

基于小波分析与 BP 神经网络的人体血压预测^①

方 杰, 张 征

(华中科技大学 自动化学院, 武汉 430074)

摘 要: 及时、准确预测人体血压变化从而预防人体血压不稳定导致的病情加重的情况发生显得越来越重要. 对此本文提出一种基于小波分析与 BP 神经网络组合的人体血压预测模型, 该模型利用小波分解重构法对非平稳的人体血压序列进行分解重构计算, 分离出原始序列中的高频细节分量和低频趋势分量, 再利用 BP 神经网络预测算法对各层分量建立预测模型, 最后将两种模型的预测值进行叠加, 得到原始血压序列的预测值. 研究表明, 该组合预测模型的预测精度明显高于传统 BP 神经网络预测模型的预测精度, 为人体血压预测提供了一种有效可靠的组合预测方法.

关键词: 血压预测; 小波分解与重构; BP 神经网络; 组合预测

引用格式: 方杰, 张征. 基于小波分析与 BP 神经网络的人体血压预测. 计算机系统应用, 2017, 26(8): 157-161. <http://www.c-s-a.org.cn/1003-3254/5889.html>

Prediction of Human Blood Pressure Based on Wavelet Analysis and BP Neural Network

FANG Jie, ZHANG Zheng

(School of Automation, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: It is becoming increasingly important to make timely and accurate prediction of human blood pressure changes in order to prevent the exacerbation caused by the instable human blood pressure. This paper proposes a prediction model of human blood pressure based on the combination of wavelet analysis and BP neural networks. This model uses the wavelet decomposition and reconstruction method to decompose and reconstruct non-stationary human blood pressure sequence, separating the high frequency components and the low frequency components in the original sequence, then the BP neural network prediction algorithm is used to establish the prediction model for each layer. Finally, the predicted values of the two models are added to obtain the predicted values of the original series. The results show that the prediction accuracy of the combined forecasting model is obviously higher than that of the traditional BP neural network prediction model, which provides an effective and reliable combination forecasting method for human blood pressure prediction.

Key words: blood pressure prediction; wavelet decomposition and reconstruction; BP neural network; combination forecasting

心血管相关的疾病是当前常见、多发病, 脑溢血、高血压急症和急性低血压等突发疾病的发病率居高不下, 将严重威胁人类的身体健康^[1]. 然而目前大多数临床及穿戴式设备只能体现出人体当前的生理特征,

不能给患者提供在未来一段时间内是否出现某种突发急症的可靠预测, 在临床上这些突发症判断往往只能依靠医生丰富的临床经验. 那么, 有效的动脉血压预测, 能为医护人员提供一个决策支持以及预警作用, 使医

^① 收稿时间: 2016-11-29; 采用时间: 2016-12-26

护人员有宝贵的时间去检查病因,并制定相应的治疗方案.人体血压受到昼夜时间变化、季节变化、年龄增长、体重、饮食、情绪等多种因素的共同影响^[2],因此具有较强的随机性和复杂性,是一种非线性非平稳的时间序列.目前,对非平稳时间序列的预测主要有神经网络、ARIMA、KALMAN 滤波、支持向量机等单一方法^[3],由于单一预测模型是从系统某个角度对系统进行预测,考虑不全面,容易受到环境随机因素的影响,导致单一预测方法对于复杂系统在预测精度上得不到较好的满足;非平稳时间序列也有很多组合预测,如小波分析与 ARIMA 组合^[4]、小波分析与支持向量机组合^[1]、EMD 法与神经网络组合的预测方法^[5].具体到本文针对人体血压序列随机性和复杂性较强的特点,是难以用一种简单的非线性模型结构来完整描述并准确预测,考虑到小波分析(Wavelets Analysis)是处理非平稳信号的有力工具以及 BP 神经网络(Back-propagation Network)有强大的函数逼近能力、自学习和自组织能力.因此通过小波分析可将血压序列的趋势项和随机项成分较好的分离,再根据趋势项和随机项的特征分别建立 BP 神经网络预测模型进行预测,能有效的对血压序列预测.由于分离后的趋势项和随机项包含的信息相对原始信号更加单一,从而使得预测结果更加准确.所以本文提出基于小波分析与 BP 神经网络组合预测模型.

1 小波分析和 BP 神经网络的基本原理

1.1 小波分析

小波分析是一种既适用于平稳信号也适用于非平稳信号的分析方法,其基本思想是以小波函数为基底对信号进行分解,将原频率空间分解为一系列反映细节高频子空间和一个反映趋势的低频子空间,进而进行分析.小波分析将一维信号映射到二维“时间-尺度”域上,因此能通过小波函数变换分析非平稳信号的局部特征,并在二维的情况下具有信号方向选择能力,因此该方法作为一种非平稳信号处理和析的方法,引起了广泛关注^[6].目前可选用的小波函数有很多,如样条小波、Morlet 小波、Daubechies 小波等.设 $\Psi(t)$ 为基本小波,将 $\Psi(t)$ 进行变换可以得到一簇函数系:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R}, a \neq 0 \quad (1)$$

式中 $\Psi_{a,b}(t)$ 为连续小波; a 为尺度因子,反映了小波的周期长度; b 为平移因子,反映了小波时间上的平移.令 $L^2(\mathbb{R})$ 表示定义在实轴上、可测的平方可积函数空间,则对于信号 $f(t) \in L^2(\mathbb{R})$, 其连续小波变换形式为:

$$W_f(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \bar{\Psi}\left(\frac{t-b}{a}\right) dt \quad (2)$$

式中 $\bar{\Psi}(t)$ 是 $\Psi(t)$ 的共轭复数; $W_f(a,b)$ 是小波系数.根据 Mallat 算法^[7]可知,序列 $f(t)$ 分层分解可表示成:

$$f(t) = A_j f(t) + \sum_{i=1}^j D_i f(t) \quad (3)$$

根据小波分解的第 j 层低频系数和 1 至 j 层的高频系数进行序列各层分量的小波重构,即可得到原始序列的低频趋势分量和高频细节分量.小波分析能够在时间和频率上作局部变换,窗口大小具有自适应性,因而能从信号中提取更多有用信息,使人们可以在不同尺度上来观察信号,被誉为“数学显微镜”.

1.2 BP 神经网络基本原理

BP 神经网络(Back-Propagation Network)基于误差反向传播算法(BP 算法,一种梯度下降、监督式学习算法),由一个输入层、一个输出层和一个或多个隐含层构成,各层神经元仅与相邻层神经元之间单向全互联连接,是由非线性变换单元组成的前馈型网络^[8,9],如图 1 所示.




图 1 BP 网络模型结构

BP 神经网络的训练过程其实就是一个迭代过程,其中网络权值不断地被进行调整,是通过误差反向传播原理来实现的,目的是使实际输出与期望输出的误差平方和最小,最终使输出结果逐渐逼近实际值,完成网络的训练. BP 神经网络具有自适应、自组织、自学习的能力,可以处理多种变化的信息,通过有监督和无监督的学习,实现对任意非线性函数的逼近,从而适应环境的变化,能较好地应用于非平稳时间序列的预测.

但是 BP 神经网络也有一定的缺陷,即网络的隐含层单元数的选取尚无理论指导,算法收敛速度慢。

2 小波分析和 BP 神经网络组合预测模型

根据以上的小波分解与重构计算,可以将血压序列一层一层分解到不同的频率通道上。由于分解后的各层分量在频率上比原始序列单一,并且小波分解对序列作了平滑处理,因此分解后的血压序列的平稳性比原始序列好^[10]。这样利用 BP 神经网络针对小波分解与重构后的高频和低频分量的不同特征选取不同的参数进行预测。

预测模型的计算步骤如下:

(1) 人体血压序列单尺度分解

由于人体血压序列是非平稳信号,而 Daubechies (dbN)系列小波是典型的具有时频紧支撑的正交小波基,适用于非平稳信号的提取,因而这里采用 db4 小波作为血压序列小波分析的基函数,然后对原始血压序列 $X(t)$ 进行低频和高频小波分解。由小波变换的 Mallat 算法分解,先通过低通滤波器和高通滤波器对原始信号进行滤波处理,然后进行采样,从而得到分解系数。分解公式如下:

$$C_j = HC_{j-1}, D_j = GC_{j-1}, j = 1, 2, \dots, J \quad (4)$$

C_j 与 D_j 分别表示原始信号在 2^j 分辨率下的低频信息和高频信息, H 表示低通滤波器, G 表示高通滤波器, j 表示分解尺度。

(2) 低频与高频分量的重构

基于分解所选用的小波基函数分别对血压序列的低频系数和高频系数进行单支重构,低频与高频分解系数经小波算法重构到原尺度上,得到血压低频分量 $L(t)$ 和高频分量 $H(t)$ 。小波重构是小波分解的逆过程,即先进行插值再进行滤波处理,重构算法公式如下:

$$C_j = H^* C_{j+1} + G^* D_{j+1}, j = J-1, J-2, \dots, 0 \quad (5)$$

其中 H^* 与 G^* 分别表示 H 和 G 的对偶算子。

(3) BP 神经网络预测

利用 BP 神经网络预测模型对 $L(t)$ 和 $H(t)$ 分别进行预测。本文建立一个具有单隐含层 BP 神经网络结构预测模型,模型输入层神经元个数 6 个,输出神经元个数 1。隐含层神经元个数根据经验公式 $M = \sqrt{m+n} + a$, m 是输入层节点数, n 是输出节点数, $a \in [0, 10]$, 再通过试凑法,经多次实验对比,确定低频分量预测模型的

隐含层神经元最佳数目为 12, 高频分量预测模型的隐含层神经元最佳数目为 7, 隐含层中神经元采用 Sigmoid 变换函数,输出层神经元采用线性传递函数,网络训练函数选用 trainlm, 该函数利用 Levenberg-Marquard 算法训练前向网络,该算法训练速度比梯度下降法要快很多。网络输入为小波分解与重构后的 $L(t)$ 或 $H(t)$, 从输入层经隐含层逐层处理,直至输出层输出各层分量 $\hat{L}(t)$ 和 $\hat{H}(t)$ 。

(4) 最终预测序列合成

将上述 $\hat{L}(t)$ 和 $\hat{H}(t)$ 序列预测结果由下式叠加得到 $X(t)$ 的预测值 $\hat{X}(t)$, 即获得对应于原始血压序列的预测结果。

$$\hat{X}(t) = \hat{L}(t) + \hat{H}(t) \quad (6)$$

由上述思想和计算步骤构造的小波分析与神经网络的组合预测模型结构框图如图 2 所示。




图2 小波分析与BP神经网络预测模型

3 实验分析

本文实验数据来源于美国的复杂生理信号研究资源网站 PhsioNet 的 The MIMIC II Waveform Database 中患者的血压相关数据^[11], 这些数据都经过了医生的确认和患者的许可, 可以免费提供给研究人员下载使用。本次实验数据来自编号 a40001T 病患从 2014 年 7 月 19 日 20 点 59 分到 2014 年 7 月 20 号 0 点 33 分的收缩压数据, 共 1283 个采样点, 前 840 份用作训练, 后 443 份作测试(时间间隔 10 秒)(见图 3)。

3.1 血压序列的分解与重构

利用 Mallat 塔式算法选用 db4 小波对原始血压序列进行单尺度一维分解, 并对分解后的一维分解系数进行重构得到高频细节分量和低频趋势分量(见图 4)。

3.2 低频与高频分量预测及结果叠加

根据血压时间序列, 进行单步预测, 即 $X(t)$ 由 $X(t-1)$, $X(t-2)$, ..., $X(t-L)$ 共 L 个数据测得, 这里 L 取 6。采用多输入、单输出的 BP 神经网络结构分别对血压的低频和高频分量进行预测, 其中输入层用 6 个神经元, 输出层 1 个神经元, 低频分量预测模型中隐含层神经

元 12 个, 高频分量预测模型中隐含层神经元 7 个, 网络的初始权值由随机函数给出. 使用小波分解重构后的高低频分量的前 840 个数据分别对各自的神经网络进行训练, 并用后 443 个数据进行测试, 从图 5 可以看出高低频预测取得了较好的效果.




图3 原始血压序列图

在完成高频与低频分量的预测后, 将预测结果根据式(6)合成为原始血压序列的预测值 $\hat{X}(t)$, 结果如图 6 所示.

3.3 实验预测结果误差分析

本文采用平均相对误差和均方根误差两种不同的评价准则作为模型预测结果评估标准. 平均相对误差反映了预测曲线与实际形状的相似程度, 均方根误差反映了预测值对实际观测值的平均偏离程度. 这两种误差评价函数能从不同的侧面和角度描述误差的特征^[12]. 指标计算如下.




图4 重构后的低频和高频信号

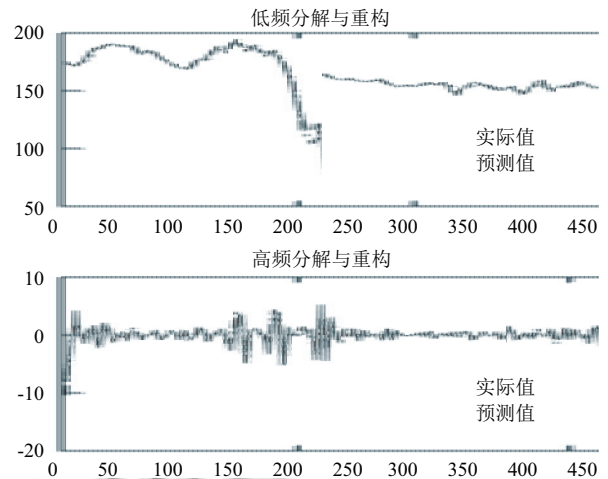


图5 高频与低频分量预测结果




图6 原始血压序列的预测结果

平均相对误差:

$$RME = \frac{1}{n} \sum_{t=1}^n \left| \frac{X(t) - \hat{X}(t)}{X(t)} \right|$$

均方根误差:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n |X(t) - \hat{X}(t)|^2}$$

本文选取传统 BP 神经网络方法对原始血压序列进行预测, 将预测结果与本文提出的组合预测模型进行对比分析, 对比结果见表 1. 通过误差分析可以看出来, 本文方法预测的均方根误差与 BP 神经网络预测法相比下降了 66.3%, 平均相对误差下降了 69%. 两项评价指标均优于 BP 神经网络预测方法.

实验结果表明, 本文的预测算法精度明显高于传统的 BP 神经网络预测精度, 用本文算法来预测人体血压变化有较高的精度和可靠性.

表1 误差对比

使用方法	均方根误差RMSE	平均相对误差RME(%)
BP神经网络方法	9.6881	5.39
本文方法	3.2673	1.67

4 结语

本文针对人体血压受到较多因素的综合影响, 血压时间序列具有较强的随机性和复杂性提出一种小波分析与BP神经网络组合预测方法, 小波分解与重构实质上是通过不同的滤波器将含有综合信息的一组原始信号分解成两组特征不同的时间序列信号, 其中低频信号反映了该血压时间序列内在的变化趋势, 而高频分量反映的是随机扰动带来的影响, 两者的规律不同, 对特征不同的信号可以选取不同的参数进行预测, 这样分别预测的结果再合成效果比做一次预测好. 本文应用 Daubechies 小波基中的 db4 小波对原始血压信号进行单尺度变换, 并提取分解与重构后的低频分量与高频分量, 运用 BP 神经网络分别对低频与高频分量进行预测, 并对预测的结果进行叠加得到原始血压预测值. 实验结果表明, 本方法取得较好的预测效果, 相对于 BP 神经网络进一步提高预测精度, 有较高的可靠性, 为人体血压预测提供一种可行性较高的新思路.

参考文献

- 赖丽娟, 王志刚, 吴效明. 基于小波变换和支持向量机的急性低血压预测方法研究. 透析与人工器官, 2011, 22(1): 28-33.
- 盛小菊. 影响血压变化的常见因素. 中国社区医师, 2014, (32): 168, 171.
- 贺国光, 马寿峰, 李宇. 基于小波分解与重构的时间序列预测法. 自动化学报, 2002, 28(6): 1012-1014.
- 窦慧丽, 刘好德, 吴志周, 等. 基于小波分析和 ARIMA 模型的交通流预测方法. 同济大学学报(自然科学版), 2009, 37(4): 486-489, 494.
- 王曦, 毕贵红, 唐京瑞. 基于 EMD 的太阳黑子时间序列组合预测模型. 计算机工程, 2011, 37(24): 176-179.
- 祖哲, 毕贵红, 刘力, 等. 基于小波神经网络的电力系统短期负荷预测模型研究. 计算机技术与发展, 2012, 22(10): 237-241.
- Daubechies I. 小波十讲. 李建平, 杨万年, 译. 北京: 国防工业出版社, 2004.
- 陈少吉. 基于神经网络血压预测研究与系统实现[硕士学位论文]. 广州: 华南理工大学, 2015.
- 董长虹. Matlab 神经网络与应用. 北京: 国防工业出版社, 2005.
- 郑剑, 白响恩, 肖英杰, 等. 组合小波分析与神经网络的船舶缆绳载荷预测. 计算机科学, 2013, 40(7): 254-257.
- PhysioNet. <http://www.physionet.org>.
- 陈丽琳. 基于多嵌入维数的时用水量 LSSVM 组合预测. 机电工程, 2012, 29(7): 869-872.