

基于相空间重构与RBF网络的心冲击波补偿研究

郑小涵^{1,2}, 杨越琪^{1,2}, 朱岩^{1,2}, 李晓欧^{1,2}

(1. 上海健康医学院医疗器械学院, 上海 201318; 2. 上海理工大学健康科学与工程学院, 上海 200093)

摘要: 在基于心冲击描记图的非接触式心率检测方法中, 心冲击波的真实形态容易在体动发生时被掩盖。为解决无效信号给心跳点定位造成的阻碍, 提出一种相空间重构与RBF神经网络结合的体动区间波形补偿模型。首先利用改进的C-C法选取合适的重构参数, 并通过动态k-均值聚类确定网络拓扑结构, 将动作发生前时间序列在重构空间中的相点作为学习样本输入到模型中, 进而实现对无效信号段的单步递归预测。实验结果显示, 该预测模型性能良好, 能够减少原始信号中不规则噪声带来的影响, 经模型修正后计算逐拍心动周期的平均误差为1.27%, 平均绝对误差为8.9 ms, 有效避免了心跳事件的误判。

关键词: 相空间重构; RBF神经网络; 心冲击描记图; 体动区间; 波形补偿

中图分类号: R318 **文献标志码:** A

Ballistocardiogram Waveform Compensation Based on Phase Space Reconstruction and RBF Network

ZHENG Xiaohan^{1,2}, YANG Yueqi^{1,2}, ZHU Yan^{1,2}, LI Xiaoou^{1,2}

(1. College of Medical Instruments, Shanghai University of Medicine & Health Sciences, Shanghai 201318, China; 2. College of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In the non-contact heart rate detection method based on ballistocardiogram, the actual shape of ballistocardiogram signals is easily covered up during notable body movements. To address the obstruction caused by invalid signals in locating the heartbeat point, a waveform compensation model for notable movement segments is proposed, which combines phase space reconstruction with RBF neural network. Firstly, the improved C-C method is used to select the appropriate reconstruction parameters. Then, the network topology is determined by dynamic k-means clustering. Transform the time series before the movement into phase points in reconstructed space, and feed them into the model as learning samples. Finally, the single-step recursive prediction of invalid signal segment is realized. Experimental results show that the prediction model has good accuracy and it can reduce the influence of irregular noise in the original signal. After model modification, the mean error of beat by beat cardiac cycle is 1.27% and the mean absolute error is 8.9 ms, effectively avoiding the misjudgment of heartbeat events.

Key words: phase space reconstruction; RBF neural network; ballistocardiogram (BCG); movement segment; waveform compensation

基金项目: 上海高水平地方高校建设项目(E1-2602-21-201006-1); 上海市智能医疗器械与主动健康协同创新中心建设项目(GWV-10.1-XK05); 上海市科委地方院校能力建设项目(22010502400)。

收稿日期: 2022-03-07; **修订日期:** 2022-05-27

引 言

心冲击描计图(Ballistocardiogram, BCG)是一种非侵入式生理信息监测技术,它将血液经心室泵出后流经全身产生的一系列冲击力记录下来,能够体现人体循环系统的工作状态^[1]。相比于传统的心电(Electrocardiogram, ECG)监测设备,基于BCG的监护方案脱离了导联的束缚与粘性电极带来的皮肤负担,能够在不影响用户日常生活的状态下进行,有助于为心血管疾病的早期预防及临床诊断提供参考^[2-3]。

现有的BCG采集装置多采用压电传感器完成电信号的转换与识别,但由于BCG信号相对微弱,在测量过程中极易受到干扰,如脏器活动、肌肉收缩等,都有可能加入到振动信号中构成伪迹。近年来,大量研究人员进行了基于BCG信号的心率提取工作,算法包括频谱法、波峰检测和模板匹配等^[4-6],同时结合了小波变换、经验模态分解与各类滤波器设计,以抑制原始信号中的噪声影响^[7-9]。以上去噪方法大都针对呼吸引起的胸廓起伏或其他微弱震动而设计,在受控的实验环境下,均能达到较高的心率提取准确率。但对于不规则干扰源引起的信号受损片段,仍无法通过常见的滤波等处理手段进行排除,导致算法表现不佳。尤其是当有大量肢体动作发生时,体表原始信号产生大幅度变异甚至出现饱和,完全掩盖了真实心冲击波的形态,无法再作为提取生理信息的有效依据,为上述算法在实际场景中的推广带来了阻碍。

本文围绕显著体动状态下的失效心冲击波补偿展开算法完善。心冲击信号属于时间序列范畴,产生源为心脏的机械活动,而心脏本身作为一个复杂的非线性系统,呈现出一种确定性与随机性相统一的混沌状态。目前针对混沌系统的数据分析方法已被应用于心电、心音信号的特征提取与预测中^[10],关于BCG信号的混沌特性也已得到证实^[11]。故本文将基于混沌理论的时间序列预测方法引入到对缺损数据段的处理中,选取合适的神经网络结构并进行构建,提出了一种结合相空间重构与径向基函数(Radial basis function, RBF)网络的心冲击序列预测模型,并分别在正常数据段与包含体动干扰的数据段上对模型效果作出检验。

1 数据准备

1.1 信号采集

聚偏二氟乙烯(Polyvinylidene fluoride, PVDF)是一种新型敏感聚合材料,当受外力作用产生机械形变时会引发成比例的电荷中心移动^[12]。基于PVDF的压电薄膜传感器质地轻薄、耐用性强,且不存在加速度传感器固有的机械噪声问题,因此非常适用于人体体震信号的采集。本文将10片压电薄膜并列排布并嵌入床垫装置中,构成了多通道式无感生命体征监测设备,然后通过电荷放大电路与50 Hz的陷波电路,在屏蔽工频干扰的同时放大有效信号,再经STM32F103ZE的12位AD模块转换为数字信号后,通过串口通讯以500 Hz的采样率向PC端传输数据,完成对原始心冲击信号的获取。

1.2 预处理

正常状态下的原始信号仍然是呼吸运动、心脏活动与各类噪声的叠加,需要通过滤波降低信号的复杂度,更好地应用于后续模型中。考虑到信号处理的实时性要求与滤波器的频率响应特性,本文选用运算量较小,且具有最大通频带平坦度的巴特沃斯滤波器进行降噪。在滤波范围的选择上,虽然BCG信号的能量在0.9~20.0 Hz均有分布,但研究表明其中对构建特征波形起正向作用的谐波大都集中在一个更窄的频段内,而其余谐波的存在则是造成信号毛刺甚至削减特征波峰的主要原因^[13]。故本文采用分段滤波的方式对信号进行梯度式分解,经不同通带宽度下的特征波峰突出程度比较后,确定滤波通带范围为1~11 Hz。

滤波后信号的振幅值范围为0~3 800 mV,过大的输入数据数量级容易造成神经网络隐含节点过饱和,从而导致网络收敛困难。为避免上述状态,应对样本数据进行归一化处理。常规的最大最小归一化方法会将数据缩放到[0, 1]区间内,而近年来有文献指出,将映射范围控制在[0.2, 0.8]时网络计算效果更佳^[14],本文依此使用改进的归一化,对应公式为

$$x'_i = \frac{(0.8 - 0.2)(x_i - x_{\min})}{x_{\max} - x_{\min}} + 0.2 \quad (1)$$

式中: x_i 为滤波处理后的实际信号序列; x_{\max} 和 x_{\min} 分别为 x_i 中的最大和最小值。此外,在预测完成后,还应通过对应的返回一化公式输出真实值

$$y_i = \frac{(y'_i - 0.2)(y_{\max} - y_{\min})}{0.8 - 0.2} + y_{\min} \quad (2)$$

2 心冲击信号的混沌特性分析

2.1 相空间重构理论

一个复杂系统往往受到多种控制因素的共同作用,当其中某一因素发生变化时,也蕴含了其他影响因素所引起变化的相关动态信息,这种隐藏的秩序难以从低维坐标系中直接观测得到,因此有必要采取措施剥离内在分量的关系。相空间重构在本质上是将一维的时间序列进行维数拓展,从而恢复出原系统在高维空间上的混沌吸引子。依据 Takens 定理^[15],若动力系统的关联维数为 d ,当选取一个合适的嵌入维 m 满足 $m \geq 2d + 1$ 时,重构出的相空间轨迹线将与原动力系统保持微分同胚,即保留了系统状态轨迹演化的所有规律信息,由此规律便可从当前系统状态中推测下一时刻状态,这为混沌时间序列的短期可预测性提供了理论支撑。

根据 Packard 等提出的坐标延迟法,对于预处理后得到的一维 BCG 信号观测值 $x = \{x_i | i = 1, 2, \dots, N\}$,可重构为 m 维相空间矢量,可表示为

$$\begin{cases} X_1 = [x_1, x_{1+\tau}, \dots, x_{1+(m-1)\tau}]^T \\ X_2 = [x_2, x_{2+\tau}, \dots, x_{2+(m-1)\tau}]^T \\ \vdots \\ X_M = [x_M, x_{M+\tau}, \dots, x_{M+(m-1)\tau}]^T \end{cases} \quad (3)$$

式中: m 为嵌入维数; τ 为时间延迟,对于离散数据可表示为延迟量 k 与采样时间间隔 Δt 的乘积; $M = N - (m - 1)\tau$ 为相空间中相点的个数。

2.2 时间延迟 τ 和嵌入维数 m 确定

相空间重构过程中 m 与 τ 的取值直接决定了重构吸引子的形状,是影响相空间对原系统特征描述能力的关键因素。通过选取恰当的时间延迟可以消除时间序列的冗余信息,更好地体现系统的状态变换;而嵌入维数应在确保展现原系统结构的前提下取最小值,过大的维数不仅会造成数据计算量的浪费,还可能引入噪声。

在实际工程中获得的时间序列往往长度有限且含有干扰信息,对于其非线性特征也无法作出合理假设,因此并不适用于单独计算两个参数的算法。另有大量研究指出,时间延迟 τ 和嵌入维数 m 之间存在着密切的关联性,能够对重构相空间质量产生显著影响的并非单个参数的变化,而是组合构成的嵌入窗口 $\tau_w = (m - 1)\tau$ 。在嵌入窗思想的基础上产生了一系列同步计算 τ 和 m 的联合算法,本文从运算的精度与稳定性出发,选择改进的 C-C 法确定相空间重构参数^[16],具体过程如下:

将混沌时间序列 $x = \{x_i\}$ 进行重构后得到相点

$$X_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad i = 1, 2, \dots, M \quad (4)$$

定义该嵌入序列的关联积分为

$$C(m, N, r, \tau) = \frac{2}{M(M-1)} \sum_{1 \leq i < j \leq M} \theta(r - d_{ij}) \quad r > 0 \quad (5)$$

式中: $r (r > 0)$ 为定义的搜索半径; $d_{ij} = \|x_i - x_j\|_\infty$ 为两相点间的空间距离, 使用无穷范数表示; θ 为 Heaviside 阶跃函数, 满足

$$\theta(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (6)$$

关联积分的意义为相空间中任意两点之间距离小于 r 的概率, 在此基础上定义 $x = \{x_i\}$ 的检验统计量为

$$S_1(m, N, r, \tau) = C(m, N, r, \tau) - C^m(1, N, r, \tau) \quad (7)$$

$S_1(m, N, r, \tau)$ 体现了时间序列的自相关性, 在进行计算时可采用分块平均的策略提升运算速度, 即分别计算出每个子时间序列统计量再取均值

$$S_2(m, N, r, \tau) = \frac{1}{\tau} \sum_{s=1}^{\tau} \left[C_s \left(m, \frac{N}{\tau}, r, \tau \right) - C_s^m \left(1, \frac{N}{\tau}, r, \tau \right) \right] \quad (8)$$

为度量 $S_2(m, N, r, \tau)$ 在不同 τ 下的偏差, 选择 τ 对应的最大值与最小值定义差量为

$$\Delta S(m, \tau) = \max \{ S(m, N, r_k, \tau) \} - \min \{ S(m, N, r_k, \tau) \} \quad (9)$$

根据 BDS 统计结论对式 (9) 参数进行合理估计, 取 $m = 2, 3, 4, 5$; $N = 3000$; $r_k = k\sigma/2$, 其中 $k = 1, 2, 3, 4$, σ 为时间序列 $x = \{x_i\}$ 的标准差; $\tau = 1, 2, \dots, 400$ 。分别计算如下统计量

$$\Delta \bar{S}_1(\tau) = \frac{1}{4} \sum_{m=2}^5 \Delta S_1(m, \tau) \quad (10)$$

$$\bar{S}_1(\tau) = \frac{1}{16} \sum_{m=2}^5 \sum_{k=1}^4 S_1(m, r_k, \tau) \quad (11)$$

$$\bar{S}_2(\tau) = \frac{1}{16} \sum_{m=2}^5 \sum_{k=1}^4 S_2(m, r_k, \tau) \quad (12)$$

改进的 C-C 算法将寻找 $\Delta \bar{S}_1(\tau)$ 曲线第一个局部极小值点对应的 τ 为最优时延, 此时重构空间中的相点分布接近均匀, 有利于重构轨道在相空间中的展开。同时以 $\bar{S}_1(\tau) - \bar{S}_2(\tau)$ 的周期节点作为最优嵌入窗 τ_w , 再根据式 (13) 求得最佳嵌入维数 τ

$$\tau_w = (m - 1)\tau \quad (13)$$

3 基于混沌-RBF的预测模型

3.1 预测原理与依据

由混沌理论可知, 重构空间中相邻相点间的演化关系可以用一个映射 $F(\cdot)$ 描述。设当前状态的相点为 X_i , 则下一时刻对应状态为

$$X_{i+1} = F(X_i) \quad (14)$$

又由式 (3) 可得 $X_{i+1} = [x_i, x_{i+1+\tau}, \dots, x_{i+1+(m-1)\tau}]^T$, 观察该向量发现其中前 $m - 1$ 个分量均为已知数据, 而最后一个未知分量 $x_{i+1+(m-1)\tau}$ 正是时间序列的下一待预测点。因此混沌时间序列预测的基本思想为构建出当前相点与预测值的状态转移方程 $h(\cdot)$, 可表示为

$$x_{i+1+(m-1)\tau} = h([x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}]^T) \quad (15)$$

Takens定理还指出,相邻状态点的内部分量变化趋势几乎是相同的,这意味着可以将 X_i 的 K 个邻近节点 $X_{i-k} \sim X_{i-1}$ 及其对应的下一时刻分量 $x_{i-k+1+(m-1)\tau} \sim x_{i+(m-1)\tau}$ 作为参考,寻求出与 $h(\cdot)$ 类似的映射关系。但对于复杂的非线性系统而言,这一规则难以依靠常规拟合方法作出准确表达,同时在生理参数监测场景中还需兼顾系统的时效性,对模型的精度与速度均提出了较高要求。在此背景下引入神经网络解决方案,人工神经网络是从信息处理层面对神经元的抽象组合,可以凭借其强大的自学习和泛化能力从历史数据中挖掘规律,从而有效地进行回归预测。

综上因素,本文采用RBF神经网络(结构如图1所示),并以重构相空间中的参考点作为样本进行模型训练。RBF网络能够模拟人脑皮质层中接收域相互覆盖又局部调整的生物学特性,其中隐含层节点由一个沿径向对称的标量函数 $\phi(x) = \phi(\|x\|)$ 构成,它使得靠近函数中央区域的输入信号能够获得更大的输出响应,通常选用高斯函数。对于从输入向量到隐含空间的非线性映射过程 $X \rightarrow R$,若隐含单元数量为 q ,则第 i 个节点输出为

$$R_i = \exp\left(-\frac{1}{2\sigma^2}\|X - c_i\|^2\right) \quad i = 1, 2, \dots, q \quad (16)$$

式中: c_i 为第 i 个高斯核函数的中心矢量,与输入向量 X 维数相同; σ_i 为基函数的宽度,其取值与激活函数作用范围成正比,影响着结果的光滑程度; $\|\cdot\|$ 表示两向量间的欧式距离。从隐藏层空间到输出层空间为线性变换 $R \rightarrow Y$,若输出向量维数为 k ,则第 j 个输出节点表达式为

$$Y_j = \sum_{i=1}^q w_{ij} R_i \quad j = 1, 2, \dots, k \quad (17)$$

式中: w_{ij} 表示这一输出节点与第 i 个隐含层单元间的连接权值,体现了该隐含单元对输出向量的贡献程度。

RBF网络虽然结构简洁,却有着优越的非线性函数刻画性能,理论上能够以任意精度进行逼近。除此之外,径向核函数的局部响应特性也在一定程度上精简了运算量,再加上单一的隐含层数目,使网络收敛效率较之传统神经网络有了显著提升,其优势已在短期电力负荷与交通流预测等领域中得以展现^[17]。

3.2 网络构建与训练

根据3.1节所述RBF网络拓扑结构,在进行构建时首先需要确定网络的输入层及输出层节点数目。研究人员已证实当输入层神经元个数等于该系统的嵌入维数 m 时预测效果更佳^[18],又由本文预测类型为单步预测可知,对应输出单元数量应设置为1。对余下网络参数的训练可以分为两个阶段:一是隐含层节点中心与方差的选取,属于无监督学习过程;二是对于隐含层与输出层间的权值调整,属于有监督式学习。

隐含层的节点参数是影响网络性能的关键因素,若选取不当则可能引发网络的过拟合或欠拟合问题。本文使用动态K-means聚类算法确定隐含节点的最佳数量与中心值,所谓动态是指在初始化聚类中心时,不再依赖事先设定的中心个数 k 从数据样本中随机抽取,而是借助最大最小距离法选取尽可能离散的对象作为初始中心,并通过试探的方式自适应地调整聚类中心的个数^[19]。这种启发式的学习机制克服了传统K-means初值选择过于随机以及聚类个数 k 难以估计的缺点,能够保证各聚类结果之间的低相似性,具体学习过程如下:




图1 典型RBF神经网络结构
Fig.1 Typical RBF neural network structure

- (1) 从输入集合 $S_n = \{X_1, X_2, \dots, X_n\}$ 中任取一个数据对象 X_p 作为首个聚类中心, 然后依据它与其他对象的欧式距离, 找出相隔最远的样本作为第二个聚类中心 X_q ;
- (2) 对于 S_n 中剩余数据 X_i , 分别计算它与前两个中心间距 $\{X_{ip}, X_{iq}\}$, 并记其中较小值为 Dis_{X_i} ;
- (3) 计算所有 Dis_{X_i} 中的最大值 $\max S_n\{Dis_{X_i}\}$, 当满足条件 $\max S_n\{Dis_{X_i}\} > m \times [\text{average}(|X_p - X_q|)]$ 时, 便将 X_i 作为新的聚类中心, 通常取 $m \in [1/2, 1)$;
- (4) 重复步骤(2)~(3)直至不再有新的中心产生, 此时被选中的数据样本即为优化的初始聚类中心 $C = \{c_1, c_2, \dots, c_k\}$;
- (5) 计算各样本与中心点的欧氏距离, 并以此作为相似性度量指标, 将样本分配至最邻近的聚类集合中;
- (6) 对于再分配后的样本类簇, 再次计算簇内所有数据的均值作为新的质心;
- (7) 比较新质心位置与原质心的差别, 若相隔距离小于某一阈值, 则说明学习过程趋于稳定, 可以终止算法, 否则还需重复步骤(5, 6)。

本文所使用径向基函数为高斯函数, 因此在动态聚类过程完成后, 其方差 σ_i 可由式(18)计算得到。

$$\sigma_i = \frac{c_{\max}}{\sqrt{2h}} \quad i = 1, 2, \dots, h \quad (18)$$

式中: c_{\max} 表示所有中心间距的最大值; h 为隐含层单元的个数。此时得到的高斯函数宽度均匀固定, 预测结果更为平滑。一旦确定了隐含节点参数便可进入有监督学习阶段, 本文通过最小二乘法修正线性映射中的连接权值 w_{ij} 为

$$w_{ij} = \exp\left(-\frac{h}{c_{\max}^2} \|X - c_i\|^2\right) \quad (19)$$

3.3 心冲击波形补偿模型设计

在网络在线学习过程中, 原始数据容量会随时间不断增长, 如果仍将全部历史数据作为学习样本将导致网络训练负担过重。因此本文引入了滑动窗口机制, 即只选取固定长度的数据进行网络训练, 并随时间推进不断移动窗口, 保证了神经网络学习的时效性。当检测到显著体动发生时, 使用本文所建立的单步递归预测模型对失效数据片段作出修正, 模型整体流程如图 2 所示。

(1) 依据滑动窗口策略截取平静状态下的历史数据序列 $\{x_i\}$, 然后进行去噪与归一化处理, 以消除数据本身干扰对模型精度的影响;

(2) 采用改进的 C-C 法进行该时间序列最佳时间延迟 τ 与嵌入维数 m 的求解;

(3) 使用步骤 2 得到的重构参数进行混沌序列相空间重构, 将原系统动力分量投射至高维空间中, 得到相轨迹矩阵 X ;

(4) 根据时间序列的最佳嵌入维数确定神经网络的拓扑结构, 随后以相空间中的点向量矩阵为学习样本, 通过动态 K-means 聚类与最小二乘估计进行网络参数训练, 达到预设目标;

(5) 将最后一个相点矢量输入到步骤 4 训练好的网络中, 获得输出即下一时刻预测值 Y_{k+1} ;

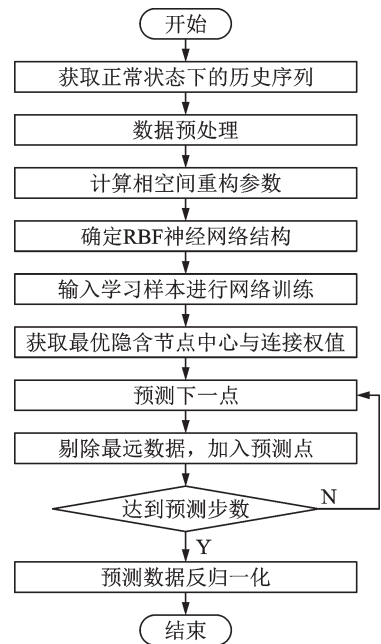


图 2 基于混沌-RBF 神经网络的模型流程

Fig.2 Model flow based on chaos-RBF neural network

(6) 剔除原时间序列最远端的数据点,同时将步骤5得到的预测值添加至末尾,使序列总体维度保持不变,随后预测下一点 Y_{k+2} ,重复步骤5、6至体动状态结束;

(7) 预测结束后进行反归一化处理,恢复真实的预测值,再将补偿后的心冲击信号用于相应的心率提取算法中。

4 实验结果与分析

4.1 模型效果验证实验

本文在 Matlab R2019a 环境下对模型进行仿真实验。为了检验模型的正确性,首先从一段未受显著体动干扰的心冲击信号中划分出训练集与测试集,通过与真实数据的对比来衡量预测性能。图3(a)给出了平静状态下从采集通道中获取的原始心冲击信号,序列长度 $L = 4\ 000$,图3(b)为其经过初步降噪的结果。

采用2.2节所述改进的C-C法进行时间序列的混沌分析,绘制统计量 $\Delta\bar{S}_1(\tau)$ 与 $|\bar{S}_1(\tau) - \bar{S}_2(\tau)|$ 随时延 τ 的变化曲线如图4所示。观察 $\Delta\bar{S}_1(\tau)$ 的首个局部极值点位置,得到对应的最优延迟时间为 $\tau = 32$,又由 $|\bar{S}_1(\tau) - \bar{S}_2(\tau)|$ 的周期节点可知嵌入窗口 $\tau_w = 358$,根据式(13)计算得嵌入维数 $m = 12.18$,为了更好地描述混沌系统结构,向上取整至 $m = 13$ 。

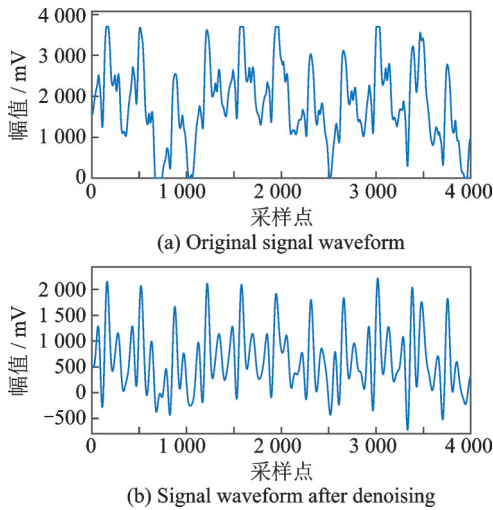


图3 心冲击信号预处理

Fig.3 Preprocessing of BCG signal




图4 改进C-C法求重构参数

Fig.4 Improved C-C method to calculate parameters

在实际心冲击信号的采集过程中,类似翻身等动作的影响将持续大约 $1\sim 2$ s。现假设上述信号的后1000点为待预测的数据段 L_{test} ,对应的训练集为前3000个历史数据,记作 L_{train} 。根据确定好的参数 m 与 τ 对时间序列 L_{train} 实施相空间重构,对应的高维空间相点个数为 $M = L_{train} - (m - 1)\tau = 2\ 616$ 。若使用列向量来表示重构空间中的一个状态点,则可构成一个 $13 \times 2\ 616$ 的矢量矩阵为

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_{2\ 616} \end{bmatrix}^T = \begin{bmatrix} x_1 & x_2 & \cdots & x_{2\ 616} \\ x_{33} & x_{34} & \cdots & x_{2\ 648} \\ \vdots & \vdots & \ddots & \vdots \\ x_{385} & x_{386} & \cdots & x_{3\ 000} \end{bmatrix}$$

根据混沌时间序列预测的原理,借助神经网络求解的目标实际上是 $x_{i+1+(m-1)\tau}$ 与 $[x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}]^T$ 之间的非线性映射关系,故将已获得的相点矩阵 X 进一步分解,得到网络的输入与输出合

集: $P=[X_1 \ X_2 \ \dots \ X_{2615}]$, $T=[x_{386}, x_{387}, \dots, x_{3000}]$ 。

依照3.3节所述方法构建RBF神经网络,其中隐含层节点的个数由动态聚类方法计算得到,最终确定网络的拓扑结构为13-19-1。随后将 P 输入网络中开始训练,在达到目标精度后保存当前网络参数,包括基函数的中心、宽度以及隐含层至输出层的权值矩阵。同时作为对照,本文也使用了BP神经网络,以及通过传统K-means聚类方式生成的RBF网络进行了预测。图5中给出了3种模型实验结果与真实值的比较,图6为其对应的相对误差曲线,从图中可以观察到采用动态聚类方式构建的RBF神经网络误差波动比其他模型要平稳很多,这表明预测信号与真实信号的拟合程度更高,尤其是考虑到后续进行心跳间隔提取时,心跳定位所关注的特征波峰出现位置也基本一致。这说明对基于心冲击信号的非接触式心率检测算法而言,处理过程中使用该模型结果替换一定区间内数据的思想具有可行性。

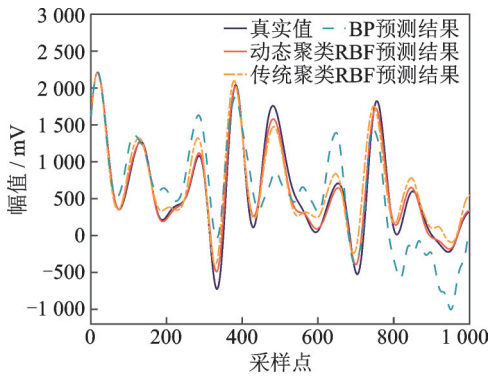


图5 不同模型的预测结果对比

Fig.5 Comparison of prediction results of different models

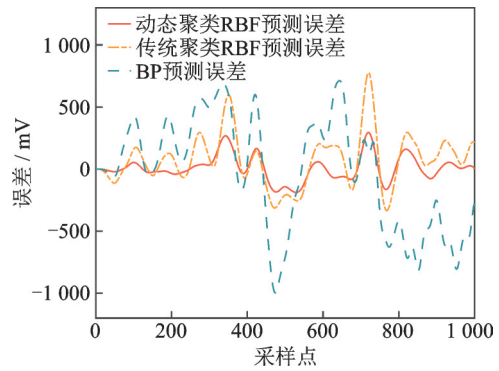


图6 不同模型的预测误差对比

Fig.6 Comparison of prediction errors of different models

为了进一步印证模型的有效性,分别使用平均绝对百分比误差(Mean absolute percentage error, MAPE)、整体均方根误差(Root mean squared error, RMSE)和决定系数(R^2)三种评价指标对预测结果作定量分析,对应的计算公式分别为

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y'_i - y_i}{y_i} \right| \times 100\% \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (21)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y'_i - y_i)^2}{\sum_{i=1}^n (y'_i - \bar{y})^2} \quad (22)$$

式中: n 为预测样本数; y'_i 与 y_i 分别为预测值与真实值。

表1中给出了3种预测模型的评价指标数据,其中误差指标MAPE和RMSE的数值愈小,表示预测结果愈精确,而决定系数越接近1,说明预测的结果越接近真实值。由表1中数据可见,基于相空间重构与RBF神

表1 不同预测模型的评价指标

Table 1 Evaluation indicators of different prediction models

预测模型	MAPE	RMSE	R^2	训练时间/s
BP网络	452.919	2.199	0.502	51.483
传统聚类RBF网络	234.999	0.931	0.866	9.285
动态聚类RBF网络	100.714	0.398	0.975	8.671

经网络融合的预测模型各指标表现均优于其他两类网络。同时得益于RBF的全局逼近能力,能够使模型避免陷入局部最优问题,网络整体训练速度更快,能够满足生理信号检测的实时性要求。除上述指标外,由于BP网络的初始化是随机的,因此每次实验结果都不尽相同,相比之下本文所提出模型的在稳定性方面具有明显优势。

4.2 波形补偿应用实例

经过4.1节的验证实验,模型的可用性与优越性已经得到了体现,现进一步测试其在排除不规则扰动中的应用效果。选取一段被受试者大幅动作干扰的原始心冲击数据如图7(a)所示,再以上文中同样的滤波方式进行预处理,结果如图7(b)所示。由图中可见采样点5 000处产生了异常波形,在其后大约1 300点原始信号才恢复稳定,并且在这种情况下,通过常规去噪方法并没有作出有效调整,预处理结果不能够直接用作进一步的分析,给心跳位置的正确识别造成了阻碍。

根据3.3节所述框架,对目标区间前3 000点的数据实施相空间重构与RBF网络构建,并将学习完成的模型应用到失效信号的预测中。图8给出了使用预测值填补体动区间的结果,其中橙色线条为模型预测结果,可以看出神经网络很好地模拟了混沌时间序列的变化趋势,从被噪声淹没的原始数据中恢复出了典型的心冲击波形态,并且就虚线右端与实线的衔接处而言,预测值与真实值间误差在可接受范围内。

以图8中的预测结果作为原始数据的替代,再截取前后共30 s的数据作为样本,使用改进的峰值检测法来提取心动周期数据。在心冲击信号的采集过程中,本实验还使用医用监护模块完成了同步心电数据的获取,因此可使用心电信号作为计算心跳间隔的金标准,得到心跳间隔序列的结果如图9所示。

图9中的黑色线条表示使用原始波形进行心动周期的计算,可以看到在体动区间内数值产生了突变,计算精度大受影响。而使用模型修正后的心冲击信号对应结果使用橙色线条表示,它与蓝色线条代表的金标准数据基本吻合,逐拍心动周期的平均误差为1.27%,平均绝对误差为8.9 ms,不存在未检出的假阴性点或误差超过100 ms的假阳性点。这表示本文所用模型能够恢复出被体动噪声掩盖的心冲击波形,有效提升了非接触式心率检测方法的抗干扰能力。

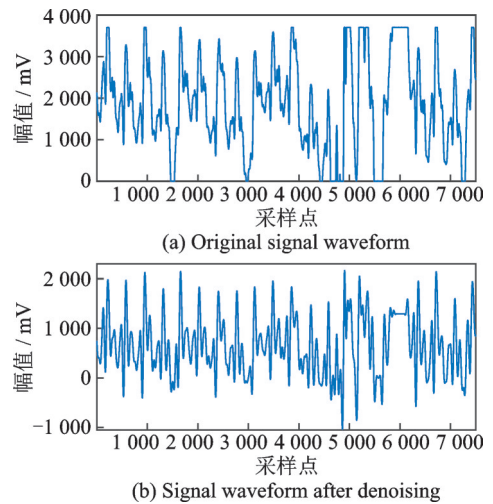


图7 包含体动干扰的心冲击信号预处理

Fig.7 Preprocessing of BCG signal with body motion segments




图8 含体动段心冲击波补偿结果

Fig.8 Results of BCG compensation with body motion segments




图9 心跳间隔计算结果比较

Fig.9 Comparison of calculation results of heart-beat interval

5 结束语

针对心冲击信号在收集过程中易被体动噪声掩盖的问题,本文在分析其作为时间序列的混沌特性基础上,提出了一种基于相空间重构与动态K-means聚类RBF神经网络相结合的体动段无效波形补偿模型,并将该模型补充至非接触式心率检测的信号处理过程中。

使用本文提出模型在未发生体动的信号段上进行序列重构与预测,所得预测结果与实际波形吻合程度较高。与使用BP神经网络以及传统K-means聚类获得的RBF网络相比,该模型在维持较高预测精度的前提下,网络收敛速度更快,结果稳定性也更好,这说明合理选择重构参数与网络构造方式是提高模型预测性能的重要因素。应用实例的结果也表明,当有明显的肢体动作发生时,经过模型补偿后的心冲击波形能够消除不规则噪声带来的异常数据,有效地恢复出被体动淹没的真实心冲击形态,这为后续的心跳位置检测提供了可靠的信号基础。

参考文献:

- [1] SADEK I, BISWAS J, ABDULRAZAK B. Ballistocardiogram signal processing: A review[J]. Health Information Science & Systems, 2019, 7(1): 1-23.
- [2] 蒋芳芳, 徐敬傲, 李任, 等. 基于CNN的心冲击信号阵发性房颤自动检测方法[J]. 东北大学学报(自然科学版), 2019, 40(11): 1539-1542, 1548.
JIANG Fangfang, XU Jingao, LI Ren, et al. Automatic detection method of paroxysmal atrial fibrillation for ballistocardiogram based on CNN[J]. Journal of Northeastern University(Natural Science), 2019, 40(11): 1539-1542, 1548.
- [3] YU B, ZHANG B, XU L, et al. Automatic detection of atrial fibrillation from ballistocardiogram (BCG) using wavelet features and machine learning[C]//Proceedings of 2019 41st Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Berlin: IEEE, 2019: 4322-4325.
- [4] XIE Q, WANG G, LIAN Y. Heart rate estimation from ballistocardiography based on Hilbert transform and phase vocoder [C]//Proceedings of 2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS). Chengdu, China: IEEE, 2019: 139-142.
- [5] 刘今越, 毕圆浩, 贾晓辉, 等. 睡眠中逐次心跳周期的无束缚提取方法研究[J]. 仪器仪表学报, 2019, 40(4): 100-106.
LIU Jinyue, BI Yuanhao, JIA Xiaohui, et al. Research on extraction method of successive cardiac cycle in the unbound sleep[J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 100-106.
- [6] PAALASMAA J, TOIVONEN H, PARTINEN M. Adaptive heartbeat modeling for beat-to-beat heart rate measurement in ballistocardiograms[J]. IEEE Journal of Biomedical & Health Informatics, 2015, 19(6): 1945-1952.
- [7] CARLOS A, PABLO S L, RAMON P. An algorithm for beat-to-beat heart rate detection from the BCG based on the continuous spline wavelet transform[J]. Biomedical Signal Processing and Control, 2016, 27(5): 96-102.
- [8] 郑红梅, 葛淼, 陈科, 等. 基于FCEEMD的心跳信号和呼吸信号分离研究[J]. 电子测量与仪器学报, 2017, 31(11): 1809-1814.
ZHENG Hongmei, GE Miao, CHEN Ke, et al. Research on separation of heartbeat signal and respiration signal based on FCEEMD[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(11): 1809-1814.
- [9] SHEN G, DING R, YANG M, et al. An elastic manifold learning approach to beat-to-beat interval estimation with ballistocardiography signals[J]. Advanced Engineering Informatics, 2020, 44(4): 101051.
- [10] 成谢锋, 李允怡, 姜炜, 等. 基于混沌理论的心音预测模型、方法与应用[J]. 南京邮电大学学报(自然科学版), 2016, 36(3): 33-39.
CHENG Xiefeng, LI Yunyi, JIANG Wei, et al. Heart sound prediction model, method and application based on chaos theory [J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2016, 36(3): 33-39.
- [11] JIANG F, XU W, JIN J, et al. Periodicity detection of ballistocardiogram based on chaotic oscillators[C]//Proceedings of 2010 2nd International Conference on Advanced Computer Control (ICACC). Shenyang: IEEE, 2019: 209-212.
- [12] 邓红, 胡飞燕, 龙康. 聚偏氟乙烯基(PVDF)介电材料的研究进展[J]. 山东化工, 2021, 50(3): 60-62.

- DENG Hong, HU Feiyan, LONG Kang. Research progress of poly(vinylidene fluoride)-based dielectric materials[J]. Shandong Chemical Industry, 2021, 50(3): 60-62.
- [13] XIN L, YE L J. Peak extraction from non-standard ballistocardiography data: A preliminary study[C]//Proceedings of 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Orlando:IEEE, 2016: 688-691.
- [14] JU Q, YU Z, HAO Z, et al. Division-based rainfall-runoff simulations with BP neural networks and xinjiang model[J]. Neurocomputing, 2009, 72(13/14/15): 2873-2883.
- [15] TAKENS F. Reconstruction theory and nonlinear time series analysis-sciencedirect[J]. Handbook of Dynamical Systems, 2010, 3(3): 345, 347-377.
- [16] 陆振波, 蔡志明, 姜可宇. 基于改进的C-C方法的相空间重构参数选择[J]. 系统仿真学报, 2007, 11(19): 2527-2529, 2538. LU Zhenbo, CAI Zhiming, JIANG Keyu. Determination of embedding parameters for phase space reconstruction based on improved C-C method[J]. Journal of System Simulation, 2007, 11(19): 2527-2529, 2538.
- [17] 张宇涵, 高海波, 商蕾, 等. 基于神经网络模型的船舶电网短期电力负荷预测[J]. 应用科技, 2021, 48(5): 12-15, 22. ZHANG Yuhan, GAO Haibo, SHANG Lei, et al. Short-term load forecasting for marine electric network based on neural network models[J]. Applied Science and Technology, 2021, 48(5): 12-15, 22.
- [18] 韩敏, 任伟杰, 李柏松, 等. 混沌时间序列分析与预测研究综述[J]. 信息与控制, 2020, 49(1): 24-35. HAN Min, REN Weijie, LI Baisong, et al. Survey of chaotic time series analysis and prediction[J]. Information and Control, 2020, 49(1): 24-35.
- [19] 刘燕. 基于抽样和最大最小距离法的并行K-means聚类算法[J]. 智能计算机与应用, 2018, 8(6): 37-39, 43. LIU Yan. Parallel K-means clustering algorithm based on sampling and maximum & minimum distance method[J]. Intelligent Computer and Applications, 2018, 8(6): 37-39, 43.

作者简介:



郑小涵(1998-),女,硕士研究生,研究方向:人体医学信号处理, E-mail: 1064253420@qq.com。



杨越琪(1997-),女,硕士研究生,研究方向:医疗设备的应用与医学信号处理。



朱岩(1997-),女,硕士研究生,研究方向:人体医学信号处理。



李晓欧(1975-),通信作者,男,博士,教授,研究方向:生物医学信息处理, E-mail:lixo@sumhs.edu.cn。

(编辑:王静)