

基于小波分析和神经网络的卫星钟差预报性能分析*

郭承军[†] 滕云龙

(电子科技大学电子科学技术研究院 成都 611731)

摘要 为了有效地进行卫星钟差预报和更好地反映卫星钟差特性,提出了一种基于小波分析和神经网络的 4 阶段混合模型来实现卫星钟差的预报,并给出了基于小波分析和径向基函数 (Radial Basis Function, RBF) 神经网络进行卫星钟差预报的基本思想、预报模型和实施步骤.采用“滑动窗”划分数据,利用神经网络预测小波分解和去噪后的钟差序列各层系数,更精确地把握钟差序列复杂细致的变化规律,从而更好地逼近钟差序列.

为验证该混合预报模型的可行性和有效性,利用 GPS 卫星钟差数据进行钟差预报精度分析,并将其与灰色系统模型和神经网络模型进行比较分析.仿真结果显示,该模型具有较好的预报精度,可为实时 GPS 动态精密单点定位提供较高精度的卫星钟差.

关键词 天体力学; 人造卫星, 时间, 方法; 数据分析

中图分类号: P 128; **文献标识码:** A

1 引言

由于卫星的空间位置是随时间变化的,所以在卫星导航定位中,精确的位置测量是以精确的时间测量为基础的.如果没有高精度的时频,卫星导航定位系统就不可能实现高精度的导航与定位^[1].因此卫星钟差的预报是一项非常重要的工作,它对实时的高精度导航定位具有重要意义,是实现实时动态高精度单点定位的关键之一^[2-3].

常用的钟差预报算法有二阶多项式模型^[4]和灰色系统模型^[5],但是,这两种模型的应用都有一定的局限性^[6].而且星载原子钟频率高且非常敏感,极易受到外界及其自身因素的影响,很难掌握其复杂细致的变化规律.文献^[7]指出,一个变化异常复杂的非线性、非平稳随机序列很难使用单一的模型进行有效的预测.

鉴于此,本文针对钟差序列的特性,提出了基于小波分析与神经网络的卫星钟差序列混合预报模型.文末,采用实测数据进行验证和预报精度分析,取得了较高的预报精度,可为卫星钟差序列预报提供借鉴和参考.

2009-11-16 收到原稿, 2009-12-02 收到修改稿

* 航空科学基金 (20090580013) 资助

[†] gcjcdn-007@163.com

2 钟差预报模型设计

基于小波分析和神经网络的钟差序列预报模型分为 4 个阶段：第 1 阶段对钟差序列应用小波分析分解到不同的时频层上；第 2 阶段对每一层的系数应用小波去噪去除孤立点和跳跃点；第 3 阶段使用神经网络对各层系数进行预测；第 4 阶段对各层系数的预测序列进行小波重构，产生钟差预报序列。该混合模型钟差预报的具体流程如图 1 所示。

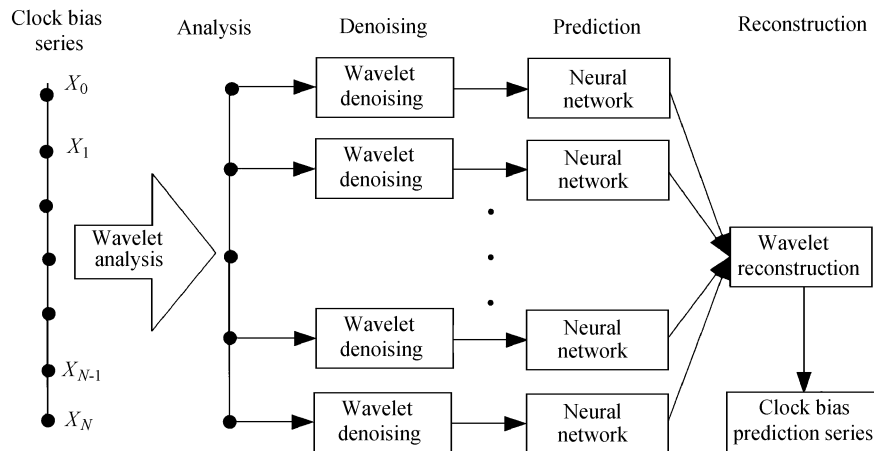


图 1 钟差预报流程图

Fig. 1 Flow chart of clock bias prediction

基于小波分析和神经网络的混合模型中，小波分解后的钟差序列低频和高频系数分别代表钟差序列的趋势项和细节项。通过对去噪后的各层系数分别建模，神经网络可以通过学习更精确地掌握钟差序列复杂细致的变化规律，从而更好地逼近钟差序列，取得更高的钟差预报精度。

3 基于小波的数据处理

小波变换是一种时间和频率的局域变换，能有效地从时间序列中提取信息，通过伸缩和平移等运算功能对序列进行多尺度细化分析。因此，通过小波变换能够揭示时序数据之间的联系，从而更好地处理时序数据^[8]。

3.1 小波分解

小波变换的基本思想是多分辨率分析，其实质就是将信号在一系列不同层次的空间上进行分解，这种信号分解的能力能将各种交织在一起的不同频率组成的混合信号分解成不同频率的子信号。

小波分解就是将一个时频信号表示为一系列不同频率、不同延迟的简单标准信号的迭加。其数学含义可以表述为: 在子空间的标准正交基不断变更的条件下, 信号按正交基展开产生的正交函数项级数的过程。即通过不断分解过程, 将信号分解成许多低分辨率成分。因此, 小波变换提供了在不同分辨率下信号的信息和度量与每个子小波的相似程度, 这表示如果小波与信号中的特征成分相似, 相应的小波变换能够提取信号的特征。

此外, 小波变换对不同频率在时域上的取样步长是调节性的, 即对低频部分的时间分辨率较差, 而频率分辨率较高; 对高频部分时间分辨率较高, 而频率分辨率较低。这符合信号低频变化缓慢而高频变化迅速的特点, 因而小波变换对信号具有自适应性。

3.2 小波阈值去噪

小波阈值收缩法去噪的主要理论依据是小波变换 (特别是正交小波变换) 具有很强的去相关性, 能使信号的能量集中在小波域内一些大的小波系数中, 而噪声的能量却分布于整个小波域内。因此, 经小波分解后, 信号的小波系数幅值要大于噪声的系数幅值。幅值比较大的小波系数一般以信号为主, 而幅值比较小的系数在很大程度上是噪声^[9]。采用阈值的办法可以保留信号系数, 而使大部分噪声系数减少至零。

小波阈值去噪的基本思路为: (1) 先对含噪信号 $f(k)$ 作小波变换, 得到一组小波系数 $w_{j,k}$ (j 为分辨层数, k 为序列数据长度); (2) 通过对小波系数 $w_{j,k}$ 进行阈值处理, 得到估计系数 $\hat{w}_{j,k}$, 使得 $\|\hat{w}_{j,k} - w_{j,k}\|$ 尽可能地小; (3) 利用 $\hat{w}_{j,k}$ 进行小波重构, 得到估计信号 $\hat{f}(k)$, 即为去噪之后的信号。

通常的去噪方法是寻找一个合适的 λ 作为阈值, 把低于 λ 的小波系数 $w_{j,k}$ (主要由噪声引起) 设为零, 对于高于 λ 的 $w_{j,k}$ (主要由信号引起), 则予以保留或收缩, 从而得到小波系数 $\hat{w}_{j,k}$, 它可以理解为基本上是由信号引起的, 然后对 $\hat{w}_{j,k}$ 进行重构, 就可以得到重构以后的信号。

3.3 小波重构

小波重构过程是使用小波系数 $\hat{w}_{j,k}$ 来进行的, 即把一系列不同频率的信息重新还原成原信号的过程, 尺度因子变得越来越小。其数学含义是: 在子空间的标准正交基不断变更的条件下, 信号按正交基展开的正交函数级数不断组合的过程。重构过程是分解过程的逆过程, 只对最大尺度的低频部分和各层高频部分进行组合。此外, 重构信号的优劣与小波去噪时的阈值估计方法有关。

4 基于神经网络的预测

神经网络具有通过学习逼近任意非线性映射的能力, 突破了建立参数模型的传统做法, 在非线性预测方面显示出了明显的优越性, 其原理是通过非线性基函数的线性组合实现从输入空间到输出空间的非线性转换。钟差序列经小波分解之后的各时频层系数是一类非线性较强的时间序列, 对其进行预测, 实质上就是找出从输入空间到输出空间的非线性映射关系。因此, 神经网络特别适合类似于钟差序列各时频层系数的非线性时间序列的预报^[10]。

4.1 RBF 神经网络

RBF 神经网络是以函数逼近理论为基础构造的一类前馈式神经网络. 这类网络具有良好的推广能力、函数逼近能力和模式识别能力, 能够对非线性、随机等复杂时间序列进行建模和预测, 同时训练方法简单易行. 基于 RBF 神经网络的这些特点, 本文将其应用于钟差序列小波分解后各层系数的预测建模.

RBF 神经网络输入层到隐层的变换是非线性的, RBF 的选取、中心以及权值对于网络的学习时间和训练结果有重要影响. 本文采用最常用的高斯函数作为基函数, 则隐层第 i 个结点的输出为

$$R_i(\mathbf{x}) = \exp\left[-\frac{\|\mathbf{x}-\mathbf{c}_i\|^2}{2\sigma_i^2}\right], \quad i = 1, 2, \dots, h, \quad (1)$$

其中, \mathbf{x} 为输入向量; \mathbf{c}_i 是第 i 个基函数的中心向量, 与 \mathbf{x} 同维; σ_i 表示该基函数中心点的宽度; $\|\mathbf{x}-\mathbf{c}_i\|$ 为向量 $\mathbf{x}-\mathbf{c}_i$ 的欧几里得范数, 通常指距离; h 表示隐层神经元的个数^[11].

构造和训练一个 RBF 神经网络就是要使映射函数通过学习, 确定出每个隐层神经元基函数的中心、宽度以及隐层到输出层的权值这些参数的过程, 从而可以完成所需的输入到输出的映射. 隐层的中心和宽度代表了样本空间模式以及各中心的相对位置, 完成的是从输入空间到隐层空间的非线性映射, 而输出层的权值是实现从隐层空间到输出空间的线性映射. RBF 神经网络的核心是隐层的设计, 中心的选取合适与否将从根本上影响 RBF 网络的最终性能.

已有多学习算法用于确定网络的中心与权值, 如基于梯度下降的误差纠正方法、最近邻聚类学习算法、正交最小二乘法 (OLS) 等. 其中, Chen 等^[12]提出的 OLS 算法, 能保证网络规模小、运算速度快, 是较为有效的算法. 因此, 本文采用 OLS 算法来确定网络的中心和权值.

4.2 基于神经网络的钟差各层系数预测

对钟差序列小波分解后的各层系数进行预测的目的是通过该序列的前 N 个时刻的值预测出后 M 个值. 这里采用序列的 N 个时刻的数据为滑动窗, 并将其映射为 M 个值. 这 M 个值代表该窗之后的 M 个时刻的预测值.

表 1 列出了数据的滑动窗划分方法. 把数据分为 K 个长度为 $N+M$ 的有一定重叠的数据段, 每个数据段可看做一个样本, 从而得到 $K=L-(N+M)+1$ 个样本, 这里 L 指原始数据长度. 将每个样本的前 N 个值作为 RBF 神经网络的输入, 后 M 个值作为目标输出. 通过学习, 实现从输入空间 R^N 到输出空间 R^M 的映射, 从而达到预测的目的.

表 1 数据划分方式

Table 1 The mode of data compartmentalization

Input	Output
x_1, \dots, x_N	x_{N+1}, \dots, x_{N+M}
x_2, \dots, x_{N+1}	$x_{N+2}, \dots, x_{N+M+1}$
...	...
x_K, \dots, x_{N+K-1}	$x_{N+K}, \dots, x_{N+M+K-1}$

5 小波选取及相关参数设定

5.1 小波的选取

钟差预报混合模型中基于神经网络的预测是以钟差序列的小波分解后的各时频层小波系数为基础的, 而小波的选取又在一定程度上影响小波系数的分布, 因此小波选取的合适与否会直接影响到预测精度^[13]. 由于对钟差序列的数据处理主要是小波分解、去噪和重构, 因此选择的小波应具有离散小波变换的特性, 并具有正交性和对称性. 同时, 需要根据数据处理的目的是来决定尺度的大小, 尺度较大的小波主要反映信号整体的近似特性, 而尺度较小的小波主要反映信号的细节变化. 此外, 较小尺度的小波变换能够减小频率混叠, 判断突变点位置准确度较高^[14]. 综合考虑以上各方面的影响, 选取 Daubechies 小波中的 Db6 小波进行钟差序列数据处理.

5.2 小波阈值和滑动窗参数设定

阈值估计方法一般有两种: 硬阈值法和软阈值法. 前者由于小波系数估计值不连续, 所以得到的重构信号可能会产生一些振荡; 而对于后者而言, 小波系数估计值虽然整体连续性好, 但当小波系数绝对值大于阈值时, 其估计值与真实值总存在恒定的偏差, 直接影响着重构信号与真实信号的逼近程度. 因此, 本文采用软硬阈值折中法来估计阈值, 在阈值模型中加入了权重因子 α , 在区间 $[0, 1]$ 内适当调整 α 的大小, 以获得更好的去噪效果和重构信号.

采用滑动窗划分数据的目的是在提高数据利用率的同时可以实时更新数据, 以提高预测精度. 如果用于构造滑动窗的数据过少, 容易因不能精确把握序列的内在规律而引起预测精度下降; 如果用于构造滑动窗的数据过多, 则会造成因数据量过大而带来的计算复杂化. 为了同时满足预测精度和计算复杂度的要求, 并达到构造滑动窗提高数据利用率并实时更新数据的目的, 采用 $N = 6, M = 1$ 来构造滑动窗.

6 试验结果及分析

为了分析本文模型实时预报卫星钟差的精度及其相关特性, 选取如图 2 所示的 PRN02、PRN03、PRN07 和 PRN08 4 颗钟差变化比较典型的卫星, 采用实测数据进行钟差预报

精度分析.

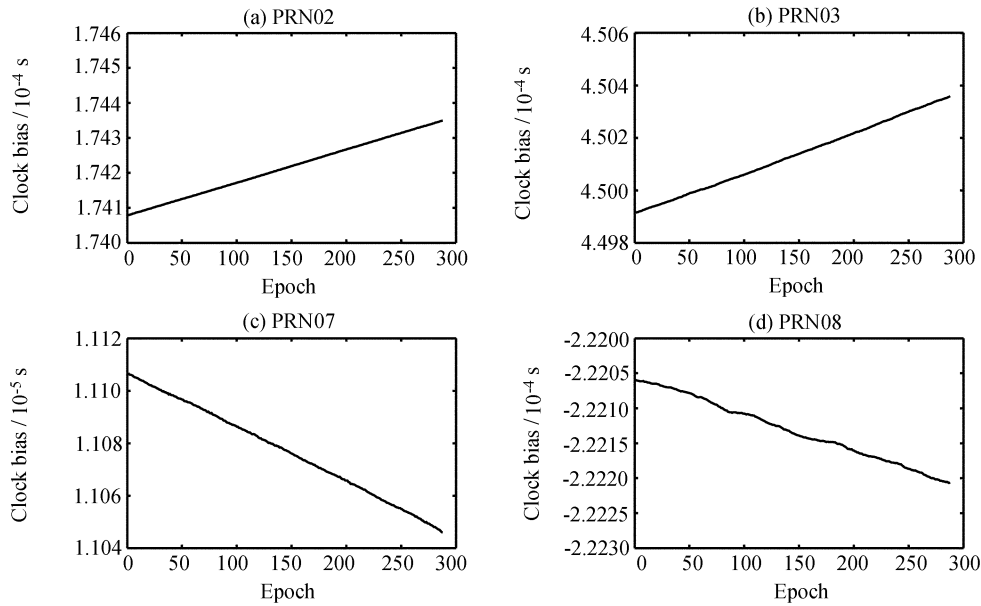


图 2 卫星钟差数据

Fig. 2 Data of satellite clock biases

由于神经网络具有大型的并行处理能力、很强的自适应学习能力和故障容错能力,因此它也是一种很好的动态系统建模方法. 为了验证本文所提出的混合模型的钟差预报性能,研究了神经网络的建模机理和建模特性,并将两者加以比较. 其中, 6.1 节对只用神经网络构造的单一预报模型与传统灰色系统模型采用实测精密星历数据进行预报精度对比分析; 6.2 节将神经网络模型与本文提出的混合模型进行预报精度对比分析. 通过对神经网络模型、传统灰色系统模型与本文模型预报精度的对比分析,验证本文提出的混合预报模型在卫星钟差预报时的可行性和有效性.

6.1 神经网络模型与传统灰色系统模型预报精度对比分析

卫星钟差是时间的函数,利用二次多项式模型进行卫星钟差预报时,误差积累会随着预报时间的延长而增大,并且多项式模型容易受多项式拟合的阶数和数据的个数等人为因素的影响,因而传统灰色系统模型钟差预报效果好于二阶多项式模型^[15]. 分别用传统灰色系统模型和神经网络模型对 4 颗卫星进行钟差预报,其预报误差如图 3 所示,图中实线表示神经网络模型钟差预报误差,虚线表示传统灰色系统模型钟差预报误差, CBP 表示钟差预报 (Clock Bias Prediction).

由图 3 可以看出,神经网络模型预测精度和稳定性远好于传统灰色系统模型. 造成这方面差距的主要原因是卫星钟差序列类型不唯一,不同类型的钟差序列对灰色系统模型指数系数的敏感度不同,因此利用灰色系统模型进行钟差预报时,不同的灰色系统模型指数系数对预报精度有着非常大的影响,传统的灰色系统模型指数系数通常固定为一

个常量, 容易导致很大的误差, 甚至是错误.

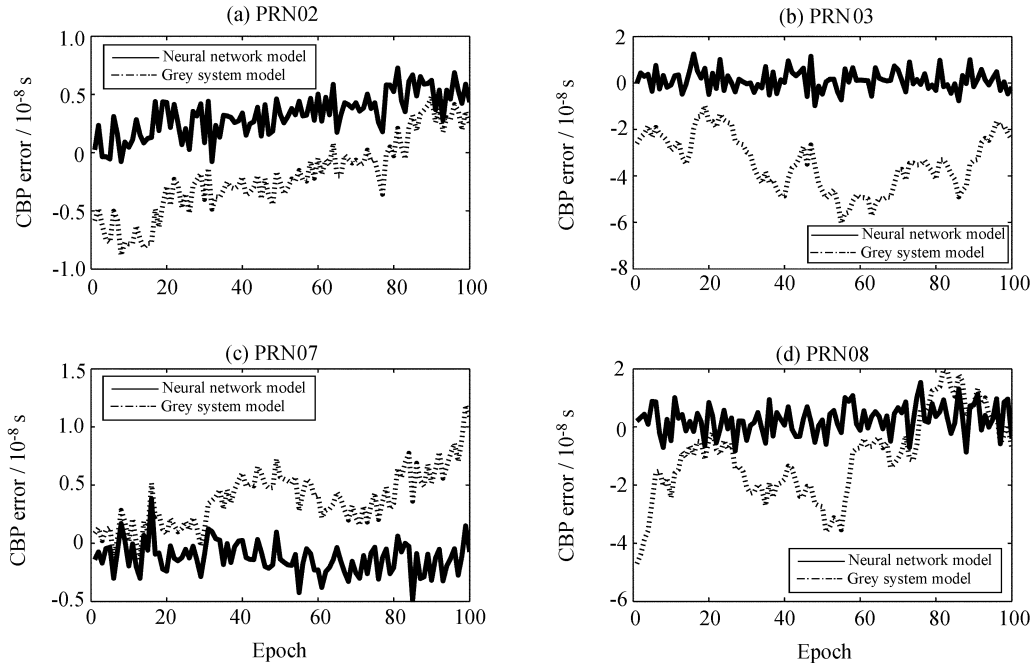


图 3 神经网络与灰色系统模型预测误差

Fig. 3 Prediction errors of neural network model and grey system model

6.2 本文模型与神经网络模型预报精度对比分析

由于神经网络模型的预报精度和稳定性都好于传统灰色系统模型, 下文只对神经网络模型和本文模型进行预报精度对比分析. 分别利用两种模型对 4 颗卫星进行钟差预报, 预报误差如图 4 所示, 图中实线表示本文模型钟差预报误差, 虚线表示神经网络模型预报误差.

由图 4 可以看出, 本文提出的小波神经网络混合模型对卫星钟差的预报有比神经网络模型更高的精度和稳定性. 原因在于对于卫星钟差序列预报而言, 神经网络模型也有一定的局限性: 神经网络建模只能由给定的输入和输出模式来描述系统的动态特性, 其结构学习的效率不是很好, 而且训练非常有限且易于陷入局部极小点, 如果只能收集到较少的学习模式或样本, 它的建模输出就不是很理想. 此外, 当一个新的训练模式增加到原始的训练之中, 或者训练集的个数发生变化时, 网络的连接权值就必须重新学习训练, 结构就必须重建, 导致网络结构的训练是一个非常消耗时间的过程. 因此, 神经网络模型对存在突变的钟差数据解决能力偏弱, 虽然允许数据中存在突变, 但并不能预计出这种突变, 只是能以一定的速度在后续预报中反映出突变的影响. 而小波神经网络模型中引入小波变换的一个重要目的就是为了对序列中极限值和突变值的点进行处理, 去除它们对钟差预报性能的影响, 并提取出序列的趋势项, 尤其对长期测量的数据处理和模型建立具有重要意义. 因此, 应用小波变换可以提高神经网络模型的建模特性, 并较好

地避免神经网络模型对存在突变的钟差数据解决能力偏弱对预报精度产生的影响。

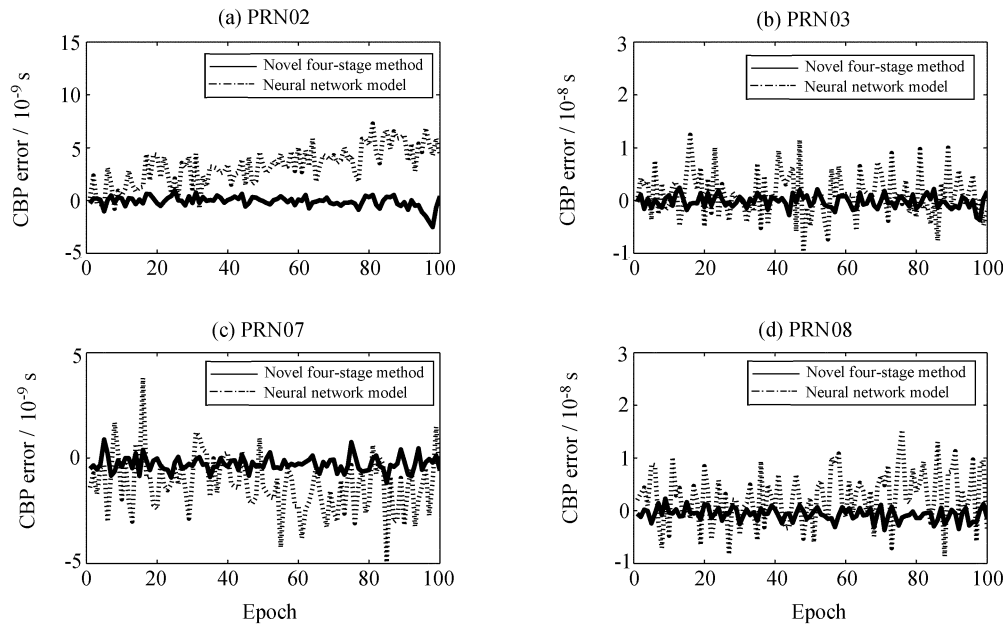


图 4 本文模型与神经网络模型预测误差

Fig. 4 Prediction errors of the model proposed in this paper and neural network model

7 结论

在探讨神经网络模型和传统灰色系统模型在卫星钟差预报时的局限性的基础上，利用小波分析对卫星钟差数据进行预处理，提出了应用小波神经网络混合模型实时预报卫星钟差的方法。利用不同卫星的钟差数据进行分析研究，得到一些对实时精密单点定位的卫星钟差预报具有一定的参考价值和借鉴意义的结论：

(1) 用小波分析进行数据处理时，采用软硬阈值折中法进行阈值估计，在阈值模型中加入权重因子 α ，可以获得更好的去噪效果和重构信号。

(2) 用神经网络进行预测时，采用“滑动窗”划分数据，不但可以有效提高数据利用率，并且可以完成数据的实时更新，提高钟差预报精度。

(3) 钟差序列经小波分解后的低频和高频系数分别代表序列的趋势和细节，分层预测各层系数，可以通过学习逼近钟差序列，更好地提高钟差预报精度。

(4) 由于灰色系统模型钟差预报时，不同模型指数系数对预报精度有较大影响，而神经网络模型虽然用于各种类型的钟差数据，但对存在突变的钟差数据解决能力偏弱。小波神经网络混合模型通过神经网络预测小波处理后的钟差序列各层系数，通过各层系数的预测序列重构预测序列，可以较好地避免这两方面的局限性对钟差预报精度的影响，取得较高的预报精度。

参 考 文 献

- [1] 郑作亚, 党亚民, 卢秀山, 等. 天文学报, 2010, 51: 95
- [2] 郑作亚, 陈永奇, 卢秀山. 天文学报, 2008, 49: 306
- [3] Zheng Z Y, Chen Y Q, Lu X S. ChA&A, 2009, 33: 72
- [4] Li X H, Wu H T, Bian Y J, et al. ScChG, 2009, 52: 353
- [5] 崔先强, 焦文海. 武汉大学学报 (信息科学版), 2005, 30: 447
- [6] 路晓峰, 杨志强, 贾小林, 等. 武汉大学学报 (信息科学版), 2008, 33: 492
- [7] Huang N E, Wu M L, Qu W D, et al. Applied Stochastic Models in Business and Industry, 2003, 19: 245
- [8] Gao X P, Cao C H. ScChF, 2008, 51: 1547
- [9] 徐建, 张琨, 游静, 等. 系统仿真学报, 2006, 18: 2626
- [10] Karunasinghe D S K, Liong S Y. JHyd, 2006, 323: 92
- [11] Niu J J, Fu Y L, Qi X Y. ChJA, 2009, 22: 279
- [12] Chen S, Cowan C F N, Grant P M. ITNN, 1991, 2: 302
- [13] Liu B, Peng J X. ScChF, 2008, 51: 2022
- [14] 郭秋英, 胡振琪. 煤炭学报, 2007, 32: 1179
- [15] 朱陵凤, 唐波, 李超. 飞行器测控学报. 2007, 26: 39

Performance Analysis of Satellite Clock Bias Based on Wavelet Analysis and Neural Network

GUO Cheng-jun TENG Yun-long

(*Research Institute of Electronic Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731*)

ABSTRACT In the field of the real-time GPS precise point positioning (PPP), the real-time and reliable prediction of satellite clock bias (SCB) is one key to realize the real-time GPS PPP with high accuracy. The satellite borne GPS atomic clock has high frequency, is very sensitive and extremely easy to be influenced by the outside world and its own factors. So it is very difficult to master its complicated and detailed law of change. With the above characters, a novel four-stage method for SCB prediction based on wavelet analysis and neural network is proposed. The basic ideas, prediction models and steps of clock bias prediction based on wavelet analysis and radial basis function (RBF) network are discussed, respectively. This model adopts “sliding window” to compartmentalize data and utilizes neural network to prognosticate coefficients of clock bias sequence at each layer after wavelet analysis and wiping off noise. As a result, the intricate and meticulous diversification rule of clock bias sequence is obtained more accurately and the clock bias sequence is better approached. Compared with the grey system model and neural network model, a careful precision analysis of SCB prediction is made to verify the feasibility and validity of this proposed method by using the performance parameters of GPS satellite clocks. The simulation results show that the prediction precision of this novel model is much better. This model can afford the SCB prediction with relatively high precision for real-time GPS PPP.

Key words celestial mechanics: artificial satellites, time, methods: data analysis