

# 基于改进的非负矩阵分解技术的抗运动 干扰心电信号感知方法

曹焯彤<sup>1</sup>, 李 凡<sup>2\*</sup>, 刘晓晨<sup>2</sup>, 谢皖冉<sup>2</sup>, 陈慧杰<sup>3</sup>

(1. 山东大学计算机科学与技术学院, 山东青岛 266237; 2. 北京理工大学计算机学院, 北京 100081;  
3. 北京工业大学计算机学院, 北京 100124)

**摘 要:** 连续监测心电信号对于加强心血管疾病的早期筛查和诊断至关重要。然而, 现有的心电信号监测方法存在依赖昂贵设备、依赖用户执行特殊操作、应用场景受限等弊端, 无法满足广泛人群在日常生活状态下长期连续监测心电的迫切需求。为了克服上述问题, 本研究提出了一种基于改进的非负矩阵分解技术的抗运动干扰心电信号感知方法。其基本思想是利用成本低廉的腕戴式智能设备集成的陀螺仪, 连续感知身体振动中隐含的心脏活动信息并生成细粒度心电信号。为了有效应对身体运动干扰难以消除的固有挑战, 本研究提出了一种基于改进的非负矩阵分解技术的创新方法。该方法能够在未经训练的情况下, 成功提取因心跳引发的微弱心冲击振动信号, 有效克服运动干扰问题。此外, 针对心冲击振动信号在心动周期中波形动态性强且缺乏明确起止点的特点, 本研究首次提出了四种全新的形态特征, 并结合机器学习算法, 精准识别心冲击振动信号中的尖峰点, 从而实现心动周期的精确切分。最后, 本研究基于循环生成对抗网络, 构建了心冲击振动信号与心电信号之间的映射关系。得益于该网络的创新设计, 模型在无需用户提供训练数据的情况下, 也能高效生成精准的心电波形。本研究对 18 位志愿者进行了大量实验, 结果表明所提出的连续心电信号监测方法非常有效, 抗运动干扰效果显著。在身体静止和运动的情况下, 平均幅值误差分别为 7.92% 和 9.02%, 均满足医学标准规定的误差范围低于 10% 的要求。

**关键词:** 心电; 腕戴式智能设备; 心冲击振动; 非负矩阵分解; 循环生成对抗网络

**基金项目:** 国家自然科学基金(No.62372045, No.62072040, No.62202019); 中国博士后科学基金(No.2021M700302)

**中图分类号:** TP391.4 **文献标识码:** A **文章编号:** 0372-2112(2024)12-4153-13

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20230475

## Motion-Robust Electrocardiogram Signal Sensing Based on Modified Non-Negative Matrix Factorization

CAO Ye-tong<sup>1</sup>, LI Fan<sup>2\*</sup>, LIU Xiao-chen<sup>2</sup>, XIE Huan-ran<sup>2</sup>, CHEN Hui-jie<sup>3</sup>

(1. School of Computer Science and Technology, Shandong University, Qingdao, Shandong 266237, China;

2. School of Computer Science and Technology, Beijing Institute of Technology, Beijing 100081, China;

3. College of Computer Science, Beijing University of Technology, Beijing 100124, China)

**Abstract:** Continuous electrocardiogram (ECG) monitoring is crucial for effectively preventing and diagnosing cardiovascular diseases. However, existing ECG monitoring methods are limited by their reliance on expensive equipment unavailable to common users, the stringent requirements of the monitoring process, and confined application scenarios, making them insufficient to meet the urgent need for long-term continuous ECG monitoring of the general population in their daily lives. Given these limitations, this study proposes a motion-robust ECG signal sensing method based on modified non-negative matrix factorization (NMF). The basic idea is to leverage a gyroscope embedded into a low-cost wrist-worn wearable to characterize cardiac activities encoded into body vibrations and interpret them to generate fine-grained ECG signals accurately. As eliminating body motion interference is inherently hard, this work innovatively employs modified NMF to tackle the problem; this can effectively handle body motion interference, even if untrained, and extract the cardiogenic body vibrations from noisy gyroscope data. Due to the lack of clear pattern of cardiogenic body vibrations in each cardiac cycles,

current cardiac cycle segmentation solutions cannot be applied. Thus, this work deeply analyses the morphological features of cardiogenic body vibrations and utilizes machine learning techniques for the identification of spike points for segmentation. Finally, cycle generative adversarial network (CycleGAN) framework is employed to construct a correlation mapping model between the cardiogenic body vibrations and the ECG signals. With innovative construction, this model can accurately generate the ECG signals without the need for a huge amount of training data. Extensive experiments with 18 volunteers confirm the effectiveness of the proposed method, with the average amplitude errors of 7.92% and 9.02% for stationary and moving scenarios, respectively. These values fall well within the acceptable range of medical standards for error tolerance of less than 10%.

**Key words:** electrocardiogram; wrist-worn devices; cardiogenic body vibrations; non-negative matrix factorization; cycle generative adversarial network

**Foundation Item(s):** National Natural Science Foundation of China (No.62372045, No.62072040, No.62202019); China Postdoctoral Science Foundation under Grant (No.2021M700302)

## 1 研究背景和意义

随着人口老龄化程度不断加深以及人们生活节奏加快,心血管疾病的发病率逐年上升.据世界卫生组织估计,全球每年约有1790万人死于心血管疾病,占有死亡原因的32%<sup>[1]</sup>.在我国,心血管疾病的防治工作面临严峻考验.目前,我国心血管疾病患者已达3.3亿,近五年内死亡率超过了恶性肿瘤,成为国民健康的“头号杀手”<sup>[2]</sup>.心血管疾病具有间歇性发作的特点,相关医学研究表明,只有长期连续监测心电才能及时发现和诊断心血管疾病<sup>[3]</sup>.特别是老年人普遍同时患有多种心血管疾病,需要同时服用多种药物,长期连续监测心电有助于更好地了解药物对老年人心血管功能的影响,优化治疗方案.

目前,临床采用的心电检测仪体积庞大、价格昂贵且依赖专业人员操作,无法满足日常心电监测需求.虽然家用便携式心电仪已面市,但其复杂的部署和使用有线电极的方法使其限制用户行为,因此不适合在日常生活中长期连续监测心电信号(Electrocardiogram, ECG).近年来,嵌入在纺织物中的可穿戴电极技术引起了研究者的广泛兴趣,但由于成本高且无法克服身体运动导致的摩擦噪音,使得这类技术只能应用于用户保持静止的特殊场景.尽管一些高端智能手表<sup>[4,5]</sup>已经集成了心电监测电极,用于短期监测心电信号并评估房颤等心血管疾病的风险.但此类设备在使用时需要用户执行特殊操作,无法满足日常生活状态下连续监测心电的需求.目前,如何实现低成本、无需额外操作、适用于生活场景的高精度连续心电监测是有效管理心血管疾病所面临的重要挑战.

近年来,腕戴式智能设备集成的传感器种类不断增加,感知能力不断提升,使其在连续感知生理信号方面展现出巨大潜力.本研究发现心脏连续跳动时,血液喷射对应的加速过程与血液流经主动脉对应的减速过程交替进行,产生一系列冲击力和反冲击力,导致人体

产生周期性振动(称为心冲击振动),其信号波形与心电信号波形具有强相关关系.基于此,本文提出一种新型连续心电信号感知方法,利用成本低廉的腕戴式智能设备来连续采集心冲击振动信号,感知心脏活动信息,并生成高精度的细粒度心电信号.然而,实现本方法面临三个重要挑战.首先,腕戴式智能设备集成陀螺仪采集的信号容易受到身体运动的干扰而畸变.由于身体运动的复杂多变,消除这种干扰并感知细粒度心跳活动信息十分困难;其次,准确切分单个心动周期的心冲击振动信号片段是获得高精度心电信号的关键,然而心冲击振动信号具有不稳定的周期和波形,难以识别心动周期的开始和结束;最后,基于心冲击振动信号的心电信号生成方法属于空白起步阶段,二者之间的映射关系尚未得到深入研究.如何精准生成心电信号同时满足用户友好型系统需求,为本研究带来了巨大挑战.

为了有效应对上述挑战,本研究提出了三项创新性的方法,分别针对提取心冲击振动信号、切分心动周期片段以及连续生成心电信号的问题,具体步骤如图1所示.

(1)提取心冲击振动信号:由于身体运动的复杂性及其引发的高能量噪声,现有的去噪技术难以有效应对.为了解决这一问题,基于改进的非负矩阵分解(Nonnegative Matrix Factorization, NMF)技术,本研究创新性地引入非监督学习分量,显著提升了对未经训练的身体运动干扰的消除效果,使得从复杂背景噪声中提取微弱的心冲击振动信号成为可能.

(2)切分心动周期片段:常规的基于模板或阈值的心动周期切分方法难以应对心冲击振动信号的高度动态性.为此,本研究深入分析了心冲击振动信号的波形形态,发现与心室收缩显著相关的尖峰点可用于切分心动周期片段的可能性.基于这一发现,本研究首次提出了四种全新的形态特征,并通过机器学习方法进行尖峰点的精确识别,实现了对单次心动周期片段的可

靠切分。

(3)连续生成心电信号:为了构建心冲击振动信号与心电信号之间的关联映射,本研究创新性地设计了一种基于循环生成对抗网络(Cycle Generative Adversarial Networks, CycleGAN)的心电信号生成模型。此模型在无需用户提供训练数据的情况下,能够从心冲击振动信号中精准提取隐含的心脏活动信息,并生成高精度的心电信号,同时确保用户的良好体验。

通过 18 名志愿者在静止和运动场景下进行的实验结果表明,本研究提出的无感式连续心电监测方法在真实环境中表现卓越,抗运动干扰效果显著。其中,静止情况和运动情况下的平均幅值误差分别为 7.92% 和 9.02%,均满足医学标准规定的误差范围低于 10% 的要求<sup>[6]</sup>。

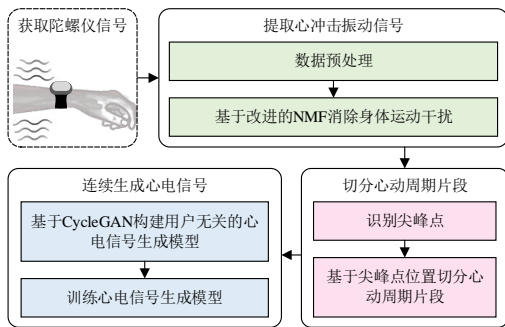


图1 所提出的心电信号监测方法流程

## 2 相关工作

目前,常规心电图是临床应用最为广泛的心电监测技术。然而,由于其体积和价格的限制,以及依赖专业医护人员操作,无法应用于日常心电监测。随着嵌入式技术与传感器技术的持续发展,家用便携式心电监测设备<sup>[1]</sup>种类日益丰富。然而,这些产品部署较为复杂,不适合在日常生活中长期连续心电监测。为了满足日益旺盛的日常生活状态下监测心电的需求,研究人员通过在床垫<sup>[7]</sup>、椅子<sup>[8]</sup>、马桶坐垫等家具设施中嵌入电极,在用户接触这些设施时测量心电信号。然而,在实际使用时,用户与这些设施的接触质量较差,导致心电监测结果误差较大。此外,心振图(Seismocardiogram, SCG)信号和心电信号的强相关性为间接测量心电提供了新的解决办法。例如,HeartQuake系统通过在床垫中安装振动传感器感知人体平躺时的SCG信号,成功实现了连续心电监测<sup>[9]</sup>。虽然这些方法的监测要求不如利用家具设施中嵌入电极监测心电的方法严格,但仍然要求用户在监测过程中与特定的家具设施保持接触,严重限制了心电监测的应用场景。

近年来,随着嵌入式、传感器及物联网技术水平的逐步提高,可穿戴技术迅速发展。基于可穿戴式智能防

织物<sup>[10-13]</sup>的心电监测方法具有支持随时随地测量的独特优势,因此吸引了大量学者的关注。然而,这些方法的实际应用受到了一些限制,例如设备制造和维护成本较高,以及在日常生活状态下人体和衣物摩擦对采集心电信号的干扰等。除了可穿戴衣物外,基于腕戴式智能设备的可穿戴心电监测方法也取得了较大进展。一些高端智能手表<sup>[14,15]</sup>中已经集成了单导心电监测电极,用于短期监测心电信号并评估房颤等心血管疾病的风险。然而,这些方法在使用时需要用户执行特定操作,且监测要求苛刻,无法满足日常生活状态下连续监测心电的需求。与先前的工作相比,本研究提出的连续心电监测系统仅利用腕戴式智能设备中普遍嵌入的低成本陀螺仪获取高精度心电信号,无需用户执行特定操作,不干扰用户生活,且无需用户提供大量的训练数据。

## 3 相关理论基础

### 3.1 心电信号的生理机制

如图2所示,心脏由左心房、左心室、右心房、右心室四个腔室构成,承担向身体各处输送血液的重要功能。在心脏跳动过程中,血液从心房流向心室,再由心室输送到全身。在一个心动周期中,心室放松并打开二尖瓣,造成约70%的血液从心房流向心室。然后心房收缩心肌并准备向动脉中泵血,同时心房中约20%的血液不断流入心室,导致压力逐渐增大。随后,所有瓣膜关闭,当心室压力超过主动脉时,心室将血压快速泵射入动脉中,使心脏中的血压容量快速减少。心脏各个部分的活动与人体健康密切相关,反映了人体的生理状况。




图2 心脏结构

在心动周期中,心房、心室相继兴奋,并伴随着一系列生物电变化,从体表引出的电位变化信号称为心电信号。具体来说,心脏跳动过程主要包括心房收缩、心室收缩和心脏舒张<sup>[16]</sup>。不同心跳活动使心电信号表现出独特的波形,如图3所示,在单个心动周期内,心电信号可以分为P波、QRS复合波和T波。P波表示心房收缩。QRS复合波指示心室收缩,是心电图最显著的特征。T波表示心脏舒张,此时心脏处于静止状态,血液被动地充满心室,然后进入下一次循环。当心脏状态变化时,心电信号也随之变化,因此连续监测心电信号对健康管理意义重大。




图3 心电信号与心脏活动的对应关系

### 3.2 心冲击振动信号生理机制

血液在不同心脏活动下喷射和流经主动脉的加速和减速交替进行. 基于牛顿第三定律, 血液的加速和减速过程使得人体对地面产生了一系列作用力和反作用力, 导致人体产生周期性振动, 即心冲击振动. 具体来说, 主动脉分为升主动脉和降主动脉, 当血液在升主动脉和降主动脉流动时, 心冲击力的变化有六个阶段<sup>[17]</sup>: (1)心室开始收缩时, 血液被快速射入主动脉入口, 导致向下的反作用力; (2)血液量迅速增加导致向上的反作用力; (3)血流速度减慢导致向下的反作用力; (4)主动脉出口处的血压达到最大值后迅速下降, 增加血压差导致向下的反作用力; (5)心室舒张时, 血液反向流动导致向上的反作用力; (6)血液进入外周血管导致向上的反作用力. 心冲击振动信号和心电信号分别表征了相同的心脏活动, 尽管二者之间没有直接形成波形的一一映射, 但仍具有内在联系. 因此, 本研究致力于建立心冲击振动信号与心电信号的关联映射, 以实现连续心电监测.

### 3.3 利用腕戴式智能设备捕捉心冲击振动信号

目前, 日益普及的腕戴式智能设备中普遍集成了低成本运动传感器, 使其成为一种受到学术界广泛关注的新型感知平台. 尽管不同型号设备的传感器可能有所不同, 但为了确保基本功能, 所有腕戴式智能设备都配备了三轴加速度计和三轴陀螺仪. 这些加速度计和陀螺仪不仅可用于惯性导航<sup>[18]</sup>、行为感知<sup>[19]</sup>, 还可通过分析其数据的频率、振幅、拐点位置等参数感知微妙的运动或振动变化<sup>[20,21]</sup>. 因此, 在用户长时间连续佩戴腕戴式智能设备时, 可以通过所集成的加速度计或陀螺仪采集心冲击振动信号, 实现连续监测心电的目标.

加速度计感知心冲击振动的方法有着悠久的历史, 一种典型的方法是将加速度计嵌入放置在地面的体重秤中, 通过分析用户站立时整个身体的位移、速度或加速度来感知心冲击振动信号. 然而, 由于受到重力的影响, 腕戴式智能设备中加速度计捕捉的心冲击振动信号质量较差, 不适合提取细粒度的信号. 已有的研究发现, 心跳活动产生的能量大部分都转换成了旋转的能量<sup>[22]</sup>. 因此, 本研究探索利用对旋转敏感的陀螺仪

捕捉心冲击振动信号. 图4展示了心电信号和腕戴式智能设备内置的陀螺仪在静止情况下捕捉的信号. 在信号采集过程中, 用户左手佩戴集成陀螺仪传感器的腕戴式设备以放松状态垂直于地面. 陀螺仪坐标系X轴沿手臂方向垂直于地面, Y轴垂直于手臂方向向左, Z轴垂直于手臂方向系. 例如, 心电信号中QRS复合波(由黑色虚线表示)对应上述振动信号中的剧烈波动. 此外, 与其他轴角速度信号相比, X轴角速度信号与心电信号的QRS波群、T波、P波都具有同时变化的特性. 大量实验表明, X轴角速度信号成功捕捉到了丰富且完整的细粒度心脏活动. 因此, 通过分析腕戴式智能设备中内置的陀螺仪与手臂平行方向X轴角速度信号, 可以准确地捕捉心冲击振动信号, 并准确生成心电信号.




图4 心电信号与陀螺仪捕捉的信号

## 4 系统设计

### 4.1 提取心冲击振动信号

在日常生活中, 用户往往需要在佩戴智能腕戴式设备的情况下完成各种活动, 如走路、开会、就餐. 这些日常活动会严重干扰采集心冲击振动信号, 从而不利于准确生成相应的心电信号. 因此, 为了准确提取心冲击振动信号, 必须先消除身体运动引起的噪音干扰.

#### 4.1.1 数据预处理

由于心跳产生的心冲击振动频率主要集中在5~30 Hz以内, 本研究首先应用截止频率为5~30 Hz的四阶巴特沃斯带通滤波器对所采集的角速度信号进行处理, 消除此范围外的噪音干扰, 例如呼吸引起的低频基线漂移和电源线引起的工频干扰. 然而, 日常生活状态下身体运动的频率范围与心冲击振动信号的频率范围重叠, 导致经过预处理后的陀螺仪信号中仍含有大量的身体运动干扰.

#### 4.1.2 基于改进的NMF消除身体运动干扰

由于心冲击振动信号相对于身体运动干扰强度微弱, 传统噪音消除方法如经验模式分解、小波分解、独立成分分析和主成分分析难以有效将二者分离<sup>[23]</sup>. 因此, 本研究提出了一种改进的NMF技术, 以更有效地消

除身体运动干扰.

问题定义:经过带通滤波后的陀螺仪  $X$  轴信号  $x(n)$  被视为心冲击振动信号  $v(n)$  和身体运动干扰  $m(n)$  的叠加结果,即  $x(n)=v(n)+m(n)$ ,其中  $n$  是信号序列的标记.本研究提出的身体运动干扰消除算法目标是从  $x(n)$  中消除  $m(n)$  的部分,只保留  $v(n)$ .

具体而言,所提出的算法分为三步:

第一步,提取时频谱矩阵.首先对  $x(n)$  应用短时傅里叶变换进行时频域分析,得到其时频谱  $x(f,t)=v(f,t)+m(f,t)$ ,其中频率  $f \in [1, F]$ ,时间  $t \in [1, T]$ ,  $F$  和  $T$  为常数,分别表示频率和时间的最大值;将时频谱  $x(f,t)$  表示为时频谱矩阵  $\mathbf{X} = [x_1, \dots, x_T] \in \mathbb{R}^{F \times T}$ ,其中,  $x_t = [|x(1,t)|, |x(2,t)|, \dots, |x(F,t)|]^T$ ,  $T$  表示矩阵转置;将时频谱  $v(f,t)$  和  $m(f,t)$  分别表示为

$$\mathbf{V} = [v_1, \dots, v_T] \in \mathbb{R}^{F \times T},$$

$$\mathbf{M} = [m_1, \dots, m_T] \in \mathbb{R}^{F \times T},$$

$\mathbb{R}$  表示实数集合.

第二步,基于改进的 NMF 技术分解时频谱矩阵.传统的 NMF 技术将时频谱矩阵分解为一个非负基矩阵  $\mathbf{W} \in \mathbb{R}_+^{F \times K}$  和一个非负系数矩阵  $\mathbf{H} \in \mathbb{R}_+^{K \times T}$  的乘积来分离具有不同局部特征的信号:

$$\mathbf{X} \approx \tilde{\mathbf{X}} = \mathbf{W}\mathbf{H} \quad (1)$$

其中,  $\tilde{\mathbf{X}}$  是估计矩阵,  $\tilde{\mathbf{X}} \in \mathbb{R}^{F \times T}$ .  $K$  为小于  $T$  和  $F$  的正整数,表示矩阵  $\mathbf{W}$  的列数,同时表示矩阵  $\mathbf{H}$  的行数.理想情况下,通过聚类  $\tilde{\mathbf{X}}$  中具有不同局部特征子成分可以分离心冲击振动信号  $\tilde{\mathbf{V}} = \mathbf{W}_V \mathbf{H}_V$  和身体运动干扰信号  $\tilde{\mathbf{M}} = \mathbf{W}_M \mathbf{H}_M$ ,其中  $\mathbf{W} = [\mathbf{W}_V, \mathbf{W}_M]$ ,  $\mathbf{H} = [\mathbf{H}_V, \mathbf{H}_M]^T$ .  $\mathbf{W}_V$  和  $\mathbf{H}_V$  分别表示心冲击振动信号分解得到的非负基矩阵和非负系数矩阵,  $\mathbf{W}_M$  和  $\mathbf{H}_M$  分别表示身体运动信号分解得到的非负基矩阵和非负系数矩阵.

在实际生活中,腕戴式智能设备采集的数据除了包含心冲击振动信号和身体运动干扰外,还存在难以预测的噪音干扰.因此,改进的方法引入了一个非监督学习成分  $\tilde{\mathbf{X}}_{\text{un}} = \mathbf{W}_{\text{un}} \mathbf{H}_{\text{un}}$ ,其中  $\mathbf{W}_{\text{un}}$  和  $\mathbf{H}_{\text{un}}$  分别表示无监督成分分解得到的非负基矩阵和非负系数矩阵.这一改进能够有效处理训练阶段未涉及的复杂噪音,防止将其错误地归因于心脏活动引起的心冲击振动信号.通过这样的优化,确保经过身体运动干扰消除后可以获取高质量的心冲击振动信号.应用改进的 NMF 技术消除身体运动干扰通过求解如下最小化方程实现:

$$\min_{\mathbf{W}, \mathbf{H}} \left[ \eta_V D(\mathbf{V}|\tilde{\mathbf{V}}) + \eta_M D(\mathbf{M}|\tilde{\mathbf{M}}) + D(\mathbf{X}_{\text{un}}|\tilde{\mathbf{X}}_{\text{un}}) + \frac{1}{T} \sum D(\mathbf{X}|\tilde{\mathbf{X}}) \right] \quad (2)$$

其中,  $\eta_V$  和  $\eta_M$  为非负矩阵分解过程中心冲击振动信号和身体运动干扰信号在分解时的权重.  $D$  表示算法估计结果与真实结果间的差距,定义为欧式距离 ( $L_2$  范数) 与稀疏惩罚项 ( $L_1$  范数) 的和:

$$D(\mathbf{X}|\tilde{\mathbf{X}}) = \|\mathbf{X}, \tilde{\mathbf{X}}\|_2 + \mu \|\mathbf{H}\|_1 \quad (3)$$

其中,  $\mu$  调整稀疏惩罚项的权重,其值也影响非负矩阵分解法的更新规则,可以根据设备计算能力调整,在本文中设置为 0.1 以验证算法表现.

在 NMF 模型的训练过程中,需要利用大量训练数据才能有效确定模型参数.然而,同时获取受身体运动影响的心冲击振动信号和纯净的心冲击振动信号,分别作为 NMF 的输入和与输出进行对比的真实值,极具挑战性.因此,在训练阶段,采用了一种人工合成的方法,生成了大量被身体运动干扰的心冲击振动信号.首先,招募具有足够个体差异的志愿者佩戴腕戴式设备,在静止状态下采集大量纯净的心冲击振动信号.接着,在身体运动状态下采集大量运动信号,并应用 30 Hz 截止频率的高通滤波器,消除其中的心冲击振动信号.然后,将这两种信号与随机高斯白噪声进行线性叠加,合成受运动干扰的心冲击振动信号,并将其输入到改进的 NMF 模型中.最后,将采集的纯净心冲击振动信号和纯净的身体运动信号与 NMF 分离结果进行比较,并指导模型的训练.具体来说,求解式(2)可以通过交替更新  $\mathbf{W}$  和  $\mathbf{H}$  实现,更新规则如下:

$$\begin{aligned} \mathbf{W} &\leftarrow \mathbf{W} \otimes \frac{\left(\frac{\mathbf{X}}{\mathbf{W}\mathbf{H}}\right) \mathbf{H}^T + \mathbf{W} \otimes (\mathbf{W} \otimes \mathbf{O}\mathbf{H}^T)}{\mathbf{O}\mathbf{H}^T + \mathbf{W} \otimes \left(\mathbf{W} \otimes \left(\frac{\mathbf{X}}{\mathbf{W}\mathbf{H}}\right) \mathbf{H}^T\right)}, \\ \mathbf{H} &\leftarrow \mathbf{H} \otimes \frac{\mathbf{W}^T \frac{\mathbf{X}}{\mathbf{W}\mathbf{H}}}{\mathbf{W}^T \mathbf{O} + \mu} \end{aligned} \quad (4)$$

其中,  $\mathbf{X}$  表示时频谱矩阵;  $T$  表示矩阵转置;  $\otimes$  和除法分别表示矩阵元素相乘和相除;  $\mathbf{O} \in \mathbb{R}^{F \times T}$  是一个  $F$  行  $T$  列的矩阵,其元素全为 1.  $\mathbf{W}$  和  $\mathbf{H}$  最初被初始化为随机非负矩阵,随着迭代的不断进行,式(2)达到收敛状态时的  $\mathbf{W}$  和  $\mathbf{H}$  即为最终解,最终得到估计矩阵  $\tilde{\mathbf{X}} = \mathbf{W}\mathbf{H}$ .

第三步,提取心冲击振动信号.通过筛选  $\tilde{\mathbf{X}}$  中具有不同局部特征子成分来分离心冲击振动信号和身体运动干扰信号实现.具体来说,分别计算  $\tilde{\mathbf{X}}$  中全部时间内不同频率子成分与预先保存的纯净心冲击振动信号的余弦距离,若余弦距离超过阈值  $\gamma$ ,则将该子成分视为心冲击振动信号的一部分.对所有超过阈值  $\gamma$  的向量聚类,得到心冲击振动信号的频谱矩阵  $\tilde{\mathbf{V}}$ .最后,利用逆短时傅里叶变换可以恢复纯净的心冲击振动信号  $v(n)$ .经过实验测试,将  $\gamma$  设为 0.8 时系统表现出较好的性能.图 5(a) 展示了腕戴式智能设备内置陀螺仪采

集的信号,图5(b)展示了应用以上算法提取出的纯净心冲击振动信号.从图中可以看出,原始信号在2 s到3 s时被身体运动严重干扰,此干扰在心冲击振动信号中被有效消除,只留下了周期性明显的心跳活动信息.

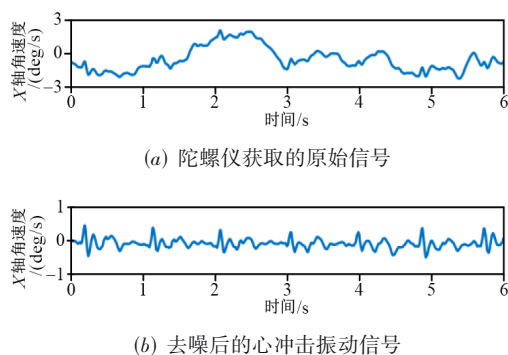


图5 未应用和应用身体运动干扰消除方法的信号示例

## 4.2 切分心动周期片段

准确切分心动周期片段对于提取细粒度心脏活动信息和生成准确的心电信号至关重要.然而,心冲击振动信号的动态特性导致其波形和周期不稳定,给准确切分心动周期片段带来了挑战.图5(b)显示,虽然心冲击振动信号具有周期性,但每个心动周期的起止时间并不明显.传统的自相关性和模板匹配等方法在这种情况下并不适用,因此需要新方法来解决这一问题.本研究发现心电信号出现QRS复合波时心冲击振动信号总是出现一个显著的尖峰点.图4展示了同时采集的心电信号和心冲击振动信号示例,也证实了这种现象.基于此现象,本研究从心冲击振动信号中提取形态特征,利用机器学习方法识别心冲击振动信号中的关键特征点,以准确切分每一个心跳区间对应的心冲击振动片段.

### 4.2.1 识别尖峰点

尖峰点是一种特殊的局部极大值点,通常具有较高的峰度.然而,心冲击振动信号中还存在其他非尖峰点的局部极大值点,它们的峰值有时与尖峰点相似,难以直接区分.因此,本研究在心冲击振动信号中提取有效的形态特征以准确识别尖峰点.提取尖峰点过程如图6所示,首先检测心冲击振动信号的所有局部极大值点并构建与其相邻的两个局部极小值点连接的三角形模型(用红色虚线表示并在右侧放大).基于三角形模型可以提取与三角形边长、高度、角度相关的七种特征表征三角形形态.

表1总结了采集自18名志愿者的数据中尖峰点与非尖峰点各自所在的三角形模型中七种特征的数值分布.从表中可以看出,尖峰点和非尖峰点所在的三角形在七种特征方面都表现出差异.然而,这七种特征间具有相关性,直接将它们全部输入到机器学习模型中可




图6 从心冲击振动信号中提取三角形的形态特征

能会导致过拟合,使得尖峰点的识别效果下降.因此,为了解决这一问题,本研究利用方差膨胀因子(Variance Inflation Factor, VIF)来量化这些几何特征之间的关联性,并最终选择了相关性最小的四个特征,包括 $a+b$ 、 $d$ 、 $e$ 和 $f$ 用于识别尖峰点.图7展示了从18名心冲击振动信号形态各异的志愿者(详情在第5.3.1节介绍)数据中提取出的四种特征,利用t型分布的随机邻接嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)降维到两个维度后的分布散点图.从图中可以看出尖峰点和非尖峰点具有不同的分布,证实了利用这四种特征可以帮助识别尖峰点.

表1 对比尖峰点与非尖峰点的7种特征

特征	尖峰点		非尖峰点	
	均值	标准差	均值	标准差
$a+b$	1.221	0.384	0.427	0.104
$c$	0.160	0.004	0.093	0.004
$d$	0.470	0.009	0.221	0.046
$e$	0.737	0.238	0.189	0.061
$f$	0.385	0.043	0.848	0.295
$g$	0.971	0.954	1.253	0.815
$h$	1.355	1.064	1.041	0.985

为了找到识别尖峰点的最佳机器学习方法,本研究比较了多种常用的机器学习方法,包括随机森林、支持向量机、最小二乘支持向量机、K-近邻、决策树、逻辑回归和朴素贝叶斯等.实验结果表明,随机森林方法表现最佳,其均衡准确率达到96.04%的均衡准确率(详细实验结果在5.4节展示),因此本研究利用随机森林识别尖峰点.此外,本研究还通过检查相邻尖峰点之间的时间间隔来进一步提高尖峰点的识别准确率.具体而言,对相邻尖峰点的时间间隔进行了以下两个要求:(1)时间间隔应在0.6 s至1 s范围内;(2)相邻时间间隔的差异应不超过20%的变化,否则舍弃涉及的尖峰点.

### 4.2.2 基于尖峰点位置切分心动周期片段

由于呼吸系统和激素系统的调节,每个心动周期的长度会自然而然地发生变化.若按照每次心跳的开始和结束时间对心冲击振动信号进行切分,具有不同长度的心动周期片段会给后续处理带来极大挑战.为了解决这个问题,本研究采用一种将心动周期片段切




图7 所选择的特征经过t-SNE降维到两个维度后的分布

分为尖峰点位置对齐且具有相同长度的方法. 具体而言, 识别出尖峰点后, 本研究基于尖峰点和心电信号的QRS复合波之间的时间关联确定心动周期的开始和结束时间, 以确保所切分的片段包含整个心动周期, 即包含收缩期和舒张期. 本研究参照基于QRS复合波位置的心电信号切分技术<sup>[24]</sup>, 将尖峰点出现前的第250 ms确定为心跳区间的起始点, 同时, 这个起始点也被视为前一周期的终点, 以确保切分范围涵盖整个心动周期.

### 4.3 连续生成心电信号

#### 4.3.1 基于CycleGAN构建用户无关的心电信号生成模型

基于3.2节的生理机制分析, 心冲击振动信号和心电信号分别感知心脏活动时产生的身体振动信息和生物电信息. 从心冲击振动信号生成心电信号波形类似于将同样含义的文本从一种语言翻译成另外一种语言. 为了解决这个“翻译”问题, 本研究需要构建有效的心电信号生成模型.

近年来, 深度学习得到广泛应用, 生成对抗网络(Generative Adversarial Network, GAN)被证明是一种强大的生成式模型, 可用于生成数据<sup>[25, 26]</sup>. 传统的GAN由生成器和判别器组成, 通过迭代训练使得生成的数据与真实数据之间的差异减小. 然而, 由于心冲击振动信号与心电信号之间的映射关系受到诸多因素影响, 传统的GAN方法需要大量成对的数据进行训练, 这会严重影响用户体验并阻碍模型的应用. 因此, 本研究采用基于CycleGAN构建用户无关的心电信号生成模型, 无需大量成对数据即可获得高精度的心电监测服务. CycleGAN最初用于实现将某一场景下获得的图像转换为另一场景下的图像. 本研究通过传统GAN的一对生成器-判别器结构的基础上额外添加一对“镜像”生成器-判别器, 保证了生成器的有效性以及判别器的用户无关性. 本研究所设计的网络模型包括四个部分:

生成器  $G_{V \rightarrow \hat{E}}$ : 利用用户提供的真实心冲击振动信号  $V$  生成具有心电信号波形特点的信号  $\hat{E}$ ;

判别器  $D_E$ : 区分生成的心电信号  $\hat{E}$  和真实的心电信号  $E$ ;

生成器  $G_{E \rightarrow \hat{V}}$ : 利用用户真实的心电信号  $E$  生成具

有心冲击振动信号波形特点的信号  $\hat{V}$ ;

判别器  $D_V$ : 区分生成的心冲击振动信号  $\hat{V}$  与真实的心冲击振动信号  $V$ .

如图8所示, 本研究设计的心电信号生成模型可以实现“正向循环”和“镜像循环”. (1) 正向循环: 将真实心冲击振动信号  $V$  输入到生成器  $G_{V \rightarrow \hat{E}}$ , 可以生成具有心电信号形态的信号  $\hat{E}$ . 将其继续输入循环以避免正向循环出现过拟合, 解决了训练过程中依赖成对心电信号和心冲击振动信号作为训练数据的问题, 实现了用户无关的心电信号生成. (2) 镜像循环: 输入真实心电信号  $E$ , 经过生成器  $G_{E \rightarrow \hat{V}}$  和生成器  $G_{V \rightarrow \hat{E}}$  后可以生成一个新的心冲击振动信号  $\hat{V}$ , 且其波形与真实心电信号  $E$  仅有微小误差. 判别器  $D_V$  在镜像循环过程中学习分辨真实的心冲击振动信号和生成的心冲击振动信号. 在训练阶段, 多位志愿者提供真实心冲击振动信号和心电信号, 不同于传统GAN模型将这两个信号组合成对, 本研究分别构建两个独立数据集并随机打乱信号片段, 消除了数据集之间的对应关系, 促进了用户无关的网络参数训练. 在测试阶段, 新用户无需提供任何训练数据, 确保了良好的用户体验.

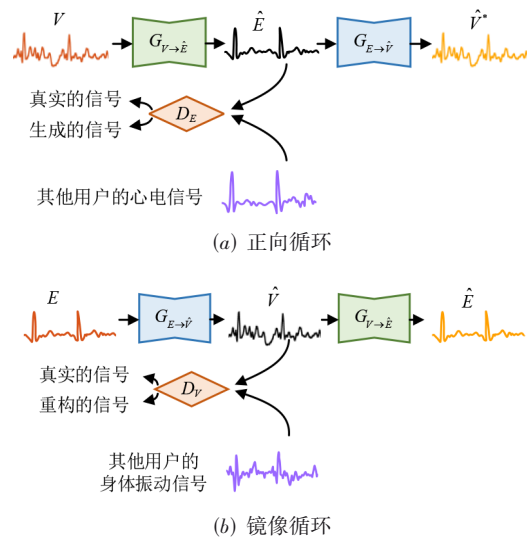


图8 基于CycleGAN的心电信号生成模型

具体来说, 生成器  $G_{E \rightarrow \hat{V}}$  和  $G_{V \rightarrow \hat{E}}$  都采用编码器-解码器(Encoder-Decoder)结构. 编码器将时间序列降维为固定形状的编码状态, 解码器将降维后的序列映射到新的时间序列. 生成器  $G_{V \rightarrow \hat{E}}$  需要学习心冲击振动信号到心电信号的正向映射关系, 是本研究训练的关注重点. 图9展示了  $G_{V \rightarrow \hat{E}}$  的结构, 其采用长短时记忆网络(Long Short Term Memory, LSTM)<sup>[27]</sup>作为基础网络, 其中编码器设计为双向的长短时记忆网络层(Bidirectional Long Short-Term Memory, BLSTM), 以提取心冲击

振动信号中的细粒度心脏活动模式. BLSTM 的输出编码了心脏活动的时间特征, 并形成了收缩通路. 解码器设计有两个堆叠的单向 LSTM, 从学习到的特征插值生成心电信号.




图9 生成器  $G_{V \to \hat{E}}$  的结构给出 ECG 全称

生成器  $G_{E \to \hat{V}}$  需要学习从心电信号到心冲击振动信号的逆向映射关系. 由于心电信号的形状复杂度远小于心冲击振动信号, 逆向映射的难度较大, 因此该生成器需要捕获不同级别的形状细节和瞬时信息. 其结构如图 10 显示, 网络将输入的心电信号片段通过插值拉伸为时长为 1.2 s 的序列, 然后将其输入到网络. 这种处理仅为了产生具有固定长度的数据, 并不会影响信号中所含的信息量. 编码器基于卷积神经网络 (Convolution Neural Network, CNN) 结构, 由两个堆叠的 CNN 块组成, 用于提取特征. 解码器基于反卷积神经网络 (DeConvolution Neural Network, DCNN) 结构, 同样设计成两个堆叠的 DCNN 块, 用于重建激活图的原始大小. 激活函数采用缩放指数线性单元 (Scaled Exponential Linear Units, SELU). 最后,  $G_{E \to \hat{V}}$  将生成的冲击振动信号重新拉伸, 使其与原始心电信号片段具有相同的长度.

判别器  $D_E$  和  $D_V$  采用相同的结构, 用于对真实数据

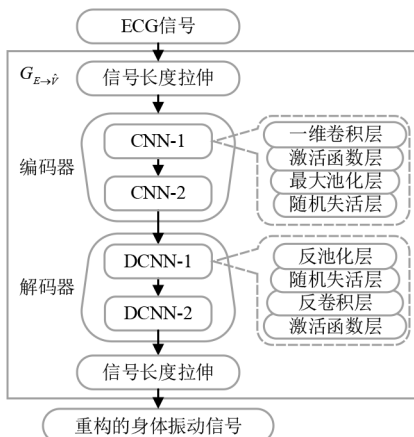


图10 生成器  $G_{E \to \hat{V}}$  的结构

和生成数据进行分类. 如图 11 所示, 时序信号首先要经过长度拉伸, 其长度变为  $1 \times 128$ . 判别器由四个级联的 CNN 块、一个全连接层和一个 Softmax 判别器  $D_E$  输出当前心电信号来自真实心电信号数据集的概率, 判别器  $D_V$  输出当前心冲击振动信号来自真实心冲击振动信号数据集的概率.

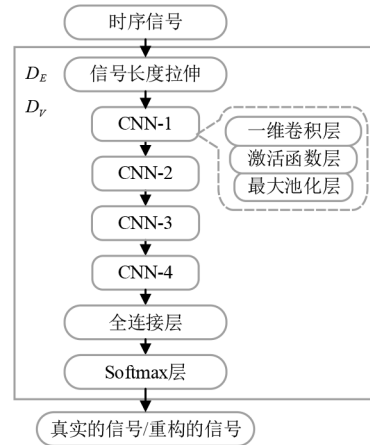


图11 判别器  $D_V$  和  $D_E$  的结构

#### 4.3.2 训练心电信号生成模型

训练心电信号生成模型通过定义损失函数并不断迭代使损失函数最小化实现. 本研究定义的损失函数包括两个部分.

(1) 对抗性损失: 本研究根据  $D_E$  和  $D_V$  两个判别器的对抗性损失来量化系统误差. 给定真实的和生成的的心电信号片段  $E$  和  $\hat{E}$ , 判别器  $D_E$  的对抗性损失为  $\mathcal{L}_a(D_E) = \mathbb{E}[\log D_E(E)] + \mathbb{E}[\log(1 - D_E(\hat{E}))]$ ; 对于真实的心冲击振动信号  $V$  和生成的的心冲击振动信号  $\hat{V}$ , 判别器  $D_V$  的对抗性损失可以计算为  $\mathcal{L}_a(D_V) = \mathbb{E}[\log D_V(V)] + \mathbb{E}[\log(1 - D_V(\hat{V}))]$ , 其中  $\mathbb{E}$  为期望计算符. 最终,  $G_{E \to \hat{V}}$  的目标函数为

$$\min_{G_{E \to \hat{V}}} \max_{D_E} \mathcal{L}_a(D_E) \quad (5)$$

类似地,  $G_{V \to \hat{E}}$  的目标函数为

$$\min_{G_{V \to \hat{E}}} \max_{D_V} \mathcal{L}_a(D_V) \quad (6)$$

(2) 循环一致性损失: 损失函数的另一个组成部分是循环一致性损失, 这也是网络实现用户无关特征的关键步骤.  $G_{V \to \hat{E}}$  和  $G_{E \to \hat{V}}$  的有效性和可循环性表现为输入真实心冲击振动信号  $V$  到  $G_{V \to \hat{E}}$  后生成的的心电信号  $\hat{E}$  再输入到  $G_{E \to \hat{V}}$  可以生成新的心冲击振动信号  $\hat{V}^*$ , 且  $\hat{V}^*$  与  $V$  具有极小的差异; 类似地, 输入真实心电信号  $E$  到  $G_{E \to \hat{V}}$ , 所生成的的心冲击振动信号  $G_{E \to \hat{V}}$  再输入到  $G_{V \to \hat{E}}$  可以生成新的心电信号  $\hat{E}^*$ , 且  $\hat{E}^*$  与  $E$  具有极小的差异. 因此, 循环一致性损失为  $\mathcal{L}_c(G_{V \to \hat{E}}, G_{E \to \hat{V}}) =$

$\mathbb{E}\left[\left\|\hat{V}^* - V\right\|_1\right] + \mathbb{E}\left[\left\|\hat{E}^* - E\right\|_1\right]$ . 最终,整体基于 CycleGAN 的网络模型最终损失函数定义为

$$\mathcal{L} = \alpha \mathcal{L}_a(D_E) + \alpha \mathcal{L}_a(D_V) + \lambda \mathcal{L}_c(G_{V \rightarrow \hat{E}}, G_{E \rightarrow \hat{V}}) \quad (7)$$

其中,  $\alpha$  是对抗损失系数,  $\lambda$  是循环一致性损失系数. 反复迭代并最小化目标损失函数可以训练有效的心电信号生成模型. 为了防止心动周期不同导致损失函数计算结果的误差,所有信号片段的切分均采用 4.2.2 节中描述的方法. 这一方法确保不同样例的信号具有相同的长度,且心冲击振动信号的尖峰点和心电信号的 QRS 波均位于同一位置.

## 5 实验验证与性能评估

### 5.1 实验设置

本研究使用了腕戴式陀螺仪传感器<sup>[28]</sup>作为实验设备,外观类似于智能手表,可通过蓝牙将角速度数据实时传输到电脑. 陀螺仪的采样率设置为 100 Hz,用于捕捉低于 30 Hz 的心冲击振动信号. 本研究所设计的心电信号生成模型具有多个参数,具体而言,生成器  $G_{V \rightarrow \hat{E}}$  中编码器与解码器分别采用 128、64、64、128 个 LSTM 隐藏单元,学习率为 0.01,衰减率 0.9;生成器  $G_{E \rightarrow \hat{V}}$  中的每个卷积运算使用 32 个滤波器,每个滤波器的内核大小为  $1 \times 10$ ,步幅为 1,随机失活层系数设置为 0.1 以确保模型的泛化性,防止模型过度拟合给定的训练数据样本集;判别器  $D_E$  和  $D_V$  采用四层卷积运算,滤波器数量逐渐增加,分别为 16、32、64 和 128,固定内核为  $1 \times 4$ ,步幅为 1.

为了评估系统性能,本研究招募了 18 名志愿者(年龄分布在 19 至 53 岁之间,包含 9 名男性和 9 名女性). 由于这些志愿者生活习惯各异,其心电信号波形呈现显著差异. 为了充分验证心电信号生成的性能,志愿者分别佩戴实验设备和临床级心电图仪(仅用于记录真实心电信号以评估系统的准确性,在使用时无需佩戴心电图仪),在身体保持静止和运动的情况下开展了实验.

### 5.2 评估方法

本研究通过比较利用心冲击振动信号生成的的心电信号  $\hat{E}$  与真实的心电信号  $E$  幅值的误差以及二者的相关性系数来评估心电信号生成的表现. 具体来说,幅值误差定义为<sup>[29]</sup>

$$\frac{1}{L} \sum_{i=1}^L \frac{|\hat{E}_i - E_i|}{\hat{E}_i} \quad (8)$$

其中,  $\hat{E}$  和  $E$  具有相同的信号长度  $L$ . 相关性系数定义为<sup>[30]</sup>

$$\frac{(E - \tilde{E})(\hat{E} - \tilde{\hat{E}})}{\sqrt{(E - \tilde{E})^2} \sqrt{(\hat{E} - \tilde{\hat{E}})^2}} \quad (9)$$

其中,  $\tilde{E}$  和  $\tilde{\hat{E}}$  分别表示全部  $E$  和  $\hat{E}$  样本的均值. 此外,为了更好地比较生成的信号和真实的信号,本研究利用互相关法对齐  $\hat{E}$  和  $E$ .

### 5.3 总体性能

#### 5.3.1 静止情况下的表现

本研究召集 18 名志愿者在实验室中保持身体静止的情况下,各自采集了约 30~50 min 的数据. 为了证明本研究提出的无感式连续血压监测系统无需新用户提供真实心电信号也能有效生成细粒度心电信号的有效性,我们用 17 名志愿者的数据训练了心电信号生成模型,然后用余下的 1 名志愿者的数据对模型进行测试. 结果显示,18 名志愿者的平均幅值误差为 7.92%. 每个志愿者数据的详细幅值误差在图 12(a)中展示. 从图中可以看出部分志愿者的幅值误差分布较集中,如 1、3、13、14 号志愿者;部分志愿者的幅值误差分布较为分散,如 5、6、7 号志愿者;但所有用户幅值误差的中位数均在 10% 以内. 美国国家标准协会允许心电监测系统所获取的心电信号具有低于 10% 的幅值误差<sup>[6]</sup>. 以上实验结果满足此医学标准,证实本研究提出的连续心电监测系统可以在静止状态下有效生成心电信号,且新用户无需提供训练数据,可以作为传统心电监测仪器的替代技术. 另外,18 名志愿者的平均相关性系数为 0.88. 图 12(b)展示了 18 名志愿者数据的详细相关性系数,尽管每位志愿者具有不同的相关性系数,但均大于 0.8. 当两个信号具有大于 0.8 的相关性系数时,可认为二者具有极强相关关系. 以上结果表明本研究提出的连续心电监测系统生成的的心电信号与真实心电信号具有高度相关性.

系统表现好时应有较低的幅值误差和较高的相关性系数,然而对比同一个用户的幅值误差和相关性系数可以发现幅值误差与相关性系数并不直接相关. 例如 15 号志愿者相比其他用户具有较高的幅值误差,却有较高的相关性系数. 2 号志愿者相比其他志愿者有较低的幅值误差,却有较低的相关性系数. 这表明本研究从幅值误差与相关性系数两个不同角度评价系统表现是必要的.

#### 5.3.2 运动情况下的表现

腕戴式智能设备集成的陀螺仪采集的数据易受到佩戴者身体运动的影响而畸变,因此研究运动情况下生成心电信号的表现至关重要. 本研究召集 18 名志愿者在家中执行吃饭、洗手、走路、瑜伽和跳绳等剧烈程度不同的日常运动,并采集了约 30~60 min 的数据. 本




图12 静止情况下生成心电信号的表现

研究以17名志愿者的数据训练心电生成模型,其余1名志愿者的数据测试心电生成模型,并分析了每种训练-测试数据组合下系统的表现。结果显示,未处理身体运动干扰时,平均幅值误差为33.14%,处理后降至9.02%;相关性系数从0.48上升至0.82。这些结果表明,消除身体运动干扰的方法有效,也证实了连续心电监测系统在运动状态下的可靠性。此外,表2展示了不同动态情况下系统的表现。例如,当用户做瑜伽时由于手部运动较缓慢,平均幅值误差最低,相关性系数最高;洗手情况下手部运动频繁,难以预测,对陀螺仪产生远强于心冲击振动的干扰,因此具有高于10%的幅值误差。尽管洗手的干扰较大,但由于其持续时间通常较短,连续心电监测系统仍具备良好的信号生成能力。

本文进一步研究了消除身体运动干扰的有效性。由于难以同时获得受身体运动干扰的和纯净的心冲击振动信号用作对比,本研究采用了新的评价指标衡量方法的有效性,即比较利用改进的NMF技术分离的心冲击振动信号和真实的心电信号的相邻两个波峰间的间隔(即波峰-波峰间隔)的误差。如果分离的心冲击振动信号足够准确,其波峰-波峰间隔应当与对应的心电信号的波峰-波峰间隔相匹配。表3总结了在五种运动类型下波峰-波峰间隔的平均误差。结果表明,在所有

情况下,平均误差均未超过25 ms,相较于心跳波峰-波峰间隔约为600~1 000 ms的范围,仅占其2.5%~4%,可见误差较小,从而证实了消除身体运动干扰的有效性。

表2 5种运动情况下生成心电信号的表现

运动类型	幅值误差/%	相关性系数
吃饭	8.31	0.85
洗手	11.24	0.71
走路	8.87	0.84
瑜伽	7.05	0.88
跳绳	9.61	0.81

表3 5种运动情况下分离的心冲击振动信号与心电信号的波峰-波峰间隔的误差

运动类型	波峰-波峰间隔误差/ms
吃饭	16.22
洗手	24.32
走路	15.41
瑜伽	9.29
跳绳	19.20

#### 5.4 不同机器学习方法识别尖峰点的性能对比

目前多种机器学习方法在识别信号中特征点方面都表现出卓越的性能。为了研究机器学习方法对识别尖峰点的影响,本研究实现了七种常用的机器学习分类器,包括K-近邻(K-Nearest Neighbors, K-NN)、随机森林(Random Forest, RF)、支持向量机(Support Vector Machine, SVM)、最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)、决策树(Decision Trees, DT)、逻辑回归(Logistic Regression, LR)和朴素贝叶斯方法(Naive Bayes, NB),并对比这些分类器的性能。考虑到尖峰点数量远小于非尖峰点,本研究采用均衡准确率评估尖峰点识别的准确性,避免评估指标受到不平衡的数据分布影响。均衡准确率定义为

$$\frac{1}{2} \left( \frac{TP}{TP+FN} + \frac{TN}{FP+TN} \right) \quad (10)$$

其中,TP、FN、TN和FP分别表示尖峰点被正确分类的样本数、尖峰点被错误分类的样本数、非尖峰点被正确分类的样本数以及非尖峰点被错误分类的样本数。

图13展示了不同分类器识别尖峰点的均衡准确率,从中可以观察到不同分类器性能具有差异,其中RF的均衡准确率最高,达到96.04%。因此,本研究采用RF识别尖峰点。

#### 5.5 影响因素

##### 5.5.1 采样率的影响

商用的腕戴式智能设备的采样率通常为50~400 Hz不等。较高的采样率有助于捕捉心冲击振动信号的细节,但也增加了计算成本;而较低的采样率则可能导致






图 13 不同机器学习识别尖峰点的均衡准确率

信息丢失,影响心电信号的生成精度.为了评估不同采样率下的表现,本研究召集 18 名志愿者佩戴具有不同采样率(分别为 50 Hz、100 Hz、200 Hz、300 Hz 和 400 Hz)的腕戴式设备开展了约 30 min 的实验.

图 14(a)和图 14(b)分别展示了 5 种采样率情况下全部志愿者数据的幅值误差和相关性系数.结果显示,所有情况下平均幅值误差均在 10% 以下,平均相关性系数均大于 0.8. 具体来说,50 Hz 采样率下的平均幅值误差最高,为 9.25%;而 100 Hz 采样率下降至 7.93%. 随着采样率的增加,幅值误差下降趋势变缓,并稳定在 7.8% 左右. 50 Hz 采样率下的平均相关性系数为 0.81, 提高到 100 Hz 后,达到 0.88. 随后的采样率提升,相关性系数稳定在 0.89 左右. 上述结果表明,本研究所提出的连续心电信号监测系统在不同采样率下均表现可靠. 尽管采样率越高,系统表现越好,但为了平衡精度和计算成本,本研究选择了 100 Hz 的采样率.



(a) 幅值误差




(b) 相关性系数


图 14 不同采样率情况下生成心电信号的表现

### 5.5.2 腕戴式设备佩戴位置的影响

不同用户习惯在不同位置佩戴腕戴式智能设备,如尺骨茎突处附近(手腕凸起的骨头)或远离该处.此外,日常生活中用户可能会改变佩戴位置.为了评估系统在不同位置的性能,本研究召集 18 名志愿者分别将设备佩戴在尺骨茎突处(0 cm)、尺骨茎突上方 1 cm、2 cm、3 cm 和 4 cm 处开展了约 30 min 的实验.本研究分别以 1 种位置处采集的数据做测试,其余 4 种位置处采集的数据做训练,5 种不同训练-测试情况分别记作情况 1 至情况 5.此外,本研究将全部位置处采集的数据混合,取其中 25% 数据用作测试,75% 用作训练,记为情况 6.图 15(a)和图 15(b)中分别比较了全部情况下生成心电信号的幅值误差和相关性系数.结果显示,所有情况下平均幅值误差均小于 10%;情况 6 的平均幅值误差最低,为 7.95%.情况 1 的幅值误差较高,表明与其他位置相比,将设备佩戴在尺骨茎突处采集的心冲击振动信号略有差异.此外,所有情况下平均相关性系数均大于 0.8,其中情况 6 具有最高的相关性系数,为 0.91.其他 5 种情况下相关性系数有所波动.以上实验结果表明设备佩戴在腕部不同位置时,系统生成的心电信号与真实的心电信号具有极为相似的波形.



(a) 幅值误差



(b) 相关性系数

图 15 不同设备佩戴位置情况下生成心电信号的表现

## 6 结论

长期连续监测心电信号在评估人体健康状态以及心脏、血管基本功能方面具有重要价值.本研究提出了一种基于循环生成对抗网络的连续心电信号感知方法,利用腕戴式智能设备集成的陀螺仪捕捉心冲击振

动信号,感知心跳活动信息,并生成高精度心电信号. 本研究提出一系列创新数据处理算法,包括一种基于改进NMF技术的身体运动干扰消除方法,从被身体运动干扰的陀螺仪数据中提取纯净的心冲击振动信号;研究了心冲击振动信号的形态特征,设计了一种基于机器学习方法切分心冲击振动信号中的心跳区间的方法;基于CycleGAN设计一种用户无关的心电信号生成模型,无需新用户提供训练数据即可根据心冲击振动信号精准生成心电信号. 本研究召集18名志愿者在身体保持静止和运动的情况下进行了实验,并研究了多种影响因素,实验结果表明本研究所提出的连续心电监测系统兼具准确性、可靠性和鲁棒性.

未来,基于腕戴式智能设备的连续心电监测系统将在智慧家庭、智能健康监护中扮演重要角色,有助于推断用户状态,及时发现异常健康状况. 为了更好地满足广泛人群在日常生活状态下连续监测心电信号的需求,未来工作将围绕用户体验展开进一步研究和实验,研究抗剧烈运动的心电信号生成模型,提高对多种场景的适应性.

#### 参考文献


- [1] POETSCH M, STRANO A, GUAN K. Role of leptin in cardiovascular diseases[J]. *Frontiers in Endocrinology*, 2020, 11: 1-13.
- [2] 国家心血管病中心. 中国心血管健康与疾病报告2021[M]. 北京: 科学出版社, 2022.  
National Center for Cardio-Vascular Diseases. Report on Cardiovascular Health and Diseases in China 2021[M]. Beijing: Science Press, 2022. (in Chinese)
- [3] 刘澄玉, 杨美程, 邸佳楠, 等. 穿戴式心电: 发展历程、核心技术与未来挑战[J]. *中国生物医学工程学报*, 2019, 38(6): 641-652.  
LIU C Y, YANG M C, DI J N, et al. Wearable ECG: History, key technologies and future challenges[J]. *Chinese Journal of Biomedical Engineering*, 2019, 38(6): 641-652. (in Chinese)
- [4] XU C H, LI H N, LI Z X, et al. Cardiacwave: A mmwave-based scheme of non-contact and high-definition heart activity computing[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2021, 5(3): 1-26.
- [5] SARHADDI F, KAZEMI K, AZIMI I, et al. A comprehensive accuracy assessment of Samsung smartwatch heart rate and heart rate variability[J]. *PLoS One*, 2022, 17(12): e0268361.
- [6] KLIGFIELD P, GETTES L S, BAILEY J J, et al. Recommendations for the standardization and interpretation of the electrocardiogram: Part I: The electrocardiogram and its technology: A scientific statement from the American heart association electrocardiography and arrhythmias committee, council on clinical cardiology; the American college of cardiology foundation; and the heart rhythm society: endorsed by the international society for computerized electrocardiology[J]. *Circulation*, 2007, 115(10): 1306-1324.
- [7] WU K F, ZHANG Y T. Contactless and continuous monitoring of heart electric activities through clothes on a sleeping bed[C]//2008 International Conference on Information Technology and Applications in Biomedicine. Piscataway: IEEE, 2008: 282-285.
- [8] LIM Y G, KIM K K, PARK K S. ECG measurement on a chair without conductive contact[J]. *IEEE Transactions on Bio-Medical Engineering*, 2006, 53(5): 956-959.
- [9] PARK J, CHO H, BALAN R K, et al. Heartquake: Accurate low-cost non-invasive ecg monitoring using bed-mounted geophones[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020, 4(3): 1-28.
- [10] KIM T, PARK J, SOHN J, et al. Bioinspired, highly stretchable, and conductive dry adhesives based on 1D-2D hybrid carbon nanocomposites for all-in-one ECG electrodes[J]. *ACS Nano*, 2016, 10(4): 4770-4778.
- [11] JIN G J, UDDIN M J, SHIM J S. Biomimetic cilia-patterned rubber electrode using ultra conductive polydimethylsiloxane [J]. *Advanced Functional Materials*, 2018, 28(50): 1804351.
- [12] DI RIENZO M, MERIGGI P, RIZZO F, et al. A wearable system for the seismocardiogram assessment in daily life conditions[C]//2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Piscataway: IEEE, 2011: 4263-4266.
- [13] 刘光达, 郭维, 李肃义, 等. 穿戴式人体参数连续监测系统[J]. *吉林大学学报(工学版)*, 2011, 41(3): 771-775.  
LIU G D, GUO W, LI S Y, et al. Wearable system for continuously monitoring physiological parameters[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2011, 41(3): 771-775. (in Chinese)
- [14] Apple. Take an ECG with the ECG app on apple watch[EB/OL]. [2023-05-30]. <https://support.apple.com/en-us/HT208955>.
- [15] Samsung. ECG at your fingertips[EB/OL]. [2023-05-30]. <https://www.samsung.com/us/apps/samsung-health-monitor/>.
- [16] XU X Y, YU J D, MA C G, et al. mmECG: Monitoring human cardiac cycle in driving environments leveraging millimeter wave[C]//IEEE INFOCOM 2022 - IEEE Conference on Computer Communications. Piscataway: IEEE, 2022: 90-99.
- [17] KIM C S, OBER S L, MCMURTRY M S, et al. Ballistocardiogram: Mechanism and potential for unobtrusive cardiovascular health monitoring[J]. *Scientific Reports*, 2016, 6: 31297.
- [18] YANG Z J, WEI Y L, SHEN S, et al. Ear-AR: Indoor acoustic augmented reality on earphones[C]//Proceedings of the 26th Annual International Conference on Mobile Computing and Networking. New York: ACM, 2020: 1-14.

- [19] CAO Y T, CHEN H J, LI F, et al. AWash: Handwashing assistance for the elderly with dementia *via* wearables[C]//IEEE INFOCOM 2021 - IEEE Conference on Computer Communications. Piscataway: IEEE, 2021: 1-10.
- [20] BA Z J, ZHENG T H, ZHANG X Y, et al. Learning-based practical smartphone eavesdropping with built-in accelerometer[C]//Proceedings 2020 Network and Distributed System Security Symposium. Reston: Internet Society, 2020: 23-26.
- [21] SU W G, LIU D B, ZHANG T Y, et al. Towards device independent eavesdropping on telephone conversations with built-in accelerometer[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2021, 5(4): 1-29.
- [22] MIGEOTTE P F, MUCCI V, DELIÈRE Q, et al. Multi-Dimensional kineticardiography a new approach for wearable cardiac monitoring through body acceleration recordings[M]//IFMBE Proceedings. Cham: Springer International Publishing, 2016: 1125-1130.
- [23] CHAWLA M P S. PCA and ICA processing methods for removal of artifacts and noise in electrocardiograms: A survey and comparison[J]. Applied Soft Computing, 2011, 11(2): 2216-2226.
- [24] ZHAO Q B, ZHANG L Q. ECG feature extraction and classification using wavelet transform and support vector machines[C]//2005 International Conference on Neural Networks and Brain. Piscataway: IEEE, 2005: 1089-1092.
- [25] 陈习坤, 杨俊美. 基于离散小波包变换与胶囊生成对抗网络的语音超分辨率算法[J]. 电子学报, 2023, 51(4): 1039-1049.
- CHEN X K, YANG J M. Speech super-resolution algorithm based on discrete wavelet packet transform and capsule generative adversarial network[J]. Acta Electronica Sinica, 2023, 51(4): 1039-1049. (in Chinese)
- [26] 裴焯, 邱文涛, 王森, 等. 基于Transformer动态场景信息生成对抗网络的行人轨迹预测方法[J]. 电子学报, 2022, 50(7): 1537-1547.
- PEI Z, QIU W T, WANG M, et al. Pedestrian trajectory prediction method using dynamic scene information based transformer generative adversarial network[J]. Acta Electronica Sinica, 2022, 50(7): 1537-1547. (in Chinese)
- [27] 谢昭, 周义, 吴克伟, 等. 基于时空关注度 LSTM 的行为识别[J]. 计算机学报, 2021, 44(2): 261-274.
- XIE Z, ZHOU Y, WU K W, et al. Activity recognition based on spatial-temporal attention LSTM[J]. Chinese Journal of Computers, 2021, 44(2): 261-274. (in Chinese)
- [28] Witmotion. Witmotion BWT901[EB/OL]. [2023-05-30]. <https://github.com/WITMOTION/BWT901>.
- [29] AMIL P, SORIANO M C, MASOLLER C. Machine

learning algorithms for predicting the amplitude of chaotic laser pulses[J]. Chaos: an Interdisciplinary Journal of Nonlinear Science, 2019, 29(11): 113111.

- [30] DE WINTER J C F, GOSLING S D, POTTER J. Comparing the pearson and spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data[J]. Psychological Methods, 2016, 21(3): 273-290.

### 作者简介



**曹焯彤** 女, 1995年3月出生, 河北保定人. 毕业于北京理工大学并获得博士学位, 现为山东大学计算机科学与技术学院研究员. 主要研究方向为物联网、智能感知、移动计算、智慧健康.

E-mail: yetong.cao@sdu.edu.cn




**李凡** 女, 1975年5月出生, 湖北武汉人. 1988年毕业于美国北卡罗来纳大学计算机科学与技术学院, 现为北京理工大学教授. 主要研究方向为智能感知、计算机网络、移动计算.

E-mail: fli@bit.edu.cn



**刘晓晨** 女, 1997年出生, 山东滨州人. 毕业于中国石油大学(华东)并获得学士学位, 现为北京理工大学博士研究生. 主要研究方向为物联网、可穿戴计算.

E-mail: xiaochenliu@bit.edu.cn



**谢皖冉** 女, 1999年出生, 四川内江人. 毕业于中国海洋大学并获得学士学位, 现为北京理工大学硕士研究生. 主要研究方向为物联网、可穿戴计算.

E-mail: huanranxie@bit.edu.cn



**陈慧杰** 男, 1989年出生, 河南新乡人. 毕业于北京理工大学并获得博士学位, 现为北京工业大学讲师. 主要研究方向为智能物联网、泛在智能感知.

E-mail: chenhuijie@bjut.edu.cn