生理学数据,包括 PPG 和 ABP 等信号,信号采样率为 125 Hz。通过对该数据库中的数据进行筛选,建立符合实验要求的数据集。

首先剔除部分信号质量差以及时间过短的数据,筛选出 1 434 名受试者共约 135 个小时的数据。每个数据按 4.992 s(624 个采样点)一个片段分割,该片段长度可以保证在心率极低的情况下也能稳定计算 SBP、DBP 等血压参数,共 97 000 组数据,样本的血压值分布如图 3 所示。数据集以 7 : 1 : 2 的比例随机划分训练数据、验证数据和测试数据。




图 3 血压值分布

### 3.2 实验设置

采用 CPU 为 Inter i7-8750H, GPU 为 NVIDIA GeForce GTX 1060 的电脑进行实验模型搭建。模型训练的批大小设置为 256,采用 Adam 优化器,初始学习率设置为 0.001,选择均方误差(Mean Squared Error, MSE)作为损失函数。模型训练迭代 200 轮,每轮训练结束后通过验证集计算当前参数下模型的损失值(Loss)与平均绝对误差(mean absolute error, MAE),其中当前 MAE 如果小于目前模型的最小 MAE,则保存模型参数并更新最小 MAE; Loss 值用于调整学习率并防止模型过拟合,如果连续 5 轮

Loss没有降低,则将学习率调整为当前学习率的1/4,如果连续15轮Loss没有降低,则停止训练。

### 3.3 评价指标与实验结果分析

本文通过Transformer建立血压预测模型,将PPG信号转换为ABP信号,并由转换的ABP信号计算SBP、DBP等参数。为了直观显示预测ABP波形质量,输入的PPG信号与由模型预测和真实的ABP波形对比分别如图4(a)、(b)所示。可以发现,ABP-Transformer可以实现由输入PPG信号准确预测ABP波形,且虽然PPG信号与真实ABP波形之间存在相位滞后问题,但ABP-Transformer可以克服相位滞后的影响,避免手动校正。

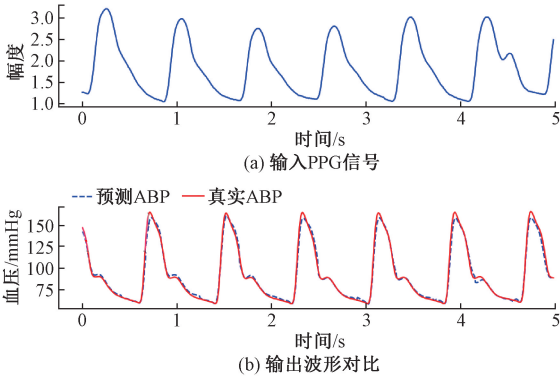


图4 模型预测结果可视化

为了评估模型的预测精度,采用MAE和标准差(STD)作为评价指标。此外,还采用英国高血压协会(BHS)和美国医疗器械发展协会(AAMI)指定的血压测量仪器相关评价标准以及Bland-Altman分析来评估实验结果。

#### 1) MAE和STD

MAE和STD的计算表达式如式(5)和(6)所示。

$$MAE = \frac{1}{m} \sum_{i=0}^m |y'_i - y_i| \quad (5)$$

$$STD = \sqrt{\frac{1}{m-1} \sum_{i=0}^m (e_i - \bar{e}_i)^2}, e_i = y'_i - y_i \quad (6)$$

在测试集中模型预测的ABP波形误差(MAE±STD)为(3.84±5.72) mmHg,通过预测的ABP波形计算得到的SBP误差为(3.76±5.66) mmHg,DBP误差为(2.20±3.77) mmHg。

#### 2) BHS标准

BHS提供了一种血压测量精度分级标准<sup>[15]</sup>。该标准基于绝对误差设定3个阈值(5、10和15 mmHg),通过计算预测值的绝对误差分别低于每个阈值的百分比,将测量精度划分为A、B、C三个等级,达到A级或者B级则符合临床使用条件。

预测的SBP和DBP的误差分布如图5(a)、(b)所示,误差分布近似于高斯分布,计算误差的绝对值低于5、10和15 mmHg的样本数占比与BHS标准进行对比,如表1所

示,本文使用的ABP-Transformer模型预测的SBP和DBP均达到A级。




图5 SBP和DBP误差分布

表1 BHS标准与实验结果

| 累计误差  | <5 mmHg | <10 mmHg | <15 mmHg |
|-------|---------|----------|----------|
| A级    | 60%     | 85%      | 95%      |
| BHS标准 |         |          |          |
| B级    | 50%     | 75%      | 90%      |
| C级    | 40%     | 65%      | 85%      |
| 本文结果  |         |          |          |
| SBP   | 76.3%   | 93.7%    | 97.5%    |
| DBP   | 91.5%   | 97.6%    | 98.9%    |

#### 3) AAMI标准

AAMI<sup>[16]</sup>提供了另一种血压测量精度指标,其规定血压测量仪器和方法的MAE应小于5 mmHg,STD应小于8 mmHg。本文在AAMI标准下的结果如表2所示,采用的ABP-Transformer模型预测的SBP和DBP均符合AAMI标准。

#### 4) Bland-Altman

Bland-Altman图是医疗应用中评估两种测量方法之间一致性水平的常用方法。本文将Transformer模型预测的SBP和DBP与动脉内测量得到的血压值进行一致性分析。SBP和DBP的分析结果如图6(a)、(b)所示。由图可

表 2 AAMI 标准与实验结果

| 指标      | ME/<br>mmHg | STD/<br>mmHg | 受试者<br>人数 |
|---------|-------------|--------------|-----------|
| AAMI 标准 | <5          | <8           | >85       |
| 本文结果    | SBP         | 3.76         | 1 434     |
|         | DBP         | 2.20         |           |

果如表 3 所示,模型对不同性别与年龄段人群的预测误差较为接近,说明该模型泛化性能较好。

表 3 ABP-Transformer 对不同人群的预测误差

| 人群 | MAE/mmHg |      |      |
|----|----------|------|------|
|    | SBP      | DBP  |      |
| 男  | 青年       | 3.78 | 2.27 |
|    | 中年       | 3.83 | 2.18 |
|    | 老年       | 3.76 | 2.22 |
| 女  | 青年       | 3.67 | 2.31 |
|    | 中年       | 3.75 | 2.26 |
|    | 老年       | 3.87 | 2.17 |

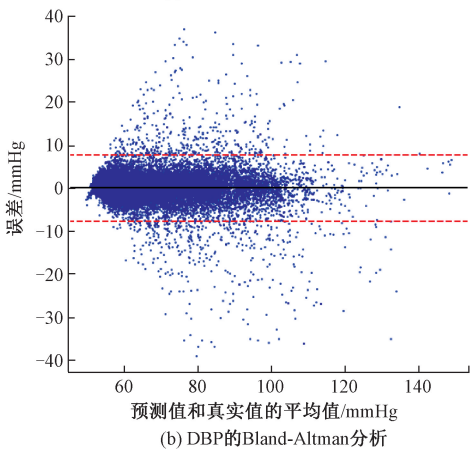



图 6 Bland-Altman 分析

以看出,SBP 和 DBP 绝大部分包含在 95%置信区间,说明本文的 Transformer 模型预测与通过动脉内测量的一致性较好。

5) 人群预测性能差异分析

为进一步验证模型对不同人群的预测性能是否存在差异,将测试数据按不同年龄、性别划分成多个测试组,分别统计每组测试数据的预测误差。其中年龄按青年组(15~40岁)、中年组(40~65岁)、老年组(65岁以上)划分。结

3.4 方法对比

表 4 对比了本文提出的方法与其他无创血压估计方法的性能。为了更公平的比较,所有的方法采用 MAE 以及 STD 作为评价指标,尽量采用相同的数据集。其中一些方法采用了 UCI 数据库中的血压数据集(UCI\_BP),UCI\_BP 数据集提取了 MIMIC 中的 PPG、ECG 和 ABP 波形,并进行了预处理<sup>[17]</sup>。多元线性回归、随机森林、ANN 等方法采用人工提取脉搏波特征参数结合机器学习方法进行血压预测,但个体的差异影响了人工提取特征的稳定性,提高了特征的设计难度和计算量,且在数据量较大情况下,上述方法的表现欠佳。LSTM 方法在输入信号上引入了 PPG 一阶导信号和二阶导信号,CNN-LSTM 和 ResNet+SE 方法引入 ECG 信号,虽然提高了预测的精度,但增加了需处理的数据量,且由于 ECG 信号需与 PPG 信号保持同步,提高了对数据采集设备的要求,降低了设备的便携性。相比其它方法,本文方法仅通过 PPG 信号预测 ABP 波形,无需其他信号参与,避免了人工提取特征,能够同时预测 SBP 与 DBP,预测精度更高。

3.5 可视化分析

ABP-Transformer 在 PPG 到 ABP 的转换任务中表现出良好的性能,这主要归功于其注意力机制。为进一步分析注意力机制对特征提取的影响,这里通过可视化分析每一层编码器输出的特征数据。

以 4 层编码器的 ABP-Transformer 为例,输入的 PPG 信号与编码器各层输出的特征及预测的动脉血压波形如图 7(a)~(f)所示。通过分析图 7 可以发现,受注意力权重影响,随着层数的加深,提取的特征稀疏程度越来越高,注意力权重增强关键特征,抑制其他特征,提高了特征的表达能力。

表4 本文方法与其它方法比较

| 方法                        | 数据集       | 输入信号    | 结果/mmHg  |          |
|---------------------------|-----------|---------|----------|----------|
|                           |           |         | SBP      | DBP      |
| 多元线性回归 <sup>[7]</sup>     | MIMIC I   | PPG     | MAE:6.10 | MAE:4.65 |
|                           | 28个受试者    |         | STD:8.01 | STD:6.22 |
| 随机森林 <sup>[9]</sup>       | UCI_BP    | PPG,ECG | MAE:9.54 | MAE:5.48 |
| ANN <sup>[18]</sup>       | MIMIC II  | PPG     | MAE:4.8  | MAE:2.5  |
| LSTM <sup>[11]</sup>      | MIMIC II  | PPG     | MAE:4.05 | MAE:2.41 |
|                           | 5289个受试者  |         | STD:5.25 | STD:3.17 |
| CNN-LSTM <sup>[19]</sup>  | MIMIC III | PPG,ECG | MAE:4.41 | MAE:2.91 |
|                           | 6972个受试者  |         | STD:6.11 | STD:2.84 |
| ResNet+SE <sup>[20]</sup> | MIMIC     | PPG,ECG | MAE:3.70 | MAE:2.81 |
|                           | 1216个受试者  |         | STD:5.11 | STD:3.95 |
| 本文                        | MIMIC III | PPG     | MAE:3.76 | MAE:2.20 |
|                           | 1434个受试者  |         | STD:5.66 | STD:3.77 |




图7 输入PPG与编码器层特征及预测波形可视化

### 4 结论

本文通过建立Transformer血压预测模型,实现了仅使用PPG信号预测动脉血压波形,可以根据预测的动脉血压波形提取SBP、DBP等血压参数,无需针对SBP、DBP分别建立模型。本方法在公共数据库MIMIC中进行了实验验证,实验结果表明根据预测得到的动脉血压波形中提取的SBP、DBP符合BHS和AAMI标准。通过Bland-Altman分析,本方法与动脉内监测方法具有较高的一致性,预测的动脉血压波形与真实血压波形相似度高,有助于连续的血压监测,给日常健康监测、预防心血管疾病提供了帮助。

### 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] ELGENDI M. On the analysis of fingertip photoplethysmogram signals[J]. Current Cardiology Reviews, 2012, 8(1): 14-25.
- [3] BYFIELD R, MILLER M, MILES J, et al. Towards robust blood pressure estimation from pulse wave velocity measured by photoplethysmography sensors[J]. IEEE Sensors Journal, 2021, 22(3): 2475-2483.
- [4] KIM S C, CHO S H. Blood pressure estimation algorithm based on photoplethysmography pulse analyses[J]. Applied Sciences, 2020, 10(12): 4068.
- [5] MOUSAVI S S, FIROUZMAND M, CHARMI M, et al. Blood pressure estimation from appropriate and

- inappropriate PPG signals using A whole-based method[J]. *Biomedical Signal Processing and Control*, 2019, 47: 196-206, DOI: 10.1016/j. bspc. 2018. 08.022.
- [6] HADDAD S, BOUKHAYMA A, CAIZZONE A. Continuous PPG-based blood pressure monitoring using multi-linear regression [J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 26 (5): 2096-2105.
- [7] YANG S, ZAKI W S W, MORGAN S P, et al. Blood pressure estimation with complexity features from electrocardiogram and photoplethysmogram signals[J]. *Optical and Quantum Electronics*, 2020, 52: 1-16, DOI:10.1007/s11082-020-2260-7.
- [8] THAMBIRAJ G, GANDHI U, MANGALANATHAN U, et al. Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning [J]. *Biomedical Signal Processing and Control*, 2020, 60: 101942, DOI: 10.1016/j. bspc. 2020.101942.
- [9] HASANZADEH N, AHMADI M M, MOHAMMADZADE H. Blood pressure estimation using photoplethysmogram signal and its morphological features [J]. *IEEE Sensors Journal*, 2019, 20(8): 4300-4310.
- [10] HARFIYA L N, CHANG C C, LI Y H. Continuous blood pressure estimation using exclusively photoplethysmography by LSTM-based signal-to-signal translation[J]. *Sensors*, 2021, 21(9): 2952.
- [11] TAZARV A, LEVORATO M. A deep learning approach to predict blood pressure from ppg signals[C]. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 2021: 5658-5662, DOI:10.1109/EMBC46164. 2021.9629687.
- [12] 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, DOI: 10.1016/j. compbiomed. 2020.103719.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30, DOI: 10.48550/ARXIV.1706.03762.
- [14] JOHNSON A E W, POLLARD T J, SHEN L, et al. MIMIC-III, a freely accessible critical care database[J]. *Scientific Data*, 2016, 3(1): 1-9.
- [15] O'BRIEN E, PETRIE J, LITTLER W, et al. The british hypertension society protocol for the evaluation of automated and semi-automated blood pressure measuring devices with special reference to ambulatory systems[J]. *Journal of Hypertension*, 1990, 8(7): 607-619.
- [16] ALPERT B S. Validation of the welch allyn spot vital signs blood pressure device according to the ANSI/AAMI SP10: 2002. Accuracy and cost-efficiency successfully combined [J]. *Blood Pressure Monitoring*, 2007, 12(5): 345-347.
- [17] KACHUEE M, KIANI M M, 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), IEEE, 2015: 1006-1009, DOI: 10.1109/ISCAS.2015.7168806.
- [18] MANAMPERI B, CHITRARANJAN C. A robust neural network-based method to estimate arterial blood pressure using photoplethysmography[C]. 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE), IEEE, 2019: 681-685, DOI: 10.1109/BIBE.2019.00128.
- [19] 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, DOI: 10.1016/j. compb. 2021.106191.
- [20] QIU Y, LIU D, YANG G, et al. Cuffless blood pressure estimation based on composite neural network and graphics information [J]. *Biomedical Signal Processing and Control*, 2021, 70: 103001, DOI: 10.1016/j. bspc. 2021.103001.

## 作者简介

田俊豪, 硕士研究生, 主要研究方向为机器学习与深度学习。

E-mail: 849555636@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