

# 基于双分支时频融合的心冲击信号心率估计网络

韦力天, 杨其宇

广东工业大学自动化学院, 广东 广州

收稿日期: 2026年3月30日; 录用日期: 2026年5月26日; 发布日期: 2026年6月17日

## 摘要

文章提出了一种基于双分支时频融合架构的模型, 用于从心冲击图(BCG)信号中实现高精度的心率估计。该模型以原始BCG信号为输入, 通过并行的时间分支与频率分支分别提取时域波形特征与频域周期特征, 其中频率分支采用快速傅里叶变换(FFT)获取频谱信息, 并引入注意力机制自适应加权关键频段, 使模型能够聚焦于心率基频及其谐波成分, 有效提升了估计的准确性与鲁棒性。实验结果显示, 该模型在平均绝对误差(3.10 BPM)、均方误差(11.23)及决定系数(0.72)等指标上均表现优异, 显著优于传统单分支网络与时域回归方法。与近年来相关研究相比, 本模型在BCG心率估计任务中展现了显著优势, 突显了其在无接触心率监测场景中的实用价值。

## 关键词

BCG, 心率估计, 深度学习, Attention

# Heart Rate Estimation Network for Ballistocardiogram Signals Based on Dual-Branch Time-Frequency Fusion

Litian Wei, Qiyu Yang

School of Automation, Guangdong University of Technology, Guangzhou Guangdong

Received: March 30, 2026; accepted: May 26, 2026; published: June 17, 2026

## Abstract

This paper proposes a model based on a dual-branch time-frequency fusion architecture for high-precision heart rate estimation from ballistocardiogram (BCG) signals. The model takes raw BCG signals as input and employs parallel temporal and frequency branches to extract time-domain waveform

features and frequency-domain periodic features, respectively. In the frequency branch, the fast Fourier transform (FFT) is utilized to obtain spectral information, and an attention mechanism is introduced to adaptively weigh critical frequency bands, enabling the model to focus on the fundamental frequency and its harmonics of heart rate, thereby effectively improving estimation accuracy and robustness. Experimental results show that the model achieves excellent performance in terms of mean absolute error (3.10 BPM), mean squared error (11.23), and coefficient of determination (0.72), significantly outperforming traditional single-branch networks and time-domain regression methods. Compared with recent related studies, this model demonstrates significant advantages in BCG-based heart rate estimation tasks, highlighting its practical potential in non-contact heart rate monitoring scenarios.

## Keywords

Ballistocardiogram (BCG), Heart Rate Estimation, Deep Learning, Attention

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

心血管疾病(CVDs)已成为全球范围内导致死亡的重要原因。世界卫生组织数据显示, 每年约有 1790 万人死于心血管疾病, 占全球总死亡人数的 32% [1]。研究表明, 心血管疾病的发病率和死亡率呈持续上升趋势, 尤其在发展中国家的增长速度更为显著。心血管疾病的发生往往与心率变异性(HRV)异常、心律不齐等心脏功能指标密切相关, 因此, 实现长期、连续、准确的心率监测对于心血管疾病的早期发现、预防和治疗具有重要的临床意义[2]。

目前, 临床上广泛认可的心率监测金标准是心电图(Electrocardiography, ECG), 通过记录心脏电活动提供精确的心跳信息[3]。然而, 传统 ECG 监测需要将电极直接贴附于皮肤, 长时间佩戴易引起皮肤刺激和不适感, 且设备体积较大、操作复杂, 限制了其在日常生活中的长期应用[4]。近年来, 可穿戴光电容积描记术(Photoplethysmography, PPG)技术迅速发展, 被广泛应用于智能手表等消费级设备中, 但其信号易受运动伪迹干扰, 且在肤色较深、末梢循环不良的人群中测量准确性显著下降[5]。因此, 研发一种非接触式、舒适便捷且准确可靠的心率监测手段, 具有重要的现实意义。

心冲击图(Ballistocardiography, BCG)作为一种无接触式生理信号监测技术, 通过高灵敏度传感器捕获心脏搏动和血流喷射引起的身体微小振动, 能够在不与皮肤直接接触的情况下获取丰富的心血管功能信息[6]。BCG 信号最早由 Gordon 于 1877 年发现, 经过近一个半世纪的发展, 已从最初的精密机械记录装置演进为可集成于床垫、座椅、体重秤等日常物品中的传感器系统[7]。研究表明, BCG 信号与 ECG 信号在心率变异性分析中表现出良好的一致性, 能够提供心搏间期(IBI)、心率(HR)等关键心血管参数[8]。BCG 技术尤其适用于睡眠监测、夜间监护等长期无干扰场景, 可有效避免电极接触不适和佩戴负担, 为家庭环境下的连续健康监护提供了新的可能[9]。

尽管 BCG 技术在无接触监测方面展现出巨大潜力, 但其信号处理仍面临诸多挑战。首先, BCG 信号幅度极弱(通常为毫伏级), 极易受到呼吸运动、体位变化、环境振动等多种噪声干扰, 信号质量波动较大[10]。其次, BCG 波形形态存在显著的个体差异和时变特性, 同一受试者在不同体位或不同时间段的波形形态可能发生明显变化, 给特征提取带来困难[11]。此外, 传统基于峰值检测的信号处理方法往往需要人工设定阈值或模板, 难以适应复杂的实际应用场景。Brüser 等人[12]提出的 BCG 心搏间隔估计算法

在受控环境下取得了 4.24 BPM 的平均绝对误差, 但在实际应用场景中性能显著下降。Tramontano 等人 [13] 在远程医疗场景下的对比研究表明, 传统信号处理方法在真实环境中的 MAE 达到 5.46 BPM, 而 CNN 方法则达到 3.54 BPM, 验证了深度学习方法在复杂环境下的优势。

随着深度学习技术的发展, 研究人员开始探索将深度神经网络应用于 BCG 信号分析。Schubert 等人 [14] 首次系统比较了多种深度学习架构(CNN、RNN 及 CNN-RNN 混合结构)在 BCG 心率估计中的性能, 实验表明深度学习方法在 42 名受试者的数据集上取得了 2.07 BPM 的平均绝对误差, 显著优于传统信号处理方法。Jiao 等人 [15] 提出基于双向长短时记忆网络(BiLSTM)的回归模型, 直接从原始 BCG 信号中学习时序模式进行心率预测, 有效降低了对精确心搏标注的依赖。Morokuma 等人 [16] 进一步采用深度学习方法从 BCG 信号预测 ECG 波形, 实现了心搏间期的无接触测量, 在逐搏间隔估计中达到了 0.034 秒的平均绝对误差。在注意力机制应用方面, Schranz 等人 [17] 提出的基于 ResNet 的代理建模方法通过连续核函数编码心跳事件, 在 J 峰检测任务中取得了优于传统方法的性能。Pino 等人 [18] 开发的 BCG 算法框架为无接触心率监测提供了有效的信号处理基础。

综合上述, 现有基于深度学习的 BCG 心率估计方法主要分为两类: 一类采用纯时域网络直接从原始波形学习时序特征, 另一类通过频域变换提取周期信息后进行建模。然而, 这两类方法往往独立使用, 未能充分利用时域波形细节与频域周期信息之间的互补关系。为此, 本文提出一种基于双分支时频融合架构的心率估计网络。该模型以原始 BCG 信号为输入, 通过并行的时间分支与频率分支分别提取时域波形特征与频域周期特征, 其中频率分支采用快速傅里叶变换(FFT)获取频谱信息, 并引入注意力机制自适应加权关键频段, 使模型能够聚焦于心率基频及其谐波成分。两个分支提取的特征经拼接融合后输入回归网络输出心率值。实验结果表明, 该模型在平均绝对误差(3.10 BPM)、均方误差(11.23)及决定系数(0.72)等指标上均表现优异, 验证了双分支时频融合架构在 BCG 心率估计任务中的有效性和优越性。

## 2. 数据集

### 2.1. 基础数据集

本文所使用的实验数据均来源于自主研发的床垫式睡眠监测系统。该系统采用非接触式气压感知原理, 通过嵌入床垫的气囊模块拾取人体心脏搏动与呼吸运动引起的微弱机械振动, 经气流管道传输至信号采集单元进行模数转换与处理。系统同步采集心冲击图(BCG)信号与心电图(ECG)参考信号, ECG 信号用于生成心率标签。

实验共招募 11 名健康受试者。为增强数据多样性, 每位受试者在三种睡眠姿态(仰卧、左侧卧、右侧卧)与三种气囊硬度(软、中、硬)组合下各采集一组数据, 共 9 组, 每组时长 3~5 分钟。总数据量覆盖了不同姿态与床垫软硬条件下的信号变化, 为模型训练提供了丰富的样本分布。结果如图 1 所示。

在数据预处理阶段, 采用长度为 8 秒的滑动窗口对原始 BCG 信号进行分段, 窗口步长为 4 秒, 每个片段包含 1000 个采样点。对于每个 BCG 片段, 同步提取对应时间窗口内的 ECG 信号, 通过 R 峰检测计算 RR 间期, 并求取窗口内瞬时速率的平均值作为该片段的心率标签(单位: BPM)。该构建方式兼顾了心率变化的时间分辨率与样本间的独立性。

### 2.2. 数据集预处理

首先进行数据集划分。本文依据心率值的分布区间, 将所有样本按 7:1:2 的比例分割为训练集、验证集和测试集。具体而言, 70% 的样本用于模型训练, 10% 作为验证集以辅助模型参数调节及训练过程监控, 剩余 20% 作为测试集用于最终性能评估。这种划分策略有助于降低模型在训练中出现过拟合的风险, 同时保证实验结果的客观性。




Figure 1. Heart rate distribution statistics  
图 1. 心率分布统计图

在实际生理条件下, 心率往往集中于特定范围(如健康成人静息时的心率多为 60~100 BPM), 且不同个体之间存在差异, 因此原始数据中不同心率区间的样本数量通常很不均衡。若直接使用该数据进行训练, 模型可能对样本量较大的心率区间学习得较为充分, 而对样本量较小的区间学习不足, 从而削弱模型的整体泛化能力。

为解决上述问题, 本文在模型训练阶段对上述划分得到的训练集进行数据增强, 以扩充训练样本并缓解数据分布不均。具体采用三种常见的时间序列增强技术: 随机时间平移、幅值缩放和高斯噪声扰动。其中, 随机时间平移是在时间轴上对信号做小幅平移, 以模拟不同心跳周期起始位置的差异; 幅值缩放则对信号的总体幅值施加随机比例变化, 用于模拟不同个体间信号幅度的差异; 高斯噪声扰动是在原始信号中添加微弱随机噪声, 以模拟实际采集过程中的环境干扰。通过这些操作, 可在保持信号主要生理特征的前提下扩展训练样本规模, 从而提升模型对不同心率区间的学习能力, 增强其鲁棒性与泛化性能。

在数据预处理方面, 为降低噪声干扰及不同样本间幅值差异对模型训练的影响, 本研究对原始 BCG 信号实施了滤波与归一化处理。

考虑到心率信号的主要能量分布在 0.8~8 Hz 之间, 本研究采用带通滤波提取 BCG 信号中的心率相关成分, 从而抑制呼吸运动(通常低于 0.5 Hz)及高频噪声的干扰, 进一步增强心率节律特征的表达能力。

此外, 为统一不同样本之间的幅值范围, 对信号进行最小 - 最大归一化处理, 将信号幅值映射到[0, 1]区间, 其计算公式为

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

其中,  $x$  表示原始信号,  $x_{\min}$  和  $x_{\max}$  分别表示信号片段中的最小值和最大值,  $x'$  表示归一化后的信号。通过上述预处理步骤, 可有效提升信号质量并降低幅值差异带来的影响, 从而为后续模型训练提供稳定的数据输入。预处理效果前后对比如图 2 所示。

### 3. 模型构建

在模型构建中, 本实验结合了时域卷积网络与频域注意力机制的优势, 构建了双分支时频融合架构。时间分支通过多层一维卷积提取 BCG 信号的时域波形特征, 捕捉心跳周期内的形态变化; 频率分支采用快速傅里叶变换获取频谱信息, 并引入注意力机制自适应加权关键频段, 使模型能够聚焦于心率基频及

其谐波成分。两个分支提取的特征经融合后输入回归网络, 有效提升了心率估计的准确性和鲁棒性。这一方法在无接触心率监测场景中具有重要的应用价值, 能够为长期连续的心血管健康监护提供有力支持, 模型整体架构如图 3 所示。

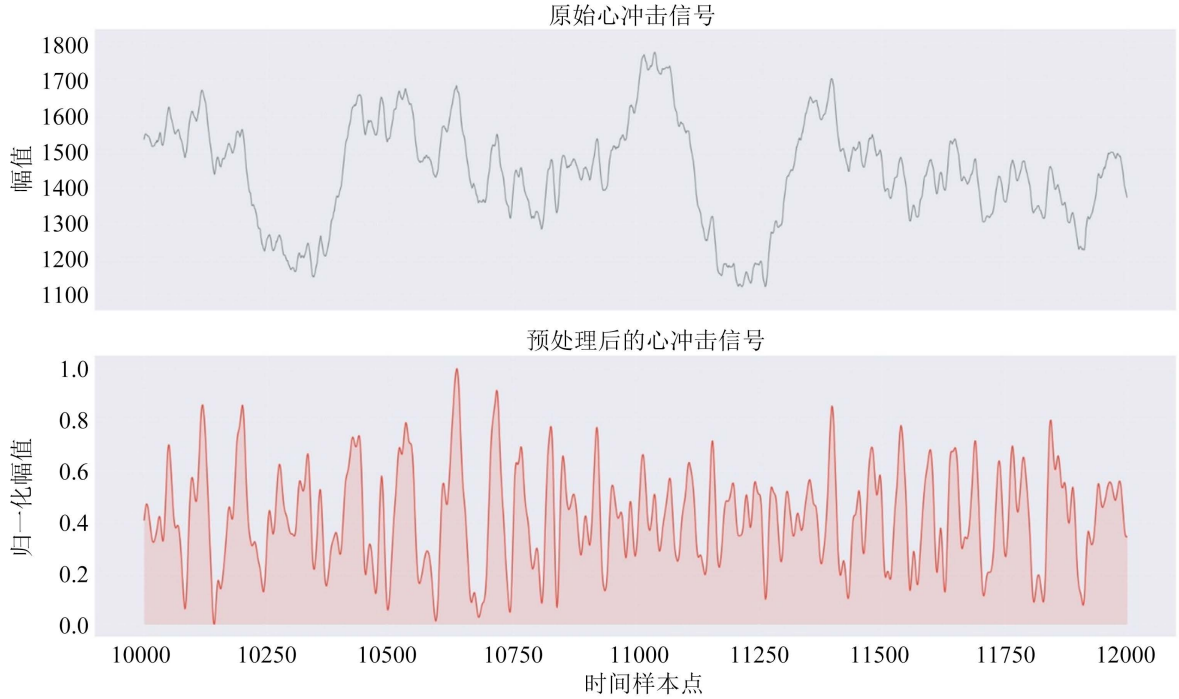


Figure 2. Comparison of BCG signal preprocessing  
图 2. BCG 信号预处理对比图

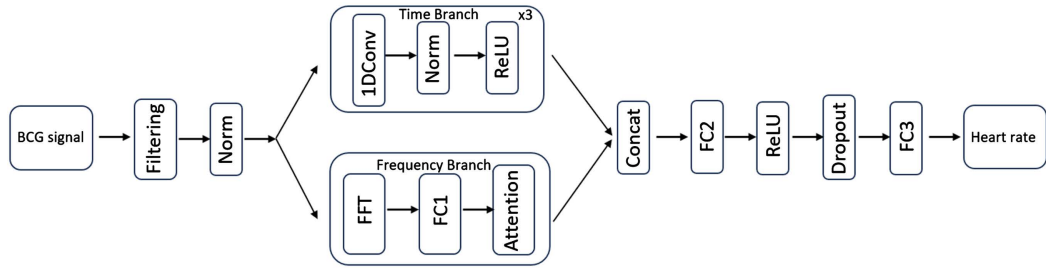


Figure 3. Overall architecture of the proposed model  
图 3. 模型整体架构

### 3.1. 时域卷积模块

时域卷积模块基于一维卷积神经网络(1D-CNN)设计, 用于从原始 BCG 信号中提取时序波形特征。一维卷积能够有效捕捉信号中的局部模式, 并通过层级堆叠逐步扩大感受野, 从而提取与心率周期相关的形态特征, 如 J 峰幅度、心搏间期变化等。相比于全连接网络, 卷积操作通过权值共享机制大幅减少参数量, 同时保持了对时间维度的平移不变性, 适合处理生理时序信号。一个典型的一维卷积操作可表示为:

$$y[t] = (x * w)[t] = \sum_{k=1}^K x[t+k] \cdot w[k] \tag{2}$$

其中,  $x$  为输入信号序列,  $w$  为卷积核,  $K$  为卷积核大小,  $y$  为输出特征序列。通过堆叠多个卷积层与池化层, 网络能够逐层提取从局部细节到全局周期的高阶特征, 为后续心率回归提供丰富的时域信息。

### 3.2. 频域注意力模块

频域注意力模块用于从 BCG 信号的频谱表示中提取心率相关频段信息, 并动态聚焦关键频率成分。首先, 通过快速傅里叶变换(FFT)将时域信号转换为频域幅度谱, 显式引入心率固有的周期信息。随后, 利用全连接层将高维频谱映射为低维特征向量, 并在该特征上施加通道注意力机制, 使模型能够自适应地学习不同频段对心率估计的重要性。该注意力机制可表示为:

$$\alpha = \sigma(W_2 \cdot \delta(W_1 \cdot \bar{u})) \quad (3)$$

其中,  $\bar{u}$  为映射后频域特征的全局平均,  $W_1$  和  $W_2$  为可学习的权重矩阵,  $\delta$  为 ReLU 激活函数,  $\sigma$  为 Sigmoid 函数,  $\alpha$  为生成的注意力权重向量。最终频域特征通过  $v_{\text{freq}} = \alpha \odot u$  进行加权, 使模型聚焦于心率的基频及谐波成分, 有效抑制无关频段噪声干扰, 提升心率估计的准确性。

### 3.3. 损失方法

本实验采用的损失函数为均方误差损失函数(Mean Squared Error, MSE), 它通过衡量模型预测值与真实标签之间的平方差来计算损失。在心率回归任务中, 均方误差损失函数的公式为:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

其中,  $y_i$  表示第  $i$  个样本的真实心率值(单位: BPM),  $\hat{y}_i$  表示模型对该样本的心率预测值,  $N$  为批处理中的样本总数。均方误差损失函数通过优化过程不断减小预测值与真实值之间的差异, 从而提高模型心率估计的准确性。该损失函数适用于连续值回归任务, 其输出层无需激活函数, 直接输出心率预测结果。

## 4. 模型训练与评估

### 4.1. 训练环境

本文的实验训练环境配置如表 1 所示。

Table 1. Experimental environment

表 1. 实验环境

硬件环境		软件环境	
CPU	Intel 12400F	操作系统	Windows 11
GPU	NVIDIA RTX4060	Cuda 版本	11.8
内存	32 G	Pytorch 版本	2.0

### 4.2. 模型训练

在模型训练开始之前, 需对若干关键超参数进行配置, 这些参数对训练效果具有重要影响。具体而言, 数据集的划分比例设为 7:1:2, 分别用于训练、验证与测试, 以增强模型的泛化能力。为降低实验结果中的随机性, 统一将随机数种子设置为 28。训练过程中选用 Adam 优化器, 并设定初始学习率为 0.001, 以引导参数进行稳定更新。同时, 批次大小(batch size)设置为 64, 即每次迭代处理 64 个样本, 模型共计训练 150 个轮次(epochs), 确保其能够充分学习数据中的特征。

### 4.3. 模型的评估指标

在评估模型的性能时, 本文采用了多种适用于回归任务的评估指标, 包括平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)以及决定系数(Coefficient of Determination, R<sup>2</sup>)。这些指标能够从不同角度全面反映模型在心率估计任务中的预测精度与拟合效果, 具体介绍如下:

#### 4.3.1. 平均绝对误差(MAE)

平均绝对误差是衡量模型预测值与真实值之间平均偏差的常用指标, 它反映了模型预测误差的绝对大小。MAE 对异常值具有较强的鲁棒性, 能够直观地反映模型在心率估计中的平均偏离程度。MAE 值越小, 表明模型的预测结果越接近真实心率值。其计算公式如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5)$$

其中,  $y_i$  表示第  $i$  个样本的真实心率值,  $\hat{y}_i$  表示模型对该样本的心率预测值,  $N$  为样本总数。

#### 4.3.2. 均方误差(MSE)

均方误差是衡量模型预测误差平方和平均值的指标, 它通过平方运算放大了较大误差的影响, 能够更好地反映模型在预测过程中出现极端偏差的情况。MSE 值越小, 说明模型的预测值与真实值之间的差异越小, 模型性能越优。其计算公式如下:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

相比于 MAE, MSE 对异常值更为敏感, 能够有效评估模型在心率估计中的稳定性。

#### 4.3.3. 决定系数(R<sup>2</sup>)

决定系数是衡量模型拟合优度的常用指标, 反映了模型对真实数据变异性的解释程度。R<sup>2</sup> 的取值范围通常在 0 到 1 之间, 越接近 1 表示模型对心率值的拟合效果越好, 预测能力越强。其计算公式如下:

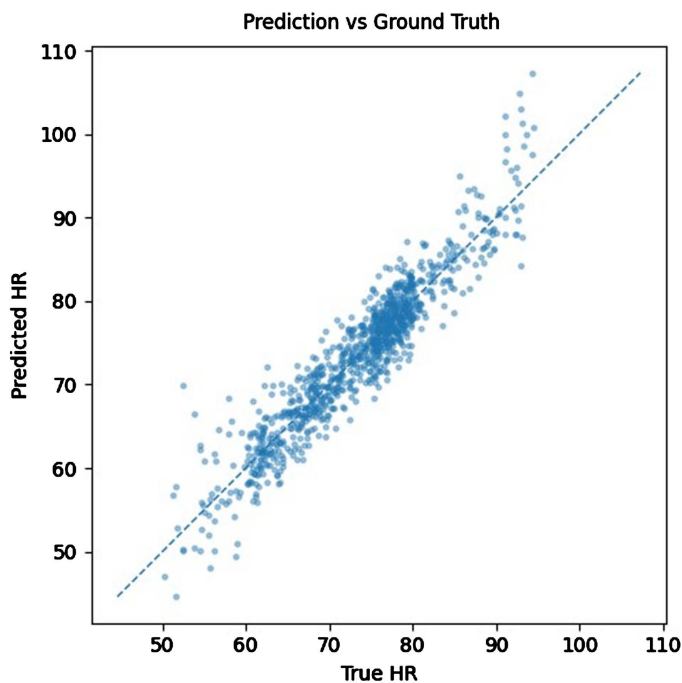
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (7)$$

其中,  $\bar{y}$  表示所有样本真实心率值的平均值。当模型预测值与真实值完全一致时, R<sup>2</sup> = 1; 当模型预测效果劣于直接使用均值作为预测时, R<sup>2</sup> 可能为负值。该指标能够直观地评估模型相对于简单基线方法的改进程度。

### 4.4. 模型评估


为了评估模型在心率估计任务中的表现, 本研究采用了逐片段评估的方法。在这种评估方式下, 模型对每个固定长度的 BCG 信号片段进行心率预测, 并与基于同步 ECG 信号计算得到的心率标签进行对比, 以全面衡量模型在不同时间窗口下的估计精度。本研究中, 每个时间片段的长度设定为 8 秒, 窗口步长为 4 秒。评估指标包括平均绝对误差(MAE)、均方误差(MSE)以及决定系数(R<sup>2</sup>), 从平均偏差、误差敏感度及拟合优度三个维度综合评价模型的性能。

图 4 给出了模型在测试集上对心率进行预测时, 其预测值与真实值之间的散点分布关系。图中横坐标代表真实心率, 纵坐标代表模型预测结果, 斜对角线对应理想情况下的恒等线( $y=x$ )。整体来看, 绝大部分点都聚集在该对角线附近, 说明模型的预测结果与真实值之间具有很高的吻合度。少数离群点主要出现在心率偏低或偏高的两端区域, 推测是由于在极端心率条件下信号质量有所下降, 或者该区间的训练样本数量较少所致。



**Figure 4.** Scatter plot of predicted vs. true heart rate  
**图 4.** 实验结果预测散点图

图 5 展示了预测误差的统计直方图。从图中可以看出, 预测误差主要集中在 $-3$  BPM 至 $+3$  BPM 范围内, 大部分样本的误差绝对值小于 3 BPM, 整体误差分布靠近 0 中线, 这反映出模型的估计结果在整体上没有偏离真实值的固定趋势, 即系统误差不显著。



**Figure 5.** Histogram of prediction errors in experimental results  
**图 5.** 实验结果预测误差统计直方图

## 5. 结论

本实验所采用的模型基于双分支时频融合架构, 作为心率估计的核心网络。时间分支通过多层一维

卷积从原始心冲击图(BCG)信号中自动提取时域波形特征, 无需繁琐的特征工程步骤; 频率分支利用快速傅里叶变换(FFT)获取频谱信息, 并引入注意力机制自适应加权关键频段, 使模型能够聚焦于心率的基频及其谐波成分, 为心率回归任务奠定了坚实基础。通过两个分支的并行提取与特征融合, 模型能够充分利用时域与频域的互补信息, 进一步提升了心率估计的精确度和鲁棒性。

实验结果表明, 该模型在各项指标上表现优异, 平均绝对误差(MAE)为 3.10 BPM, 均方误差(MSE)为 11.23, 决定系数( $R^2$ )达到 0.72。通过与近年来相关研究的检测方法进行对比, 证明了该模型在 BCG 心率估计中具有较为出色的性能, 展现了其在无接触心率监测场景中的潜力和优势。

## 参考文献

- [1] World Health Organization (2021) Cardiovascular Diseases (CVDs). WHO Fact Sheets.
- [2] Inan, O.T., Migeotte, P., Park, K., Etemadi, M., Tavakolian, K., Casanella, R., *et al.* (2015) Ballistocardiography and Seismocardiography: A Review of Recent Advances. *IEEE Journal of Biomedical and Health Informatics*, **19**, 1414-1427. <https://doi.org/10.1109/jbhi.2014.2361732>
- [3] Goldberger, A.L., Amaral, L.A.N., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., *et al.* (2000) PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*, **101**, e215-e220. <https://doi.org/10.1161/01.cir.101.23.e215>
- [4] Carlson, C., Turpin, V., Suliman, A., Ade, C., Warren, S. and Thompson, D.E. (2021) Bed-Based Ballistocardiography: Dataset and Ability to Track Cardiovascular Parameters. *Sensors*, **21**, Article 156. <https://doi.org/10.3390/s21010156>
- [5] Hoog Antink, C., Mai, Y., Aalto, R., Bruser, C., Leonhardt, S., Oksala, N., *et al.* (2020) Ballistocardiography Can Estimate Beat-to-Beat Heart Rate Accurately at Night in Patients after Vascular Intervention. *IEEE Journal of Biomedical and Health Informatics*, **24**, 2230-2237. <https://doi.org/10.1109/jbhi.2020.2970298>
- [6] Alametsä, J., Värri, A., Koivuluoma, M. and Barna, L. (2004) The Potential of EMFi Sensors in Heart Activity Monitoring. *Proceedings of the 2nd OpenECG Workshop*, Berlin, 1-3 April 2004, 81-85.
- [7] Wang, F., Zou, Y., Tanaka, M., Matsuda, T. and Chonan, S. (2007) Unconstrained Cardiorespiratory Monitor for Premature Infants. *International Journal of Applied Electromagnetics and Mechanics*, **25**, 469-475. <https://doi.org/10.3233/jae-2007-751>
- [8] Martin-Yebra, A., Landreani, F., Casellato, C., Pavan, E., Frigo, C., Migeotte, P., *et al.* (2015) Studying Heart Rate Variability from Ballistocardiography Acquired by Force Platform: Comparison with Conventional ECG. 2015 *Computing in Cardiology Conference (CinC)*, Nice, 6-9 September 2015, 929-932. <https://doi.org/10.1109/cic.2015.7411064>
- [9] Brink, M., Müller, C.H. and Schierz, C. (2006) Contact-Free Measurement of Heart Rate, Respiration Rate, and Body Movements during Sleep. *Behavior Research Methods*, **38**, 511-521. <https://doi.org/10.3758/bf03192806>
- [10] Wiard, R.M., Inan, O.T., Argyres, B., Etemadi, M., Kovacs, G.T.A. and Giovangrandi, L. (2011) Automatic Detection of Motion Artifacts in the Ballistocardiogram Measured on a Modified Bathroom Scale. *Medical & Biological Engineering & Computing*, **49**, 213-220. <https://doi.org/10.1007/s11517-010-0722-y>
- [11] Feng, J., Huang, W., Jiang, J., Wang, Y., Zhang, X., Li, Q., *et al.* (2023) Non-Invasive Monitoring of Cardiac Function through Ballistocardiogram: An Algorithm Integrating Short-Time Fourier Transform and Ensemble Empirical Mode Decomposition. *Frontiers in Physiology*, **14**, Article 1201722. <https://doi.org/10.3389/fphys.2023.1201722>
- [12] Bruser, C., Stadthanner, K., de Waele, S. and Leonhardt, S. (2011) Adaptive Beat-to-Beat Heart Rate Estimation in Ballistocardiograms. *IEEE Transactions on Information Technology in Biomedicine*, **15**, 778-786. <https://doi.org/10.1109/titb.2011.2128337>
- [13] Tramontano, A., Tamburis, O., Cioce, S., Venticinque, S. and Magliulo, M. (2023) Heart Rate Estimation from Ballistocardiogram Signals Processing via Low-Cost Telemedicine Architectures: A Comparative Performance Evaluation. *Frontiers in Digital Health*, **5**, Article 1222898. <https://doi.org/10.3389/fdgth.2023.1222898>
- [14] Isfahani, R.T., Loghmani, A., Akhavan, A. and Taebi, A. (2024) Evaluation of Signal Processing and Deep Learning Methods for Inter-Beat Interval Extraction from Ballistocardiography Signals. *Journal of Computational Methods in Engineering*, **44**, 49-61. <https://doi.org/10.47176/jcme.44.2.1056>
- [15] Jiao, C., Yang, A., Zhao, H., Yi, R., Gou, S., Sha, Y., *et al.* (2025) Self-Supervised, Non-Contact Heartbeat Detection Based on Ballistocardiograms Utilizing Physiological Information Guidance. *IEEE Journal of Biomedical and Health Informatics*, **29**, 2589-2602. <https://doi.org/10.1109/jbhi.2024.3509875>
- [16] Morokuma, S., Saitoh, T., Kanegae, M., Motomura, N., Ikeda, S. and Niizeki, K. (2025) Prediction of ECG Signals from Ballistocardiography Using Deep Learning for the Unconstrained Measurement of Heartbeat Intervals. *Scientific Reports*,

- 15**, Article No. 999. <https://doi.org/10.1038/s41598-024-84049-0>
- [17] Schranz, C., Halmich, C., Mayr, S. and Heib, D.P.J. (2024) Surrogate Modelling of Heartbeat Events for Improved J-Peak Detection in BCG Using Deep Learning. *Frontiers in Network Physiology*, **4**, Article 1425871. <https://doi.org/10.3389/fnetp.2024.1425871>
- [18] Pino, E.J., Chavez, J.A.P. and Aqueveque, P. (2017) BCG Algorithm for Unobtrusive Heart Rate Monitoring. 2017 *IEEE Healthcare Innovations and Point of Care Technologies (HI-POCT)*, Bethesda, 6-8 November 2017, 180-183. <https://doi.org/10.1109/hic.2017.8227614>