

基于智能手机的生命参数检测方法研究

朱珍民¹ 郭高安^{1,2} 马官慧^{1,3} 许晓莹⁴

¹(中国科学院计算技术研究所 北京 100190)

²(中国科学院大学 北京 100049)

³(中南大学 长沙 410083)

⁴(湘潭大学 湘潭 411105)

摘要 智能手机可用于老年人和慢病患者生命特征参数及其变化的监测,降低意外生命安全风险。文章介绍了基于智能手机传感器检测生命体征参数的方法,研究了一种新的基于算法融合的检测方法,提出了两套手机集成监测方案并实现了相应的演示系统。通过与专业检测设备对比,验证了方法的有效性。

关键词 手机传感器;呼吸率;心率/心律;血氧饱和度;无创监测;远程监护

中图分类号 TP 391 文献标志码 A

Vital Parameters Detection Methods With a Smart Phone

ZHU Zhenmin¹ GUO Gao'an^{1,2} MA Guanhui^{1,3} XU Xiaoying⁴

¹(Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China)

²(University of Chinese Academy of Sciences, Beijing 100049, China)

³(Central South University, Changsha 410083, China)

⁴(Xiangtan University, Xiangtan 411105, China)

Abstract Smart phones are becoming more popular, more powerful and have a variety of sensors available to capture information from the outside world, process the data in real-time, and transfer information remotely using wireless communications. These factors make smart phones an ideal option as a “take-anywhere” physiological monitor without the need for additional hardware, and their potential has been explored for many medical tele-monitoring applications. In this paper, we describe a few methods that perceived of human activity parameters and vital signs parameters using the existing sensors of smart phones. In addition, in order to make the fusion and integration of several monitoring methods realized, we proposed a new monitoring approach and gave an integrated solution. Finally, through comparisons with the professional health equipment, the effectiveness of the approach was verified.

Keywords phone sensors; breathing rate; heart rate variability; oxygen saturation; noninvasive monitoring; tele-monitoring

收稿日期: 2014-2-26

基金项目: 国家科技支撑计划课题(2013BAI04B01)。

作者简介: 朱珍民(通讯作者), 博士, 教授, 研究方向为普适计算、情境感知、嵌入式技术和可穿戴技术等, E-mail: zmzhu@ict.ac.cn; 郭高安, 硕士研究生, 研究方向为普适计算、移动医疗与健康; 马官慧, 硕士研究生, 研究方向为统计分析、医疗与健康数据挖掘分析; 许晓莹, 硕士研究生, 研究方向为普适计算、医疗与健康数据挖掘分析。

1 引 言

全球人口老龄化速度加剧。据联合国统计, 2010 年底全球 65 岁以上人口为 5.23 亿, 到 2050 年将达到 15 亿。中国人口老龄化速度更快, 自 2001 年迈入老龄化社会, 2011 年底 65 岁以上人口占比 9.1%(达到 1.23 亿), 预期 2030 年中国将成为全球人口老龄化程度最高的国家, 2050 年进入深度老龄化社会, 典型的“未富先老”国家。老年人独居户现象也非常突出, 城市老年人独居户占比 49.7%, 农村老人独居户占比 38.3%。老年人体弱, 而且大多数老年人受到糖尿病、心脑血管疾病等全球性“杀手级”慢性疾病的困扰, 严重威胁老年人的生命安全。需要便携式或者可穿戴式的低成本信息技术产品为老龄化社会分忧, 为老年人解难。基于智能手机(带有多种传感器)的健康指标或生命体征指标参数的实时监测技术成为一种合适的选择。许多研发人员开展了智能手机的健康用途研究和开发, 智能手机厂商也在积极参与健康手机的研制^[1-6]。

目前, 智能手机的普及率越来越高, 全球智能手机用户数已超过 7 亿。智能手机(如 Android、iOS)支持十多种传感器, 基于这些传感器已经开发出丰富的应用, 如基于接近传感器、光亮度传感器的锁屏和节能应用, 基于惯性传感器的导航辅助、手机防盗、人体姿态和跌倒监测, 基于方向传感器、磁场传感器的数字罗盘。近几年来, 许多研发人员更是将智能手机的应用拓展到了身体运动鉴别、生理参数监测和远程医疗监控。例如, 基于视频传感器采集皮肤颜色变化来估算心率 HR(Heart Rate)、脉率 PR(Pulsatile Rate)^[1-2]、血氧饱和度 SpO₂(Oxygen Saturation)^[3]; 利用声音传感器监测睡眠呼吸状况; 基于加速度传感器估算呼吸率^[4]; 综合利用手机视频传感器和加速度传感器估计人体血压^[5]; 利用手机压力传感器估计人的肺活量^[6];

利用手机加速度传感器和陀螺仪来追踪人体运动过程中卡路里消耗, 督促人们改变不健康的生活方式^[7]; 利用惯性传感器和方位传感器感测身体运动行为(走、跑、跳和跌倒), 估计人体姿态和航迹推算; 利用磁场传感器和通信信号(WiFi、BlueTooth)对人进行定位。智能手机传感器种类的广泛性和传感器的灵敏性以及普及率, 必将使其成为便携式情景感知的重要工具和应用对象。

2 基于手机传感器的生命参数直接检测与估算方法

人的主要生命参数包括: 心率/脉率、呼吸率、肺活量、血氧饱和度、血压和体温等。由于体温降低发生在生命特征消失之后, 所以无急救意义。前五项(特别是前两项)生命参数的监测均能够及时地捕捉意外情况的发生, 并具有急救缓冲时间。

2.1 心率/脉率估算方法

心率是最重要的生命参数, 其大小与稳定性直接反映一个人的健康状况, 对心率进行实时监测可以实现对病人健康异常的及时反应, 降低因心率不齐引起的死亡率。可以利用手机光电传感器和加速度传感器来研究心率的测量方法。

心脏跳动会导致皮肤颜色的细微变化, 这种变化在脸部和手指位置更为明显。目前的智能手机摄像头可以捕捉这些细微变化, 由此可以捕捉到心跳的变化。

基于人脸 RGB 信号的心率检测。2012 年, Kwon 等^[1]提出了基于手机摄像头的心率检测方法。该方法通过手机前置摄像头采集人脸视频信号, 利用人脸识别算法获得感兴趣区域并把区域内的信号按 RGB 三个信道求出像素平均 $x_{ch}(t)$ 值, 其中 $ch = \{R, G, B\}$; 然后对每窗的 $x_{ch}(t)$ 进行标准化 $y_{ch}(t) = (x_{ch}(t) - \mu_{ch})/\sigma_{ch}$, 其中 μ_{ch} 和 σ_{ch} 分别是 $x_{ch}(t)$ 的均值和标准差; 再对标准化后的信号

$y_{ch}(t)$ 进行时域图的波峰检测, 从而得到手机计算的心率。通过对 10 人的手机计算结果与心电采集系统得到的结果进行对比, 发现平均误差仅为 1.04%。该方法对手机与人脸相对姿势的稳定保持以及环境光干扰等因素比较敏感, 在采集到的信号质量比较差时会得出错误估算结果。

基于手指 RGB 信号的心率检测。通过手机摄像头获取手指的颜色信号来计算人的心率, 考虑到手机采集手指颜色信号会受手指摆放位置偏差、手指运动以及指压过大等因素的影响, Pal 等^[2]在研究中引入了有限状态机, 通过设置启发式阈值来对颜色信号进行筛选, 能识别运动伪影和避免前述影响, 进而得到稳定的心率估计。算法流程如图 1 所示。在图 1 中, μ_r 表示平均红色成分, σ 为其方差, α 为启发式阈值, ε 为有效帧数下界。

2.2 呼吸率估算方法

呼吸率是一项非常重要的生命体征信号, 在临床和家庭护理中起着非常重要的作用。传统医用呼吸监测装置常采用应变式传感器、温度传感器、流量传感器和电容传感器等, 但是这些装置会不同程度地给被检测者带来不适感, 且成本太高。需要使用便利或配戴舒适的装置来测量人的呼吸率, 而智能手机或可穿戴式装置是不错的选择。

2013 年, Gupta 等^[4]利用手机加速度传感器测量腹部位置加速度信号来估计呼吸率, 并且评价呼吸质量。该方法通过手机加速度 z 轴方向的测量结果对呼吸率进行估计, 对正常呼吸、慢速呼吸、快速呼吸和非正常呼吸者均有较高的估计精度。与呼吸测量仪测得的呼吸率相比, 估计精度达到 95%~100%。但是该方法对测试环境有苛刻要求, 只适合静息腹式呼吸人群。一般情况下, 用该方法所测量的加速度信号是混合信号, 且呼吸信号只是其中的低频信号。

2.3 肺活量估算方法

肺活量能反映一次呼吸的最大通气能力。成年男性的正常肺活量为 3500 mL, 成年女性为 2500 mL, 老年人的肺活量则偏低。肺活量反映了呼吸肌收缩的力量及幅度, 能够检测肺的通气功能以及肺部气体的实际容量。

2012 年, Larson 等^[6]提出了利用深呼吸声音信号和基于机器学习回归的肺活量估算方法, 并开发出相应的手机软件 SpiroSmart。该方法的步骤如下:

(1) 采集呼气过程中产生的声音信号。用户拿着自己的智能手机, 保持一只胳膊的距离深吸一口气, 然后再迅速而有力地呼出, 采集这一过程的声音信号 $p(t)$ 。

(2) 损失补偿和特征提取(见图 2)。用

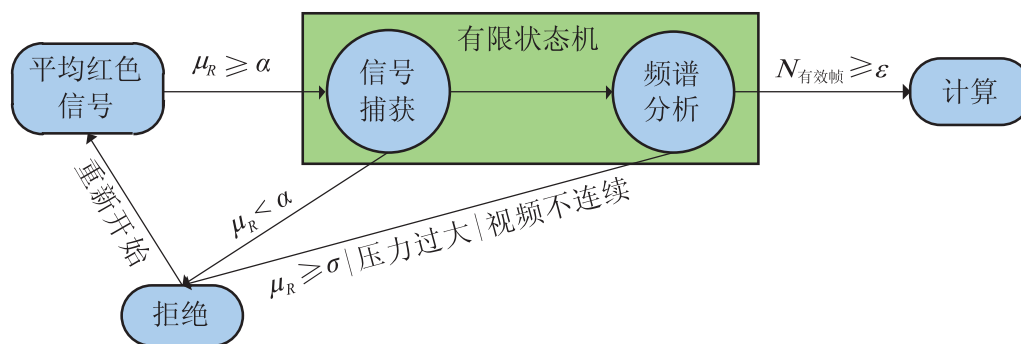


图 1 基于有限状态机的心率估算算法流程图

Fig. 1. Mealy machine of PPG based heart rate detection

逆辐射模型对 $p(t)$ 进行变换, 得到 $p_{lips}(t)$ 作为对损失信号的补偿; 将压力信号 $p_{lips}(t)$ 经非线性流变换得到流速信号 $\mu_{lips}(t)$, 其中, $\mu_{lips}(t) = 2\pi r_{lips}^2 \sqrt{2p_{lips}(t)}$, r_{lips} 是呼气口半径。最后将 $p(t)$ 、 $p_{lips}(t)$ 和 $\mu_{lips}(t)$ 输入到特征提取模块。特征提取包括包络检测、线性预测和频谱处理 3 个工作。包络检测: 对时域信号进行 Hilbert 变换, 将变换后信号加到原始信号上, 再进行低通滤波, 最后对滤波后的信号进行下采样。线性预测: 将声音信号再次输入到 30 ms 的重叠帧中, 然后进行 2、4、8、16 和 32 阶的线性滤波, 最后进行低通滤波。频谱处理: 对缓存中的数据进行 FFT 得到信号的幅度谱图; 然后进行共振追踪 (针对每个快速傅里叶变换后的帧, 选取最大值所对应的频率, 所有大于全局最大值 20% 的局部最大值都被保存, 最后形成一个滑动窗口), 对所有的帧都处理完成后, 共振时间小于 300 ms 的均被视为噪音, 并计算保存共振幅度的平均

值; 最后对共振信号的均值进行低通滤波。值得注意的是, 包络检验、频谱图处理和线性预测处理最后提取出的特征均具有相同的采样频率。此步最后提取出声音的流速特征。

(3) 基于机器学习的回归处理。将流速特征信息进行去噪处理, 然后再分别进行肺功能回归和曲线回归。肺功能回归采用袋装决策树回归方法, 每个回归森林由 100 个决策树组成; 曲线回归过程中则采用条件随机场和袋装决策树回归方法。

通过对 52 个个体的实验发现, 与专业肺活量仪相比, SpiroSmart 的测量误差小于 6.3%。然而, SpiroSmart 软件仍存在一定局限性: 当人在吸气的声音很小时, 手机无法进行测量, 因此吸入空气总量这个因素无法考虑在内; 测试时需要比较安静的环境; 最大肺活量值有误差。

2.4 血氧饱和度估算方法

血氧饱和度 SpO_2 是指在全部血容量中氧合

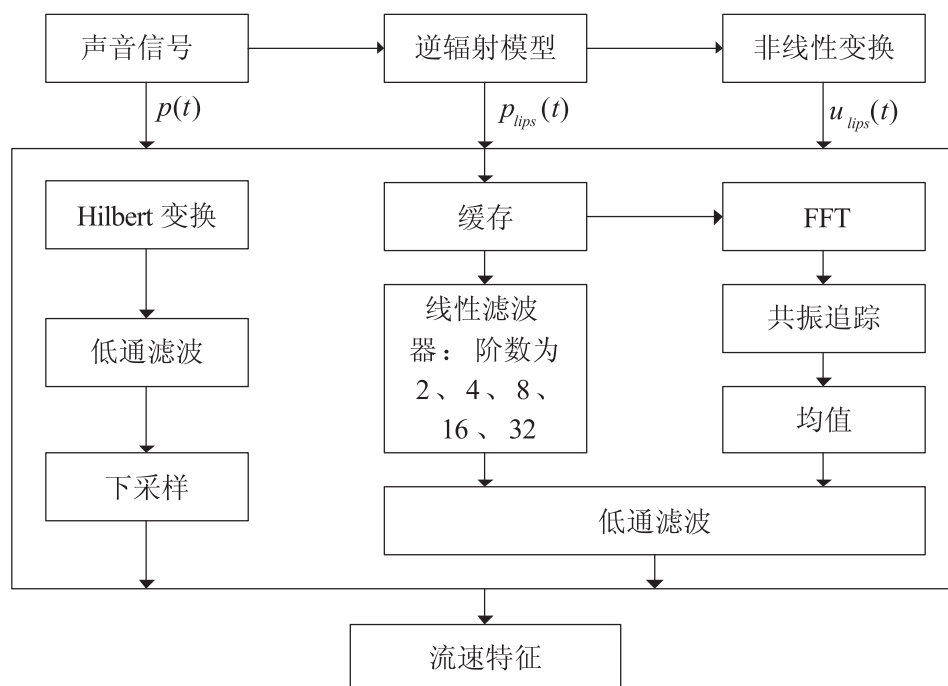


图 2 特征提取

Fig. 2. Block diagram of SpiroSmart's feature extraction

血红蛋白(HbO₂)占全部血红蛋白(Hb)的比例。血氧饱和度是反映机体内氧状况的重要生理指标,一般认为血氧饱和度正常值应不低于94%,在94%以下被视为供氧不足。传统脉氧仪基于Beer-Lambert定律实现SpO₂计算^[8]:

$$\text{SpO}_2 = A - B \times \frac{c(\lambda_1)}{c(\lambda_2)} \quad (1)$$

其中, A 、 B 表示经验参数; λ_1 表示红光波长(660 nm); λ_2 表示红外光波长(940 nm); $c(\lambda_1)$ 为血液的吸光率。

吸光率的计算公式为:

$$\begin{cases} C = \log_{10}(I_{in}/I_{out}) \\ I_{out} = I_{in} \times 10^{-acd} \end{cases} \quad (2)$$

其中, I_{out} 表示出射光强度; I_{in} 表示入射光强度; α 表示血液样本对特定光的摩尔吸收率; c 表示血液样本的浓度; d 表示特定光的射程长度。

由于红外光不可见,所以手机无法直接捕捉。但根据颜色空间理论,三原色RGB中蓝光的性质与红外光最接近。2012年,Scully等^[3]利用手机摄像头采集皮肤表面RGB颜色信号序列来估算相对血氧饱和度,研究过程中参照光用蓝光来代替。首先用脉氧仪测得的SpO₂信号与手机测得的红光和蓝光信号对 A 、 B 进行回归估计,然后用计算得到的估计值以及红光和蓝光信号对SpO₂进行计算:

$$\text{SpO}_2 = A - B \times \frac{AC_R/DC_R}{AC_B/DC_B} \quad (3)$$

其中, AC_R 、 AC_B 为交流信号,分别表示红光和蓝光的方差; DC_R 、 DC_B 为直流信号,分别表示红光和蓝光的均值。计算得出的SpO₂数据和脉氧仪测得的结果较吻合,测量误差低于5%。

2.5 血压估算方法

血压(Blood Pressure)是指血管内的血液在单

位面积上的侧压力,反映心脏的收缩舒张能力。一般人的正常收缩压为90~140 mmHg,舒张压为60~90 mmHg。

2013年,Chandrasekaran等^[5]设计了利用两部手机测量人体血压的方法,其中一部手机用来测量心跳信号,检测所得信号的波峰,记录其对应的时间,进而得出每两次心跳的间隔时间 VTT ;另一部手机用来测量脉搏信号,由于心脏正常情况下脉率等于心率,所以直接检测脉搏信号的波峰就可以得出心率值 HR 。通过与专业的血压计相比,该方法的测量精度达到了95%~100%。收缩压 P_s (Systolic Pressure)及舒张压 P_d (Diastolic Pressure)计算公式为:

$$\begin{cases} P_s = -0.425 \times VTT + 214 \\ P_d = P_s - P_p \end{cases} \quad (4)$$

其中, $P_p = SV / [(0.013 \times W_t - 0.007 \times age - 0.004 \times HR) + 1.307]$ 是脉压估计; W_t 是信号固定窗长; $SV = -6.6 + 0.25 \times (ET - 35) - 0.62 \times HR + 40.4 \times BSA - 0.51 \times age$ 是心搏量估计, ET 表示每次血液循环射血时间,而 $BSA = 0.007184 \times weight^{0.425} \times height^{0.725}$ 。

Choudhury等^[9]给出了利用单部手机测量PPG(photoplethysmograph)信号来估算血压的方法。其处理过程包括:(1)对手机测得的PPG信号进行去噪处理,得到稳定的PPG信号;(2)对稳定信号提取出特征(包括收缩振幅、脉冲宽度、脉冲面积、峰间间隔和脉冲间隔等统计量);(3)将舒张压和收缩压均设定为“很低、低、正常、高和很高”几个水平,基于(2)中给出的特征统计量来训练线性回归模型和支持向量机模型来对数据进行分类。在不考虑身高、体重和年龄信息的情况下,此方法的实验估计精度达到了75%,若考虑了身高、体重和年龄等信息则估计准确度达到95%。

3 基于手机传感器的生命参数融合估算方法

主要讨论两类集成监测方法。一类是基于多种感知参数指标的数据融合算法,此方法将生命体征与外在环境的关联性考虑在内;另一类是基于新的信号分析成果的方法融合算法,此方法考虑到手机传感器检测到的信号弱而杂(非线性、非平稳)等因素的影响。

3.1 基于加速度和 GPS 信号的多参数融合心率估算算法

虽然基于手机光电传感器来测量心率的技术已经趋于成熟(参见 2.1),但是这类方法及其相应的手机软件只适用于测量非运动状态下的心率,导致在现实生活中普适效果比较差。为了提高普适性,测量人在运动状态下的心率变化情况,Mayu 等^[7]提出了基于带有监督学习的多层神经网络模型的心率估算算法。该算法通过手机加速度传感器和 GPS 传感器对 18 个人的 5 种不同运动路线进行实验采样,之后利用航迹推算方法来计算第 k 个时间窗的路程 D_k 以及第 k 个时间窗的行走速度 V_k ,利用 GPS 导航仪来测量路线梯度 G_k ,然后根据走路速度 V_k 和路线梯度 G_k 来计算走路过程中的耗氧量;另外根据手机加速度传感器可以实时测量运动过程中的加速度垂直分量和水平分量;利用 weka 软件进行有监督学习来构造多层神经网络模型,将加速度垂直分量、加速度水平分量、路线梯度和耗氧量作为输入,心率作为输出。最后进行估算结果的评估。估算算法步骤如下:

(1) 路线梯度和耗氧量变化的计算。

① 基于航迹推算方法计算走路步速 V_k 。

$$\begin{cases} V_k = \frac{D_k}{W} \\ D_k = ST_k \times SL \\ SL = \frac{D_{total}}{ST_{total}} \end{cases} \quad (5)$$

其中, D_k 表示第 k 个时间窗的路程; W 表示时间窗长度; ST_k 表示第 k 个时间窗的步数; SL 表示步长; D_{total} 表示总路程; ST_{total} 表示总步数。

② 基于海拔高度 H_k 和走路位移路程 D_k 来计算路线梯度 G_k 。

$$G_k = \frac{H_k}{D_k} \times 100\% \quad (6)$$

③ 计算需氧量 O [mL/kg/min]。

$$\begin{cases} O = O_h + O_v + O_r \\ O_h = 0.1 \times V_k \times M_h \\ O_v = 1.8 \times V_k \times G_k \times M_v \end{cases} \quad (7)$$

其中, O_r 表示休息时的耗氧量(经验值 $O_r=3.5$); O_h 和 O_v 分别表示速度的水平分量和垂直分量的耗氧量; M_h 和 M_v 分别表示与速度的水平分量和垂直分量耗氧量在个体间的差异系数,通过最小化估计耗氧量和实际耗氧量之间平均误差来求解。

④ 计算耗氧量变化。

在进行行走运动时,耗氧量并不立刻随着运动强度的变化而变化,而是在运动开始后的 2~3 分钟内慢慢接近于稳定值,这个稳定值就是③中所说的需氧量。耗氧量的增加量和减少量分别用 ΔO 和 ∇O 表示,计算公式如下:

$$\begin{cases} \Delta O = O \times e^{-\frac{\tau}{t}} \\ \nabla O = O \times (1 - e^{-\frac{\tau}{t}}) \end{cases} \quad (8)$$

其中, τ 表示耗氧量趋近于需氧量时的时刻; t 表示运动已持续时间。

(2) 构造基于带有监督学习的多层神经网络模型来估算心率。

① 基于神经网络估算心率。此过程中用到了数据挖掘软件 weka 进行有监督学习,构造多层神经网络模型(如图 3 所示),基于此模型估算出

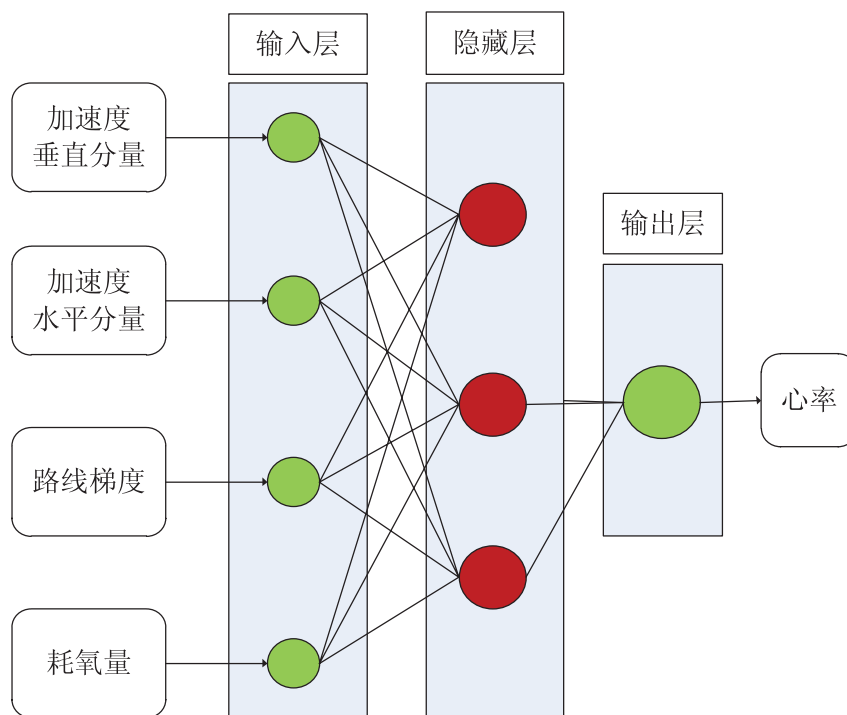


图3 神经网络结构图

Fig. 3. The structure of neural network

心率。

②标准化心率数据, 消除心率个体差异, 从而使模型学习的是心率变化。标准化公式如下:

$$\overline{HR}_i = HR_i + (HR_r - HR_s) \quad (9)$$

其中, HR_i 表示未标注化心率; HR_r 表示休息时的心率; HR_s 表示运动初始时刻的心率; \overline{HR}_i 作为机器学习的神经网络的输出值。

(3) 估算结果评估。

最后对手机计算出的心率估算结果进行评估。将来自 18 个人的 5 种不同路线的数据分类: ①根据人们日常锻炼的时间将 18 个人分为三组: 每周锻炼两次, 每次 30 分钟以上, 锻炼持续时间已经超过一年; 不锻炼; 介于两者之间。②为了检测用手机测心率的准确性, 定义了四种类型的模型 $M = \{RP00, RP01, RP10, RP11\}$ 。其中 P 代表人, R 代表路线, 数字表示是否选择个体 P 或者路线 R 的数据进行模型评估。评估公

式如下:

$$MAE(P, R, M) = \frac{\sum_{i=0}^{n-1} |p_{hr_M}(\frac{W}{2}i) - r_{hr}(\frac{W}{2}i)|}{n}, \quad (10)$$

$$n = \frac{2T}{W}$$

其中, T 表示走路的持续时间; W 表示窗口长度; M 表示路程类型; $p_{hr_M}(t)$ 表示 M 类型在 t 时刻的预测心率; $r_{hr}(t)$ 表示 t 时刻的实际心率。

引入耗氧量和标准化心率数据能在一定程度上减小 MAE 值和心率变化方差, 提高实验结果的准确性。评估结果显示, 不同模型的 MAE 值均小于 7, 与人在正常休息状态下的心率变异基本一致, 说明用此种方法来测量运动过程中心率的变化是有效的。但该方法对心率变异性学习能力有待加强。

3.2 基于方法融合算法的估算

近年来, 将一些复杂的数学统计方法应用到信号处理过程中, 获得了很好的处理效果。

典型的算法有：奇异值分解 SVD (Singular Value Decomposition) 算法、多分辨率小波分解的 Mallat 算法和经验模态分解 EMD (Empirical Mode Decomposition) 算法等。基于手机传感器进行生命参数感知的方法受到多种因素制约：可用传感器少、信号精度有限、多混叠信号和易受干扰等，这些感知到的信号一般具有非线性和非平稳性。而 SVD 算法是分析非线性、非平稳信号的有效工具^[11]，在信号去噪^[12]、信号分离^[13-14]等方面都具有一定优势。Mallat 小波算法在时域和频域内部都表现出极强的信号局部特征表征能力。小波变换后的结果在低频部分有较高的分辨率，在高频部分有较低的频率分辨率，能对信号进行多分辨率分析^[15]。EMD 算法可将信号分解成一系列本征模函数 IMF (Intrinsic Mode Function) 分量，使得各 IMF 分量是窄带信号，即将一个复杂信号分解成多个简单信号的过程^[21]。

3.2.1 算法

(1) SVD 算法

SVD 算法的主要步骤^[16]：

①信号嵌入。令时间序列 $s = \{s_0, s_1, \dots, s_{r-1}\}$, $r > 2$ 。将 s 映射为 1 维列向量 x_i ，即：

$$x_i = [s_{i-1}, s_i, \dots, s_{i+l-2}]^T, (1 \leq i \leq k) \quad (11)$$

其中， $k = r - l + 1$ ； l 是窗口长度 ($1 \leq l \leq r$)， l 的下界和上界分别是 f_s/f_L 和 $r/2$ ； f_s 是采样频率， f_L 是最小的感兴趣频率。由此形成一个 $l \times k$ 的嵌入矩阵 X 。

$$X = \begin{bmatrix} s_0 & s_1 & \dots & s_{k-1} \\ s_1 & s_2 & \dots & s_k \\ \vdots & \vdots & \ddots & \vdots \\ s_{l-1} & s_l & \dots & s_{r-1} \end{bmatrix} \quad (12)$$

②特征值分解。令 $S = XX^T$ ， $\lambda_1, \lambda_2, \dots, \lambda_l$ 为 S 的特征值，且 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l \geq 0$ ， e_1, e_2, \dots, e_l 为对应的特征向量。如果令 $v_i = X^T e_i / \sqrt{\lambda_i}$ ，则

X 可以表示成：

$$X = X_1 + X_2 + \dots + X_d \quad (13)$$

其中， $d = \text{argmax}_i \{\lambda_i > 0\}$ ， $X_i = \sqrt{\lambda_i} e_i v_i^T$ 。把 $(\sqrt{\lambda_i}, e_i, v_i)$ 称为 SVD 的本征元组。

这样就将时间序列投影到每个特征向量方向上，得到相应的时域主分量。

③信号分组。按照一定规则(感兴趣的信号)将 d 个本征元组(即 X_i)分成 M 组： I_1, I_2, \dots, I_M ，其中 $I_m = \{i_{m1}, \dots, i_{mp}\}$ ，得到 $X_{I_m} = X_{i_{m1}} + \dots + X_{i_{mp}}$ ，得到

$$X = X_{I_1} + \dots + X_{I_M} \quad (14)$$

这样就可以通过选取本征元组，进而选取出感兴趣的矩阵信号分量。

④信号序列重构(对角平均)^[17]。将每组矩阵 X_{I_m} 变换为长度为 r 的序列 s_{I_m} 。 s_{I_m} 的第 $q \in [0, r)$ 个位置的值 g_q 为矩阵中满足 $i+j-2=q$ 的所有元素 $(X_{I_m})_{ij}$ (斜对角)的平均值。由此得到所需提取的信号序列。

(2) Mallat 算法

实际应用中一般采用离散小波变换，即尺度参数和平移参数是离散化的，最常用的是二进制小波：

$$\psi_{j,k} = 2^{-j/2} \psi(2^{-j}t - k), \quad j, k \in Z \quad (15)$$

Mallat 塔式算法更是得到广泛应用^[18,19]。算法原理如下：设 $\{V_j\}$ 是一给定的多分辨率分析， $\varphi(t)$ 和 $\psi(t)$ 分别是分辨率 2^j 下相应的尺度函数和小波函数，现在要对一个信号 $s(t)$ 进行分析，设 $f(t) \in V_j$ ($J \in Z$ ，是一确定整数)，则有分解^[20]：

$$s(t) = A_J s(t) = \sum_{k=-\infty}^{\infty} c_{J,k} \varphi_{J,k}(t) \quad (16)$$

若 $\langle \varphi_{j,k}(t), \varphi_{j-1,m}(t) \rangle = h^*(k-2m)$ ，

$\langle \varphi_{j,k}(t), \psi_{j-1,m}(t) \rangle = g^*(k-2m)$ ，则有：

$$A_j s(t) = A_{j-1} s(t) + D_{j-1} s(t) \quad (17)$$

其中,

$$\begin{cases} A_{j-1} s(t) = \sum_{k=-\infty}^{\infty} c_{j-1,k} \varphi_{j-1,k}(t) \\ D_{j-1} s(t) = \sum_{k=-\infty}^{\infty} d_{j-1,k} \psi_{j-1,k}(t) \end{cases} \quad (18)$$

而

$$\begin{cases} c_{j-1,k} = \sum_{m=-\infty}^{\infty} h^*(m-2k) c_{j,m} \\ d_{j-1,k} = \sum_{m=-\infty}^{\infty} g^*(m-2k) d_{j,m} \end{cases} \quad (19)$$

这样将式(17)一直做下去, 式(16)将有分解:

$$s(t) = A_j s(t) = A_l(t) + \sum_{j=l}^{J-1} D_j s(t) \quad (20)$$

(3) EMD 算法

EMD 算法能根据信号自身的特点, 自主地抽取信号内在本征模态函数, 是一种适用于分析非线性平稳信号的方法。同小波变换相比, EMD 方法完全根据信号数据本身来确定需要分解出多少个 IMF, 因此更加具有自适应性。IMF 分量须满足两个条件: ①整窗信号的极值点数和过零点的数目必须相等或只相差一个; ②任意时刻, 由极大值点定义的上包络线和由极小值点定义的下包络线的平均值为零, 即信号的上下包络线关于时间轴对称。

EMD 算法的步骤如下:

①计算信号 $s(t)$ 的极值包络线 $e_+(t)$ 和 $e_-(t)$ 。找到信号 $s(t)$ 的所有极大值点, 通过三次样条函数拟合出极大值包络线 $e_+(t)$; 同理拟合出极小值包络线 $e_-(t)$ 。

②计算上下包络线的均值 m 。即 $m(t) = (e_+(t) + e_-(t))/2$ 。

③将原信号 $s(t)$ 减去 $m(t)$ 得到一个去掉低频的新信号 $h(t)$, 即 $h(t) = s(t) - m(t)$ 。

④将 $h(t)$ 作为新信号, 重复步骤①~③, 直到 $h(t)$ 满足 IMF 的定义, 则此时的 $h(t)$ 为原信号 $s(t)$ 的一个有效 IMF, 记第一次产生的 IMF 为一阶 IMF 分量 $\text{imf}_1(t)$, 之后依此类推。

⑤将原信号 $s(t)$ 减去得到 IMF, 可得到一个去掉高频成分的新信号 $r(t) = s(t) - h(t)$ 。然后重复上述过程进行下一个 IMF 的迭代计算, 直到第 n 阶 IMF 分量或残余量小于预设值或当余量是单调函数或常量时, EMD 分解过程停止^[21]。

最终将信号分解一组 IMF 和一个残余信号, 即: $\text{imf}_1(t), \text{imf}_2(t), \dots, \text{imf}_n(t)$ 和 $r_n(t)$ 。

图 4 给出了基于手机加速度传感器感测的加速度数据进行心率信号分解的效果。验证了从加速度数据提取心率等生命参数的可行性。




图 4 手机加速度信号的 SVD 和 Mallat 分解效果图

Fig. 4. Acceleration signal decomposition based on SVD and Mallat

3.2.2 基于加速度数据的心率和呼吸率融合估算算法

本文提出了一种利用手机加速度传感器来测量人体呼吸率和心率等生命参数融合感知方法。具体测量方法: 将手机放在胸口位置, 以 25 Hz 的采样速率采集正常呼吸过程中手机三轴加速度

数据, 进而研究其间接反映出的人体生理参数的变化情况。经过大量实验发现合成加速度数据中含有呼吸信号和心率信号(如图 5 所示)。

(1) 对手机合加速度信号 $s(t)$ 使用 EMD 分解算法求出一阶 IMF 分量 $\text{imf}_1(t)$, 如图(a');

(2) 利用 Mallat 小波函数对 $\text{imf}_1(t)$ 进行滤波, 得到了呼吸信号;

(3) 剔除原始信号中的呼吸信号; 将得到的信号进行质量评估, 若信噪比低于给定阈值则按 SVD 算法进行信号重构; 然后进行波峰波谷检测, 提取出波峰波谷信号。由此得到心率信号(如图 5(c) 所示)。

图 5(b) 和图 5(c) 分别是图 5(a) 的原始信号中提取出来的呼吸信号和心率信号, 可以看出, 由于测量过程中的抖动和接触不良, 以及在去除呼吸信号的过程中所带来的误差, 导致心率信号出现少量缺失, 需要进行补齐处理。尽管如此, 由图 5(b) 可以看出 30 s 内大约有 9 次呼吸, 由 5(c) 可以看出 30 s 内大约有 29 次心跳, 与专门检测仪同步进行的心率检测结果基本一致(缺失 1 次)。这表明了该融合方法的有效性和可行性。只是融合算法会有一定时间延迟, 这主要依赖于处理窗时间长度和算法复杂度, 但窗长时间又不能太短, 否则影响呼吸率的正确估计。

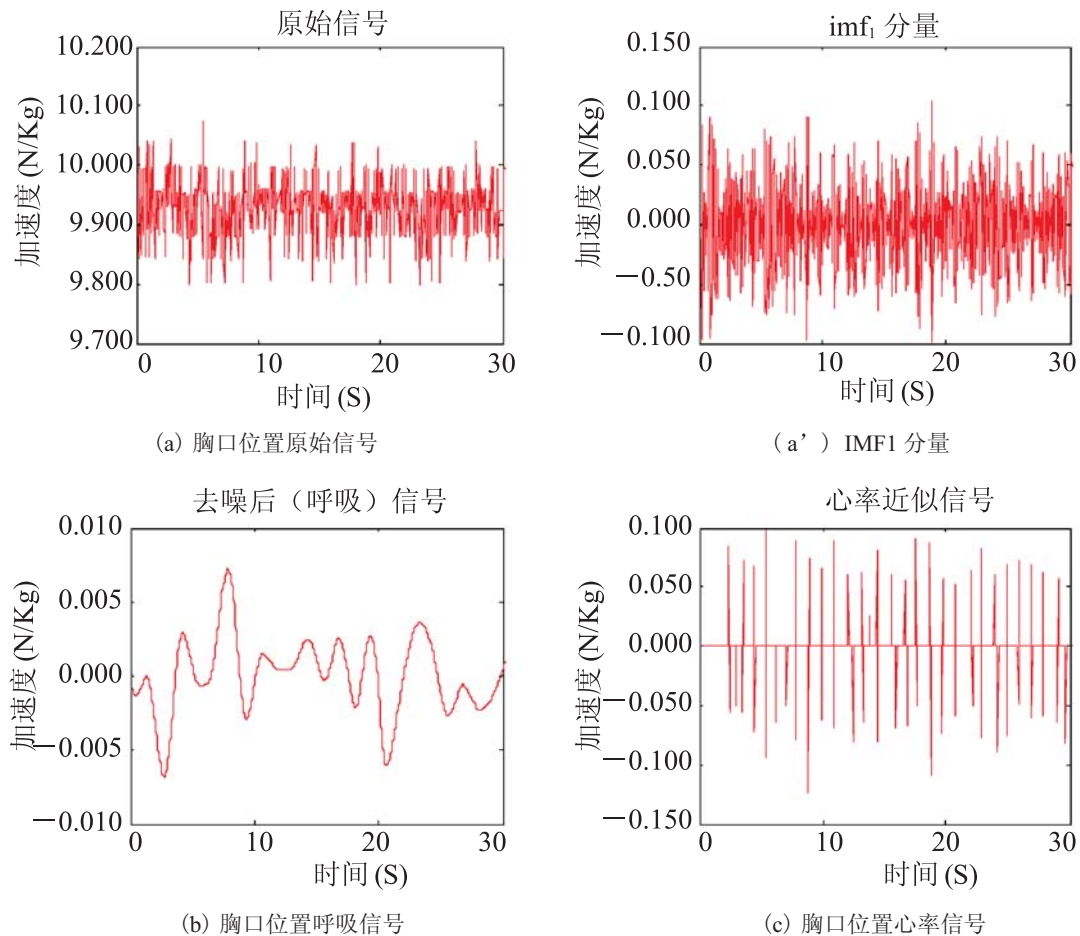


图 5 手机加速度信号处理效果

Fig. 5. Effect of signal processing

4 基于手机的生命参数集成监测方法

4.1 基于手机传感器的生命参数集成监测方法

基于智能手机传感器采集的数据和人的社会学参数, 利用第 2~3 节的各种方法在手机上进行高度集成, 构成一套生命参数检测系统。可将检测范围拓展到身体活动(走、跑、跳、上下楼、乘电梯、乘车和骑车等)检测和跌倒行为检测。

将手机长期检测的生命参数序列和每年的体检结果构成个人的健康数据队列, 以健康知识库为基础, 为各个参数设计分析和预测算法, 便构成了生命参数监测系统, 其系统架构如图 6 所示。

图 7 是在手机上集成的基于摄像头的心率检测, 图 7(b)是基于加速度的呼吸率、心率、检测演示系统 SmartHealth。实验选取实验者共



(a) 心率检测系统 (b) 呼吸率检测系统

图 7 基于手机传感器的心率和呼吸率检测演示系统

Fig. 7. Demo system of heart rate and respiratory rate detection based on phone-sensor

17 名, 其中老人 4 名(60 岁以上), 中年人 4 名(35~60 岁), 年轻人 9 名(20~35 岁), 每两分钟记录一组数据, 静息时连续测量 20 分钟。手

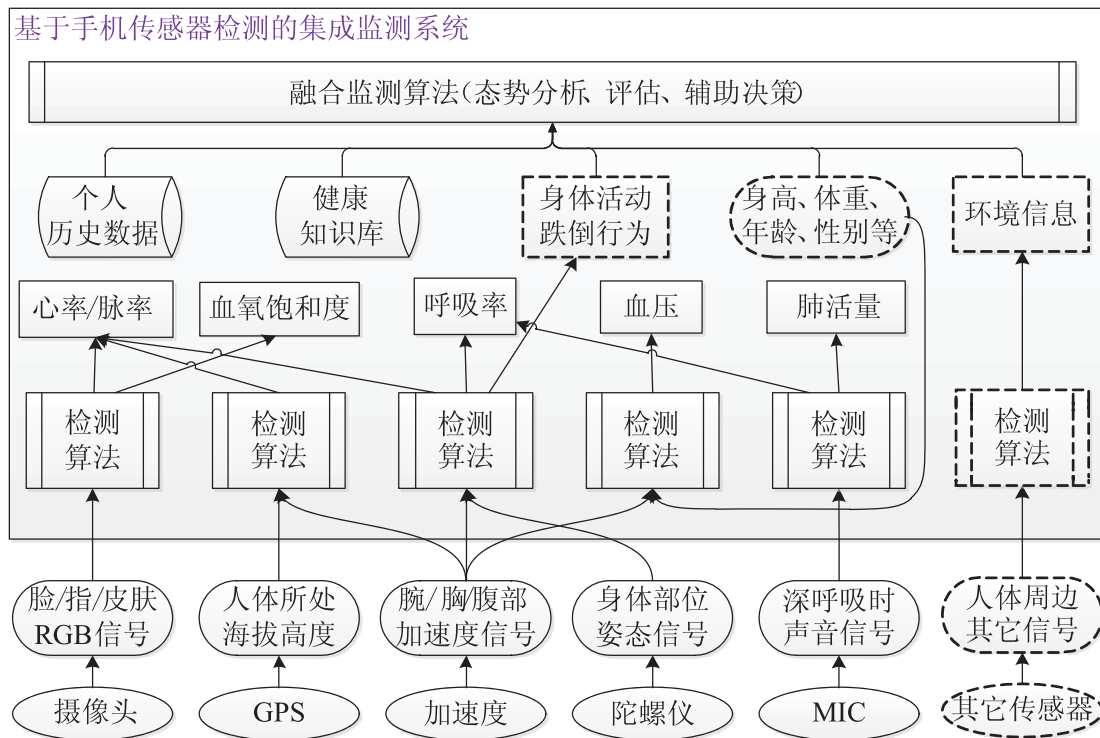


图 6 基于手机传感器的集成监测系统框图

Fig. 6. Block diagram of integrated monitoring system based on acceleration sensor

机检测结果与益体康 HC801B 指夹血氧仪检测结果基本一致：基于摄像头的心率检测结果在手指放置位置稳定后平均误差不超过 1 次/分钟；在手机紧贴比较轻薄的内衣置于心窝稳定后，基于加速度的呼吸率、心率检测结果平均误差分别不超过 1 次/分钟、3 次/分钟。反复测试验证 SmartHealth 系统具有很高的检测稳定性。可以用于老人或病人的生命参数自我监测，并利用手机的通信能力远程传输检测结果。

4.2 基于便携或可穿戴检测设备的手机网关集成监测方法

移动通信、智能计算等技术的飞速发展和智

能终端的日益普及为移动医疗的实施和广泛应用提供了机遇，张足生等已经在基于 Android 手机的人体生理参数监护的终端开发方面做了一些研究^[22]。为了给老年人提供更加方便的健康监测服务，我们在国家科技支撑计划课题的支持下，集成设计了一套基于无线生理参数检测设备和手机的健康监测系统方案(见图 8)并进行了系统实现。手机集成检测系统的应用界面如图 9 所示。

该监测系统集成了指夹式无线脉氧仪、臂带式无线血压仪、II 导联无线心电图仪、无线血糖仪和手握式无线脂肪仪等五种专门的生理参数检测设备

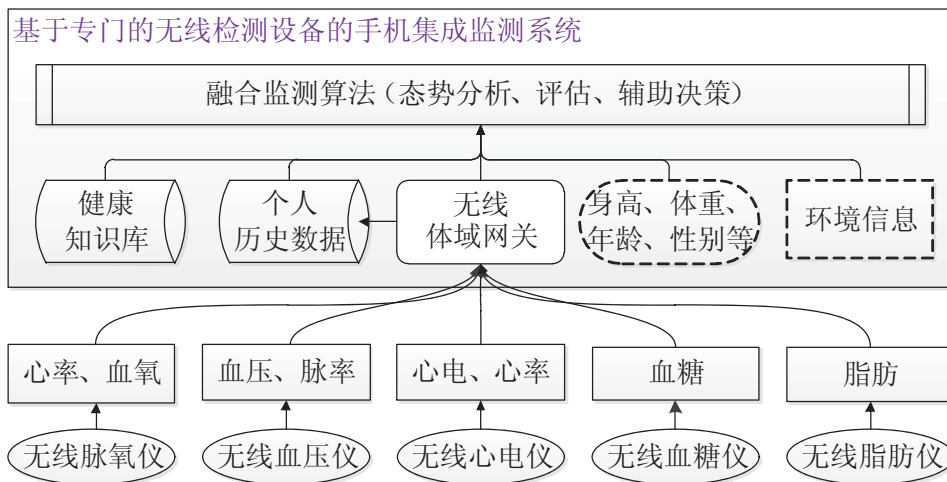


图 8 基于无线检测设备的手机集成监测系统框图

Fig. 8. Block diagram of mobile-integrated monitoring system based on wireless detection devices



图 9 手机集成系统效果图

Fig. 9. Diagram of mobile-integrated system

区, 长期检测老人或患者的生命参数, 形成监测队列数据。无线体域网关(智能手机软网关)集数据汇集、存储、分析、预测和远程互联网传输功能于一体, 结合社区医疗机构的个人健康/医疗档案管理平台, 可实现对老人或患者的生命参数长期跟踪和实时治疗, 同时也可以在意外发生时通过无线体域网关实现应急求救。

5 总 结

为了实现实时监测心率、肺活量、呼吸率、血氧饱和度和血压这五种具有生命急救意义的生命参数, 本文介绍了近几年基于手机传感器的生命参数直接检测与估算方法, 以及基于手机传感器的生命参数融合算法, 生命参数融合算法包括基于加速度信号和 GPS 信号的多参数融合算法与基于方法融合的算法。在此基础上, 研究出了一种新的基于 EMD 算法和小波的方法融合算法, 提出了基于手机传感器的生命参数集成监测系统 and 基于便携或可穿戴检测设备的手机网关集成监测系统, 并将这两套检测系统的监测结果与专业设备测量结果进行对比, 验证了本文方法和方案的有效性与可用性。

致 谢

本文研究获得了国家科技支撑计划课题(2013BAI04B01)的资助。在此也向中国医学会健康管理委员会的鼓励和帮助表示衷心感谢。

参 考 文 献

- [1] Kwon SJ, Kim H, Park KS. Validation of heart rate extraction using video imaging on a built-in camera system of a smartphone [C] // 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2012: 2174-2177.
- [2] Pal A, Sinha A, Choudhury AD, et al. A robust heart rate detection using smart-phone video [C] // Proceedings of the 3rd ACM MobiHoc workshop on Pervasive wireless healthcare, 2013: 43-48.
- [3] Scully CG, Lee J, Meyer J, et al. Physiological parameter monitoring from optical recordings with a mobile phone [J]. IEEE Transactions on Biomedical Engineering, 2012, 59(2): 303-306.
- [4] Gupta NK, Dantu R. Evaluation of respiration quality using smart phone [C] // Proceedings of the 6th International Conference on Pervasive Technologies Related to Assistive Environments, 2013: 28.
- [5] Chandrasekaran V, Dantu R, Jonnada S, et al. Cuffless differential blood pressure estimation using smart phones [J]. IEEE Transaction on Biomedical Engineering, 2013, 60(4): 1080-1089.
- [6] Larson EC, Goel M, Boriello G, et al. SpiroSmart: using a microphone to measure lung function on a mobile phone [C] // Proceedings of the 2012 ACM Conference on Ubiquitous Computing, 2012: 280-289.
- [7] Khan AM, Lee SW. Need for a context-aware personalized health intervention system to ensure long-term behavior change to prevent obesity [C] // Proceedings of the 5th International Workshop on Software Engineering in Health, 2013: 71-74.
- [8] Mendelson Y. Pulse oximetry: theory and applications for noninvasive monitoring [J]. Clinical Chemistry, 1992, 38(9): 1601-1607.
- [9] Choudhury AD, Visvanathan A, Banerjee R, et al. HeartSense: estimating blood pressure and ECG from photoplethysmograph using smart phones [C] // Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems, 2013: 88.
- [10] Sumida M, Mizumotoyz T, Yasumoto K. Estimating heart rate variation during walking with smartphone [C] // Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing, 2013: 245-254.

- [11] 曾作钦. 基于奇异值分解的信号处理方法及其在机械故障诊断中的应用 [D]. 广州: 华南理工大学, 2011.
- [12] Shafer MW, Mckee GR, Schlossberg DJ. Singular value decomposition filtering for enhanced signal extraction from two-dimensional beam emission spectroscopy measurements [J]. *Review of Scientific Instruments*, 2008, 79(10): 102-107.
- [13] Isayama A, Iwama N, Hosoda Y, et al. Singular value decomposition analysis of multichannel electron cyclotron emission signals of Tokamak plasma [J]. *Japanese Journal of Applied Physics*, 2003, 42(3): 329-331.
- [14] Vrabie VD, Mars JI, Lacoume JL. Modified singular value decomposition by means of independent component analysis [J]. *Signal Processing*, 2004, 84(3): 645-652.
- [15] 岳洋. 一种新型阈值函数在小波去噪中的应用 [D]. 长春: 长春工业大学, 2011.
- [16] Ghaderi F, Mohseni HR, Sanei S. Localizing heart sounds in respiratory signals using singular spectrum analysis [J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(12): 3360-3367.
- [17] Golyandina N, Nekrutkin V, Zhigljavsky AA. *Analysis of Time Series Structure: SSA and Related Techniques* [M]. Florida: CRC Press, 2001.
- [18] 钟丽辉, 魏贯军. 基于 Mallat 算法的小波分解重构的心电信号处理 [J]. *电子设计工程*, 2012, 20(2): 57-59.
- [19] 倪原, 王晓丽, 陆文总. 心电信号的小波变换处理算法及仿真 [J]. *西安工业大学学报*, 2012, 32(4): 310-314.
- [20] 杨蕾, 郑慧民, 杨扬. Mallat 算法用于语音信号分析与压缩 [J]. *北京科技大学学报*, 1996, 18(1): 10-13.
- [21] 王婷. EMD 算法研究及其在信号去噪中的应用 [D]. 哈尔滨: 哈尔滨工程大学, 2010.
- [22] 张足生, 方翔. 基于 Android 智能手机的健康监护终端研究 [J]. *集成技术*, 2013, 2 (4): 79-82.