

DOI:10.19651/j.cnki.emt.2107524

基于参数优化 VMD 的呼吸波提取^{*}

宋海声 庞荣妮

(西北师范大学 物理与电子工程学院 兰州 730070)

摘要: 针对目前呼吸波提取准确率不高的问题,提出一种从光电容积脉搏波(PPG)信号中提取呼吸波的改进方法。在MIMIC数据库获取10组脉搏和呼吸信号。利用遗传变异粒子群参数优化的变分模态分解(VMD)算法对同一时段光电容积脉搏信号进行分解,得到本征模函数(IMF),选择相关系数大于0.3的IMF分量重构呼吸信号,并将重构呼吸信号与原始呼吸信号进行比较。实验结果表明,呼吸速率的平均准确率为0.95,波形相关系数(RCC)的平均值为0.9451,均方根误差(RMSE)的平均值为2.0110,该算法提取呼吸波呼吸速率相比于EMD、EEMD算法提高了5%和3%,RCC提高了19.96%和13.17%,准确性更高。同时该算法克服了VMD算法在分解时惩罚因子和分解层数选取的不确定性。这对临床实践具有重要意义。

关键词: 呼吸波;变分模态分解;光电容积脉搏波;遗传变异粒子群;本征模函数

中图分类号: R318 文献标识码: A 国家标准学科分类代码: 510.4099

Respiratory wave extraction based on parameter optimized VMD

Song Haisheng Pang Rongni

(College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou 730070, China)

Abstract: Aiming at the low accuracy of respiratory wave extraction, an improved method for respiratory wave extraction from photoplethysmography (PPG) signal is proposed. Ten groups of pulse and respiratory signals were obtained from the mimic database. The variation mode decomposition (VMD) algorithm optimized by genetic mutation particle swarm optimization is used to decompose the pulse signal of photo capacitance product in the same period, and the intrinsic mode function (IMF) is obtained. The IMF component with correlation coefficient greater than 0.3 is selected to reconstruct the respiratory signal, and the reconstructed respiratory signal is compared with the original respiratory signal. The experimental results show that the average accuracy of respiratory rate is 0.95, the average value of waveform correlation coefficient (RCC) is 0.9451, and the average value of root mean square error (RMSE) is 2.0110. Compared with EMD and EEMD, the algorithm improves respiratory rate by 5% and 3%, and RCC by 19.96% and 13.17%, with higher accuracy. At the same time, the algorithm overcomes the uncertainty of penalty factor and decomposition level selection in VMD algorithm. This is of great significance to clinical practice.

Keywords: respiratory wave; variation mode decomposition; photoplethysmography; genetic variation particle; swarm optimization

0 引言

呼吸是评价人体生命体征重要的参数之一,尤其对于危重病人是首要的生命体征检测参数。目前记录呼吸用的方法比如呼吸机压力控制通气记录呼吸等不适用于临床长时间监护。在脉搏信号中包含着呼吸、血压、心冲击信号等5种其他生理信号。光电容积脉搏波(photoplethysmography, PPG)是一种常用的非侵入技术,许多研究学者

通过PPG信号推导出呼吸信号,并且对此做了许多研究^[1],实验证明PPG信号中包含了与呼吸相关的信息。对此,众多的学者致力于通过PPG信号提取呼吸信号。采用非平稳信号中广泛使用的小波分析法对PPG信号分析,小波变换法^[2]是一种传统的信号分解方法,广泛应用于生理信号处理,但是分解结果易受到小波基的影响。经验模态分解(empirical mode decomposition, EMD)算法^[3]是一种自适应的信号处理方法,对信号或数据序列平稳化处理,将

收稿日期:2021-08-09

*基金项目:国家自然科学基金(117417030)、甘肃省科技计划(20JR10RA080)项目资助

信号从高频到低频逐步分解为独立的信号, 广泛应用于食品科学^[4]、生物医学等非线性、非平稳信号, 文献[5]使用 EMD 得到重构呼吸波与原始呼吸波波形的相关系数在 0.5 左右。自适应基弥补了小波分解的缺陷, 但分解出的固有模态函数(intrinsic mode function, IMF)存在模态混叠问题。为了解决此问题, 文献[6-7]提出一种噪声辅助数据分析方法集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法, 在分解信号时加入白噪声, 当使用足够多测试数据的全体均值时, 添加噪声将被消除。文献[8]在基于改进 EEMD 呼吸波提取中波形相关系数在 0.65 以上。在分解时会混入大量伪分量, 使得重构信号误差加大。Yeh 等^[9]提出互补集合经验模态分(complementary ensemble empirical mode decomposition, CEEMD)算法, 利用多次加入相反的白噪声改善该问题, 但集成次数多, 计算效率低下。为了解决以上问题, 新的自适应信号处理方法变分模态分解(variational mode decomposition, VMD)由 Dragomiretskiy 等^[10]提出, 相比于以上的方法, VMD 方法引入变分模型, 将信号的分解转换为约束模型最优解的寻优问题, 可以避免端点效应、抑制模态混叠, 而且数学理论推导更加严格, 同时鲁棒性和收敛速度都有所提升。研究表明, VMD 算法对低频信号处理效果高于高频信号, 但在分解过程中易受到惩罚因子和分解层数的影响。VMD 在现阶段用于生理信号分解还处于起步阶段, 研究较少。目前为止, 国内外都没有成熟的方法从 PPG 中提取呼吸信号。

本文在 VMD 算法中加入遗传变异粒子群思想, 对影响分解效果较大的惩罚因子 α 和分解层数 K 优化, 将 MIMIC 数据库中 PPG 信号进行分解, 选取相关系数大于 0.3 的 IMF 分量重构呼吸信号, 与 EMD 和 EEMD 算法重构进行效果对比, 通过仿真实验证实了本文算法的优势。

1 脉搏信号分解基本原理

1.1 变分模态分解理论

VMD 算法是通过构造并求解约束变分问题^[11], 将待处理信号 $x(t)$ 自适应的分解成指定个数并紧密围绕在中心频率 ω_k 附近的具有稀疏特性的 IMF 分量信号。变分问题即为寻找 K 个模态分量且使得模态带宽之和最小, VMD 问题主要求解约束变分问题, 假设将信号 $x(t)$ 分解成 K 个 IMF 分量, 约束变分问题构造模型如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k = x \end{cases} \quad (1)$$

式中: u_k 为信号的第 K 个分解的 IMF 分量; ω_k 为 IMF 分量对应的中心频率; $(\delta(t) + \frac{j}{\pi t}) u_k(t)$ 为 u_k 通过 Hilbert 变换得到的解析信号。

引入二次惩罚因子 α 和拉格朗日惩罚算子 $\lambda(t)$ 构造增广 Lagrange 函数将式(1)转换成非约束变分问题, 其中二次惩罚因子可以在独立同分布高斯噪声的影响下, 保证信号重构后的准确度。拉格朗日乘数保证了过程的严格性。增广 Lagrange 函数为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_k u_k \right\|_2^2 + \langle \lambda(t), x(t) - \sum_k u_k(t) \rangle \quad (2)$$

利用乘法交替方向法(alternate direction method of multipliers, ADMM)求解式(2)的鞍点, 即为式(1)约束变分问题的最优解, 交替更新从 n 步到 $n+1$ 步迭代的 u_k^{n+1} 、 ω_k^{n+1} 、 λ^{n+1} , 将 u_k^{n+1} 、 ω_k^{n+1} 的取值问题转换到频域, 便可求得表达式(2)的鞍点。从而将信号 $x(t)$ 分解成 K 个 IMF 分量。

VMD 算法的具体步骤如下:

- 1) 初始化 $\{u_k^1\}$ 、 $\{\omega_k^1\}$ 和 n 为 0。
- 2) 令 $n=n+1$, 执行整个循环。
- 3) 令 $k=1$, 更新 u_k 、 ω_k 的更新可假设为 u_k^{n+1} 的问题, 则 u_k^{n+1} 的表达式可表示为:

$$u_k^{n+1} = \arg \min_{u_k \in X} \left\{ \alpha \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{-j\omega_k t} \right\|_2^2 + \left\| x(t) - \sum_i u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \quad (3)$$

假设 $\omega_k^n = \omega_k^{n-1}$ 和 $\sum_i u_i(t) = \sum_{i \neq k} u_i(t)^{n+1}$ 利用傅里叶变换将式(3)从时域变换到频域进行更新, 可得:

$$\hat{u}_{k1}^{n+1} = \arg \min_{\hat{u}_{k1}, u_k} \left\{ \alpha \left\| j(\omega - \omega_k) [(1 + \text{sgn}(\omega)) \hat{u}_k(\omega)] \right\|_2^2 + \left\| \hat{x}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right\|_2^2 \right\} \quad (4)$$

令式(4)中的变量 $\omega = \omega - \omega_k$, 式(4)的频域表达式则变为:

$$\hat{u}_{k1}^{n+1} = \arg \min_{\hat{u}_{k1}, u_k} \left\{ \alpha \left\| j(\omega - \omega_k) [(1 + \text{sgn}(\omega)) \hat{u}_k(\omega)] \right\|_2^2 + \left\| \hat{x}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right\|_2^2 \right\} \quad (5)$$

式(5)的非负频率区间积分形式为:

$$\hat{u}_{k1}^{n+1} = \arg \min \left\{ \int_0^\infty 4\alpha (\omega - \omega_k)^2 |\hat{u}_k(\omega)|^2 + 2 \left\| \hat{x}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right\|^2 d\omega \right\} \quad (6)$$

二次优化得到的解为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i=1, i \neq k}^K \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha (\omega - \omega_k)^2} \quad (7)$$

4) 更新 K , 则 $K = K + 1$, 重复步骤 3), 直到满足循环次数时停止。

5) 继续令 $k = 1$, 更新 ω_k ; ω_k 的更新问题可以理解为 ω_k^{n+1} 的取值问题, 则 ω_k^{n+1} 可以表达为:

$$\omega_k^{n+1} = \arg \min_{\omega_k} \left\{ \left\| \partial_t [(\delta(t) + \frac{j}{\pi t}) u_k(t)] e^{j\omega_k t} \right\|_2^2 \right\} \quad (8)$$

同步步骤 2) 原理, 优化可得:

$$\omega_k^{n+1} = \arg \min_{\omega_k} \left\{ \int_0^\infty (\omega - \omega_k) u_1(t) |^2 d\omega \right\} \quad (9)$$

求解得:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_{k1}(\omega)|^2 d\omega}{\int_0^\infty |u_{k1}(\omega)|^2 d\omega} \quad (10)$$

6) 令 $k=k+1$, 重复步骤 5), 直到满足 k 的循环次数时停止。

7) 根据表达式:

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau(\hat{x}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (11)$$

更新 λ , 其中 τ 表示更新参数。

$$8) \text{ 重复步骤 } 2) \sim 7), \text{ 直至满足 } \sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \omega$$

时, 结束整个循环, 输出结果为 K 个 IMF 分量信号。

1.2 VMD 算法参数优化基本原理

在 VMD 算法分解时需要确定参数, 影响分解效果较小的参数设为经验值, α 和 K 的选择影响分解效果较大^[12 13], 且参数选择呈现不规律性, 凭借经验值选择这两个参数存在随机性和不确定性。为了选取最优的参数组合, 使 VMD 算法可以分解出清晰的特征信息, 本文采用遗传变异粒子群算法对 K 和 α 这两个参数进行优化, 计算最优的参数组合。

粒子群算法是一种全局优化算法, 它的参数较少, 易于调整, 但是容易陷入局部最优, 故难以计算全局最优解^[14], 本文在粒子群算法的基础上加入遗传变异思想, 能够保持全局最优。

定义遗传变异粒子群算法^[15]: 在 N 维搜索空间内, 种群个数为 X , 种群 X 由 n 个粒子组成, 种群 X 可以表示为 $X = [x_1, x_2, \dots, x_n]$, 每个粒子在 N 维搜索空间的位置可以由 N 维向量表示, 即 $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}]$, 第 i 个粒子的移动速度 $v_i = [v_{i1}, v_{i2}, \dots, v_{iN}]$, 粒子局部极值 $p_i = [p_{i1}, p_{i2}, \dots, p_{iN}]$, 该代种群的全局极值 $G_1 = [g_1, g_2, \dots, g_D]$, 次全局最优值 $G_2 = [g_1, g_2, \dots, g_D]$, 个体最大最优保持代数为 $\max Age$, 变异概率为 q , 为了防止粒子陷入局部最优, 需要记录迭代过程中粒子个体最优的保持代数, 当个体最优保持代数没有达到 $\max Age$ 时, 每个粒子通过个体局部极值和全局极值来更新下一代的位置和速度, 更新公式如下:

$$v_i^{n+1} = \omega v_i^n + c_1 \eta(p_i - x_i^n) + c_2 \eta(G_1 - x_i^n) \quad (12)$$

$$x_i^{n+1} = x_i^n + v_i^{n+1} \quad (13)$$

式中: ω 为惯性权重, η 为 $[0, 1]$ 之间的随机数, c_1, c_2 为学习因子, 分别代表了局部搜索能力和全局搜索能力, n 为迭代次数。基于遗传变异粒子群算法的参数寻优流程如图 1 所示。

遗传变异粒子群算法的适应度函数选择包络熵, 包络熵概念由唐贵基等^[16]提出, 在长度为 M 的时间信号 $x(j)$ 包络熵定义为:

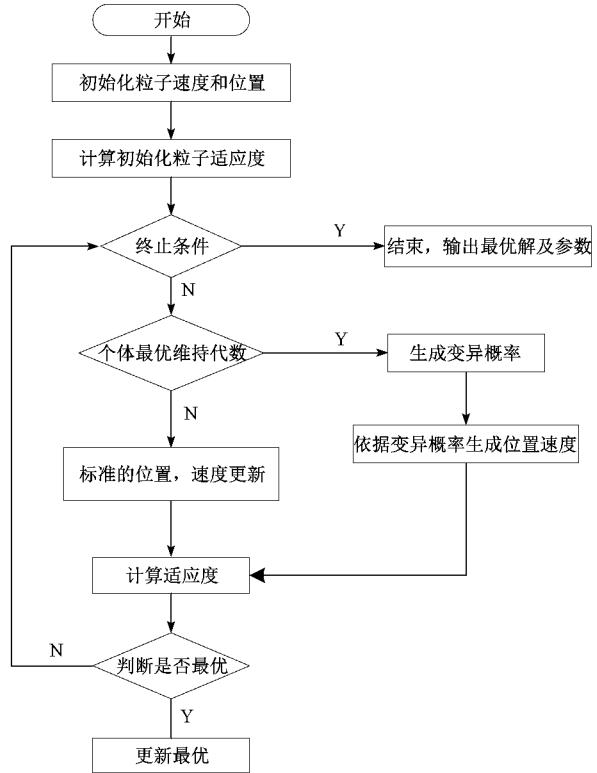


图 1 基于遗传变异粒子群算法的参数寻优过程

$$p_j = a(j) / \sum_{j=1}^M a(j) \quad (14)$$

$$E_p = - \sum_{j=1}^M p_j \lg p_j \quad (15)$$

式中: $j=1, 2, \dots, M$, $a(j)$ 是 $x(j)$ 在希尔伯特变换解调后得到的包络信号, p_j 是对 $a(j)$ 归一化后的结果, 归一化的目的是为了避免 IMF 分量不同幅值的影响以及消除微弱噪声信号, 是根据信息熵计算得到, 本文根据包络熵判断 VMD 的分解效果。脉搏信号经过 VMD 分解后, 若得到的分量中包含频率分量较多, 会掩盖呼吸信号的特征, IMF 信号的稀疏性较弱, 适应度函数包络熵较大; 反相, 若分量中单一频率且呈现一定规律性的脉冲, 信号呈现较强的稀疏性, 这时包络熵较小。在 α 和 k 的影响下, 选择 k 个分量中包络熵最小的作为局部极小熵 $\min E_p$, 将局部极小熵作为整个搜索过程中适应度函数一部分, 寻找全局最优组合 $[k_0, \alpha_0]$ 。

1.3 重构呼吸信号性能的评价指标

本文采用呼吸速率、相关系数(RCC)和均方根误差(RMSE)作为评价重构呼吸信号性能的评价指标。呼吸速率表示人体每分钟由压力控制通气呼吸或者容量控制通气呼吸的次数, 它是评价呼吸是否正常的一项重要指标。相关系数取值在 0~1 之间, 具有归一化特性, 可以避免不同分量幅值影响, 相关系数表达式如下:

$$r_{ij} = \frac{\sum_i u_i(t) s_j(t)}{\sqrt{\sum_i u_i^2(t) \sum_j s_j^2(t)}} \quad (16)$$

式中: $u_i(t)$ 为分离后的 IMF 分量信号; $s_j(t)$ 为呼吸信号。均方根误差(RMSE)表示两个信号不同的离散程度, 表达式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (17)$$

式中: n 为数据个数, x_i 和 y_i 表示两种同一长度的不同信号。

1.4 重构呼吸信号

PPG 信号进行两次分离重构呼吸信号, 首先根据经验值设置 VMD 分解参数, 将原始信号分解为 $IMF_1(t)$, $IMF_2(t)$, ..., $IMF_K(t)$ K 个模态分量, 根据相关系数重构呼吸信号^[14], 在呼吸信号重构中假设 $0 \leq r_{ij} < 0.3$ 表示分离出的 IMF 分量与呼吸信号不相关; $0.3 \leq r_{ij} < 0.5$ 表示低度相关; $0.5 \leq r_{ij} < 0.8$ 表示中度相关; $r_{ij} \geq 0.8$ 表示高度相关, 相关系数越接近 1, 说明分解效果越好, 算法的选择性与分离性越好。重构呼吸信号表示为:

$$S(t) = \sum_{n=n_0}^{n_b} IMF_n(t) \quad (18)$$

首次重构的呼吸信号中包含些许其他生理信号, 对重构信号进行二次分离, 二次分离基于遗传变异粒子群对 VMD 参数优化, 选取最优 K 和 α 参数组合对重构信号二次分离, 相关系数大于 0.3 的 IMF 分量认为和呼吸信号相关, 利用式(18)重构呼吸信号。

基于遗传变异粒子群参数优化的 VMD 重构呼吸信号的具体步骤如下:

1) 对 PPG 信号首次分离重构呼吸信号。

2) 基于遗传变异粒子群算法对 α 和 K 寻找最优组合, 将首次重构呼吸信号经参数优化的 VMD 分解为 K 个 IMF 分量。

3) 计算各个 IMF 分量与原始呼吸信号的相关系数。

4) 选取相关系数大于 0.3 的 IMF 分量利用式(17)重构呼吸信号。

5) 分析重构信号与原始呼吸信号的呼吸速率、相关系数和均方根误差。

2 数据的分析与处理

本文选取 MIMIC Database 数据库中的 BIDMC PPG and Respiration Dataset(bidmc)前 10 组信号, 选择 60 s 同时段的脉搏波(PPG)信号和呼吸波(Pleth)信号。

2.1 脉搏信号的初始分离重构呼吸信号

首先用未进行参数优化的 VMD 算法对脉搏信号进行粗分离, 对分解效果影响较小的参数设为经验值, 由于脉搏信号有 5 个主要频率, 如图 2 所示为脉搏信号的频谱图。

故 K 设为 6, α 设为经验值 2 000, 脉搏信号的频率主要集中在 5 Hz 以下, 图 3 为 VMD 分离的 IMF 分量和对应的频谱图, 由图 3 可以看出, VMD 分解与 EMD 分解相比消除了端点效应和模态混叠现象。原始呼吸信号与 IMF 分量进行相关性分析, 6 个 IMF 分量与原始呼吸信号的相关系数分

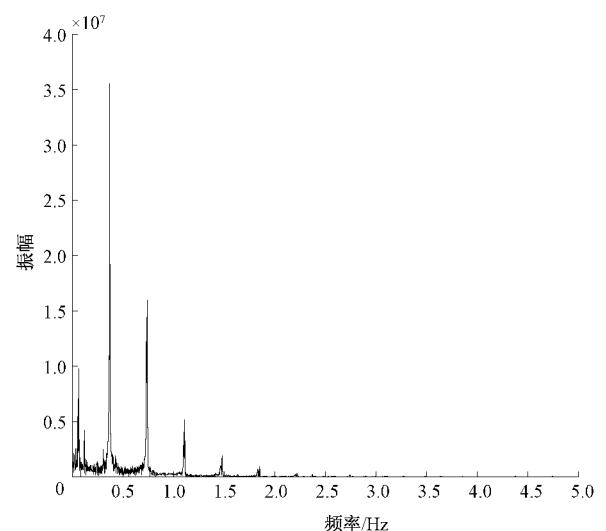
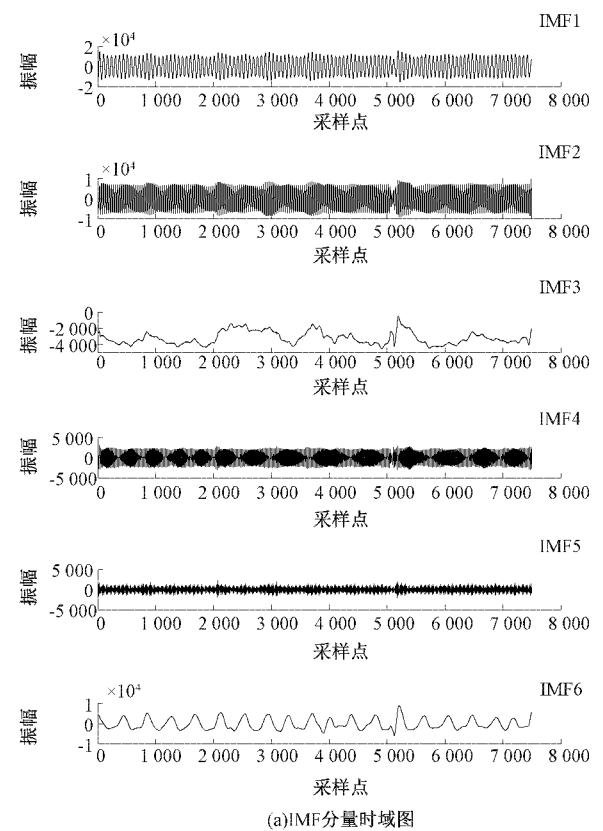


图 2 光电容积脉搏信号频域图

别为 $a_{01}=0.0485, a_{02}=0.0098, a_{03}=0.3212, a_{04}=0.0021, a_{05}=0.0017, a_{06}=0.8618$, 根据相关性初始定义, 与原始呼吸信号相关性较强分量为 IMF_3 和 IMF_6 , 对这两个相关性较强的 IMF 分量利用式(17)对呼吸信号进行重构, 重构信号如图 4 所示。重构信号与原始呼吸相关系数为 $a=0.7612$ 。初次分离的重构效果较好, 但在第 5 000 个抽样点处, 出现了幅值突然上升, 这是因为在原始脉搏信号中在 5 000 采样点处出现急速的心跳加速导致的。



(a) IMF 分量时域图

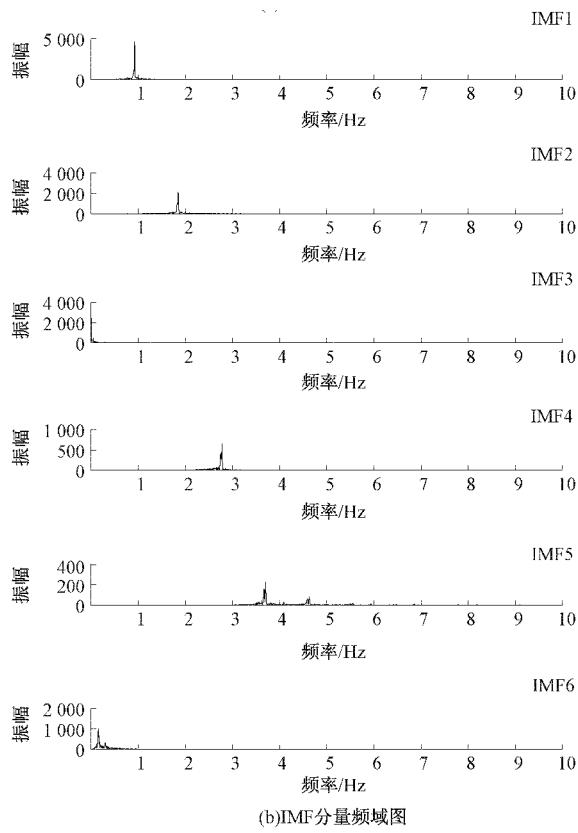


图3 VMD分解图

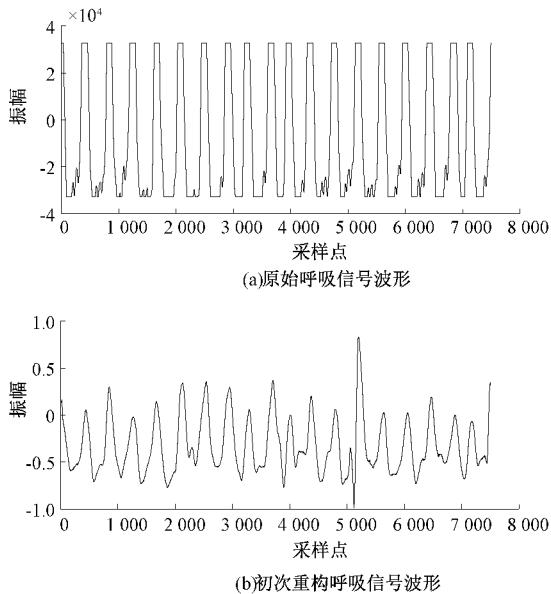


图4 初次分离重构呼吸信号波形图

2.2 脉搏信号的二次分离

初次重构的呼吸信号中包含着部分其他生理信号,同时为了进一步提高重构信号的准确性和相关性,对初次重构的呼吸信号二次分离,利用遗传变异粒子群算法对 K 和 α 进行优化,得到最优的参数组合,二次分离算法^[15]根据初

始重构呼吸信号的特点,设置遗传变异粒子群算法参数参考文献[17],参数设计如表1所示。

表1 遗传变异粒子群算法的参数设计

N	C_1	C_2	W	M	D	Q
20	2	2	0.9	10	2	0.5

其中 N 为种群个数, C_1, C_2 为粒子群参数, W 为最大权值, M 为循环迭代次数, D 为种群中个体个数, Q 为变异概率。

依据遗传变异粒子群算法全局寻优的特点,根据包络熵最小值作为目标函数搜索 VMD 各个状态下最优参数组合 $[k_0, \sigma_0]$, 得到 k_0 个 IMF 分量。更新的粒子位置向量为 2 维空间,一个维度 K 的范围是 $[2, 15]$, 另一个维度 α 寻优范围为 $[200, 5000]$, 迭代结束, 得到全局适应度为 7.9822, 计算出的最优参数组合为 $[7, 2932]$, 利用最优参数组合对初次重构呼吸信号二次分解,各个 IMF 分量相关系数为 $a_{01}=0.2863, a_{02}=0.8148, a_{03}=0.3207, a_{04}=0.0594, a_{05}=0.0030, a_{06}=0.0021, a_{07}=0.0018$ 。根据相关系数相关性初始定义,IMF2 和 IMF3 相关性较强。

选择这两个模态分量对初次重构呼吸信号二次重构,二次重构的呼吸信号相关系数为 $a_0=0.8593$,相比于初次重构呼吸信号,基于参数优化的 VMD 重构呼吸信号 RCC 提高了 9.81%,准确度有一定的提升,同时节约计算时间。参数优化的 VMD 二次分离重构呼吸信号时域与频域如图5所示。

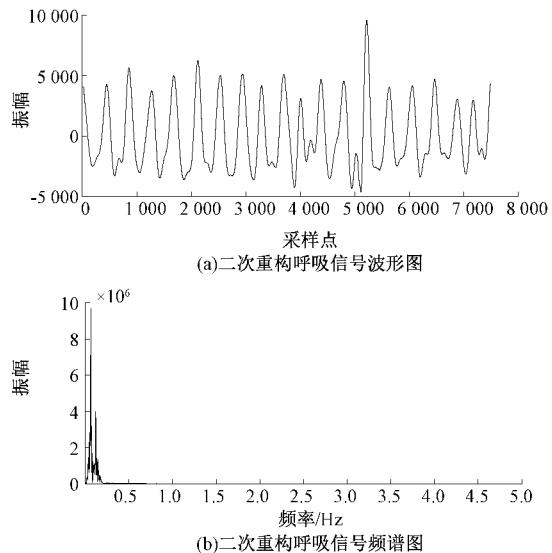


图5 二次重构呼吸信号图

2.3 信号重构效果对比分析

呼吸速率的准确度是衡量提取呼吸信号是否准确的一项重要指标,本文选取数据库中的前 10 组数据进行呼吸率计算,如图6所示,基于参数优化的呼吸速率平均值为

0.95, EMD 为 0.90, EEMD 为 0.92, 基于参数优化的 VMD 算法呼吸准确率高于 EMD 和 EEMD 算法。

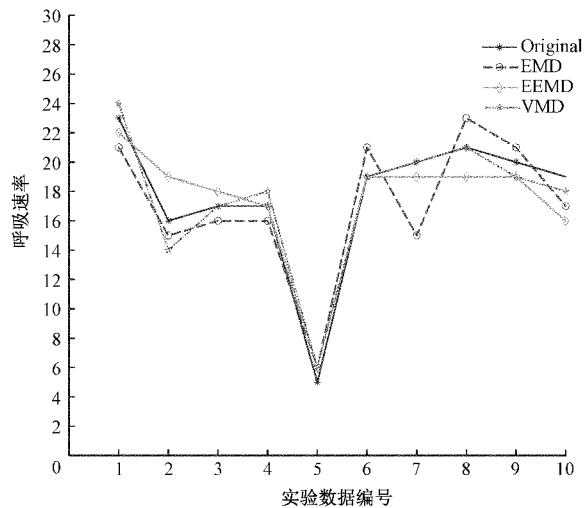


图 6 不同算法的呼吸速率对比

根据表 2 结果, 3 种不同算法的 RCC 10 组测试数据平均值为 0.7455、0.8133、0.9451, 基于参数优化的 VMD 算法提取呼吸波的 RCC 高于 EMD 和 EEMD 算法提取呼吸波, 3 种算法的 10 组测试数据的均方根误差平均值为 2.1089、2.0537、2.0110, 基于参数优化的 VMD 提取算法相比于 EMD 和 EEMD 有一定的提升。

表 2 不同算法相关系数和均方根差结果对比

编 号	相关系数			均方根差		
	EMD	EEMD	VMD	EMD	EEMD	VMD
1	0.6117	0.7870	0.7342	2.1532	2.1263	2.1209
2	0.9621	0.8210	0.9954	2.3501	2.4236	2.3763
3	0.9425	0.8046	0.9939	1.5939	1.4684	1.4463
4	0.8777	0.8015	0.9856	1.9919	1.7522	1.6828
5	0.5668	0.7698	0.9859	2.7492	2.7424	2.7370
6	0.5222	0.8568	0.8319	1.9985	1.9674	1.9545
7	0.7101	0.8546	0.9966	2.5601	2.4911	2.4733
8	0.5584	0.8495	0.9979	2.2794	2.0133	1.9604
9	0.9615	0.7737	0.9580	1.9672	2.0716	1.9280
10	0.7417	0.8151	0.9719	1.4455	1.4802	1.4308

如图 7 所示为几种不同算法重构呼吸信号的时域波形图, 图 8 为频谱波形图, 基于 EMD 算法的自适应分解方法重构的呼吸波有部分频率缺失, 波形上下浮动, 相关系数为 0.6860, RMSE 为 2.5848; EEMD 算法分解算缺少部分波形细节, 相似系数为 0.7125, RMSE 为 2.6549; 基于参数优化的 VMD 算法重构信号相似度最高, 相似系数为 0.8593, RMSE 为 1.9808, 通过数据对比基于参数优化的 VMD 算法重构呼吸信号效果更好。

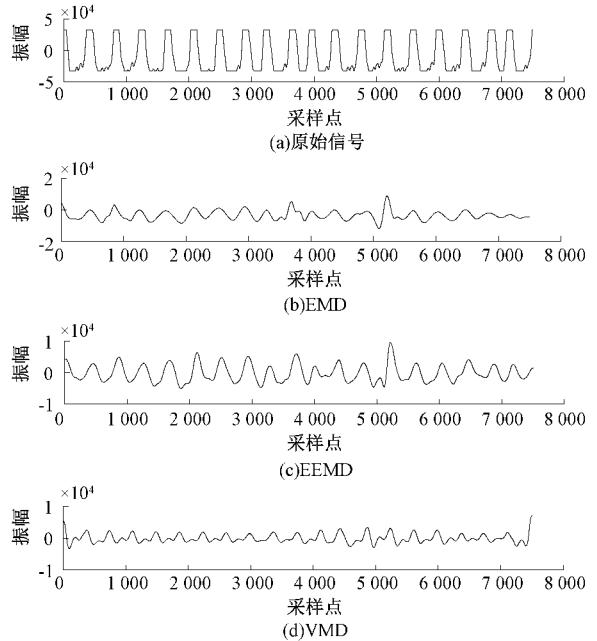


图 7 不同算法重构呼吸信号时域对比图

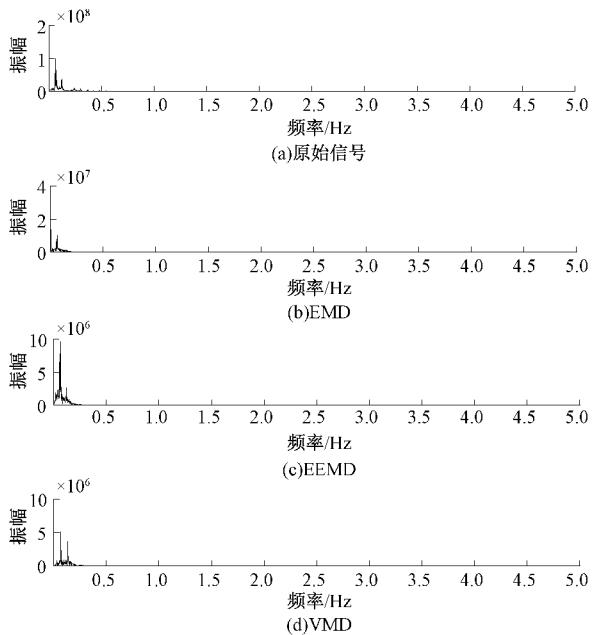


图 8 不同算法重构呼吸信号频域对比图

3 结 论

本文提出使用 2 次 VMD 算法从 PPG 信号中重构呼吸信号, 取得了较好的重构效果。首次分离脉搏信号重构的呼吸信号采用未经参数优化 VMD 算法, 参数设置凭借经验值, 首次重构的呼吸信号中包含部分其他生理信号, 效果欠佳。对首次重构呼吸信号二次分离, 针对 VMD 算法参数选择具有随机性的缺点, 利用遗传变异粒子群算法优化 VMD 算法中影响分解效果较大的 α 和 K , 保证参数组

合选择最优值。通过对 MIMIC 数据库中前十组数据进行测试,得到重构呼吸信号与原始呼吸信号 RCC 平均值为 0.945 1,呼吸速率的准确率平均值为 0.95。实验表明,基于参数优化的 VMD 算法对比 EMD 和 EEMD 在低频内模态混叠情况得到改善,提取的呼吸波与原始呼吸波相比在时域与频域上的相关性更强,呼吸速率的准确率相比于 EMD 和 EEMD 分别提高了 5% 和 3%,RCC 提高了 19.96% 和 13.17%,参数优化同时也缩短了计算时间,提取效果要优于 EMD 和 EEMD 算法。

参考文献

- [1] GARDE A, KARLEN W, DEHKORDI P, et al. Empirical mode decomposition for respiratory and heart rate estimation from the photoplethysmogram [J]. IEEE, 2014, 40: 799-802.
- [2] 曹辉, 杨理践, 刘俊, 等. 基于数据融合的小波变换漏磁异常边缘检测[J]. 仪器仪表学报, 2019, 40(12): 71-79.
- [3] 范勇, 王鹏, 张宁超. 基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究[J]. 国外电子测量技术, 2020, 39(8): 5-10.
- [4] 张志勇, 李刚, 林凌, 等. EMD 和 SPA 算法在光谱法检测面粉过氧化苯甲酰添加量中的应用[J]. 光谱学与光谱分析, 2012, 32(10): 2815-2819.
- [5] 邹滋润, 陈真诚, 朱健铭. 基于光电容积脉搏波的呼吸波提取[J]. 中国生物医学工程学报, 2013, 32(4): 508-512.
- [6] YUAN Y. The multi-dimensional ensemble empirical mode decomposition (MEEMD) [J]. Journal of Thermal Analysis and Calorimetry, 2017, 128 (3): 1841-1858.
- [7] WU Z H, HUNG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1 (1): 1-41.
- [8] 王涛, 朱希安. 基于改进 EEMD 的呼吸波提取算法[J]. 科技通报, 2017, 33(1): 44-47.
- [9] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [10] DRAGOMIRETSKIY K, ZOSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [11] 谢国民, 黄睿灵, 丁会巧. 基于 VMD 样本熵和 KELM 的输电线路故障诊断[J]. 电子测量与仪器学报, 2019, 33(5): 73-79.
- [12] 陈妮, 覃玉荣, 熊艳婷, 等. 基于变分模态分解的脑电锁相刺激方法[J]. 仪器仪表学报, 2020, 41(5): 205-213.
- [13] 郭世凯, 孙鑫. 基于改进粒子群算法的移动机器人路径规划[J]. 电子测量技术, 2019, 42(3): 54-58.
- [14] 朱丽莉, 杨志鹏, 袁华. 粒子群优化算法分析及研究进展[J]. 计算机工程与应用, 2007(5): 24-27.
- [15] 江春冬, 王景玉, 杜太行, 等. 基于变分模态分解算法的单通道无线电混合信号分离[J]. 上海交通大学学报, 2018, 52(12): 1618-1626.
- [16] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73-81.
- [17] 刘衍民. 粒子群算法的研究及应用[D]. 济南: 山东师范大学, 2011: 43-45.

作者简介

宋海声,副教授,硕士生导师,主要研究方向为人工智能技术、传感器检测、计算机测量与控制等。

E-mail:653526491@qq.com

庞荣妮(通信作者),硕士研究生,主要研究方向为生物医学信号处理、计算机测量与控制。

E-mail:1825628308@qq.com