

利用遗传小波神经网络预报导航卫星钟差

王宇谱¹ 吕志平¹ 崔 阳¹ 吕 浩¹ 李林阳¹

1 信息工程大学地理空间信息学院,河南 郑州,450001

摘 要:针对卫星钟差难以用精确模型来进行预报问题,首先通过遗传算法优化适合非线性时间序列预报的小波神经网络的网络参数,得到预报性能更好的遗传小波神经网络(GWNN);然后根据钟差数据的特点对钟差进行预处理,建立了一种能够高精度、近实时预报钟差的 GWNN 钟差预报算法。使用 GPS 卫星钟差进行一天内的预报实验证明了本方法的有效性。结果表明,通过本方法得到的预报钟差较 IGS 超快预报钟差在精度上有了较大的改善。

关键词:卫星钟差;遗传算法;小波神经网络;预报
中图分类号:P228 **文献标志码:**A

在卫星导航定位系统的实时应用中,卫星钟差(SCB)是指地面运控系统测得的星载原子钟钟面值与卫星导航系统的系统时之间的偏差;其作为影响定位结果的一项主要误差源是必须要进行改正的。以 GPS 系统为例,IGS 最终(IGS-F)钟差的精度已经相当高了,但实时性不理想;而满足实时性的广播星历钟差和超快预报(IGU-P)钟差其精度却不好(IGS 产品的精度、时延等信息参考文献[1])。因此,探索一种能够在单个测站上实时高精度预报导航卫星钟差的方法,改善传统星钟预报体系或者至少提高 IGU-P 钟差产品的质量是非常必要的[2]。

目前,已建立了多种预报模型[2-8],主要有二次多项式(QP)模型、灰色模型(GM(1,1))、Kalman 滤波模型、谱分析模型、时间序列模型以及这些模型的改进模型等;将这些模型中任一种简称为单一模型;其中,QP 模型和 GM(1,1)模型是较常用的两种模型。但在钟差预报的实际应用中,使用任何一种单一模型都是不完善的[8]。

IGS 的超快预报钟差是根据前一天的实测 SCB 预报得到的,它是全球多个 IGS 数据处理中心预报钟差综合加权的结果[9]。但星载原子钟由于在空间环境中受多种不确定因素的影响以及原子钟本身复杂特性的原因,导致目前的预报模型难以准确地预报 SCB,这也是 IGS 超快预报钟差精度不高的主要原因。本文针对钟差难以用具体

表达式描述的特点,利用小波神经网络(WNN)较强的逼近能力和自学习特点,结合遗传算法(GA)较好的全局搜索能力,建立了一种基于 GA 优化 WNN 网络参数的遗传小波神经网络(GWNN)钟差预报算法。

1 钟差预报模型的构建

人工神经网络(ANN)是一种模仿大脑和神经系统的并行信息处理系统[10],使用神经网络模型来解决钟差预报的问题是比较合适的。在神经网络模型中,小波神经网络(WNN)通常被用于复杂时间序列的预报,并且取得了较好的预报效果[11]。

1.1 小波神经网络

假设有 L 组数据,每组数据由 N 个分量组成,将其表示为 $T=(t(1), \dots, t(j), \dots, t(L))$, $t(j) \in \mathbb{R}^N$;模型输出为一个 P 维向量,记为 $O=(o(1), \dots, o(j), \dots, o(L))$, $o(j) \in \mathbb{R}^P$;则输入量经过 WNN 模型传播得到输出为[12]:

$$O_n(k) = \sum_{i=1}^M \omega_{ij} h \left(\frac{\sum_{i=1}^N \omega_{ii} t_n(i) - b_i}{a_i} \right),$$
$$k = 1, 2, \dots, P; n = 1, 2, \dots, L \quad (1)$$

式中, $h(\cdot)$ 为隐含层的小波基函数,本文预报钟差选用 Morlet 小波基函数,其表达式为 $h(t) =$

收稿日期:2013-05-14

项目来源:国家自然科学基金资助项目(41274015);国家 863 计划资助项目(2013AA122501)。

第一作者:王宇谱,博士生,主要从事测量数据处理方法与理论研究。E-mail:987834660@qq.com

$\exp(-t^2/2) \times \cos(1.75t)$; M 为网络隐含层神经元的个数; w_{hi} 为连接输入层节点 i 和隐含层节点 t 的权值, w_{tj} 为连接隐含层节点 t 和输出层节点 j 的权值; a_t, b_t 为隐含层节点 t 的伸缩、平移因子。

构造适合钟差预报的神经网络时发现, WNN 虽然具有较好的预报性能, 但由于网络的权值参数及伸缩、平移因子随机选取的初始值不同, 同时网络在收敛过程中会受局部极值的影响, 导致网络训练结束后每次钟差预报的结果有差异, 使得钟差预报结果不稳定; 在实际中通常是取多次预报结果的平均值作为该模型的最终预报结果, 而这样的预报产品在具体应用中是不理想的。

1.2 遗传小波神经网络模型的建立

GA 按照一定的适应度函数, 借助复制、交换、变异等遗传操作, 通过多点随机并行搜索的方法能够有效地防止参数收敛到局部最优解^[13]。GA 优化 WNN 模型的参数是在 WNN 模型给定的前提下进行的, 因此, 从 WNN 模型的构造和 GA 优化 WNN 模型的过程来叙述适合钟差预报的 GWNN 模型。

1) WNN 模型的构造

一个 3 层结构采用反向传播的前馈型神经网络可以任意精度来近似任何非线性连续函数^[14]; 同时, 一个可靠、稳健的神经网络的获取主要取决于恰当的数据预处理、合理的网络结构选取及使用适当的网络训练方法^[15]。

① 钟差数据的预处理。为了获取高精度的时间信息, SCB 数据的有效位数比较多, 但较多的数据位数会影响神经网络的学习训练性能。同时, 从预报的实时性、精度和周期考虑, 本文钟差预报建模数据使用具有大约 17 h 延迟的 IGS 快速(IGR)钟差产品; 该产品的精度和最终产品的精度基本相当, 更新周期为一天, 是比较理想的神经网络建模数据。同时, 钟差数据在获取过程中难免会存在误差, 尤其对于 IGR 钟差产品, 其存在系统误差的可能性较大, 而误差的存在会影响神经网络的预报性能。基于这些原因, 本文首先对相邻历元钟差作差得钟差的一次差序列, 然后基于一次差数据进行建模预报接下来的一次差数据, 最后再将一次差数据还原得到所要预报时刻的钟差。由于钟差相邻历元的变化比较小, 通过一次差可以一定程度上消除原钟差序列趋势项的影响, 得到一组更利于 GWNN 模型建模的数据序列; 同时一次差可消除钟差数据中的部分系统误差, 降低误差对网络预报性能的影响。

② 网络各层所含单元数的确定。在确定神经网络每层所含神经元个数时, 输出层神经元个数通常等于所需输出的不同类型变量的个数。由于网络仅输出钟差一种变量, 因此输出层单元数为一个; 在钟差的输出过程中, 根据其所对应时刻的变化, 网络输出不同时刻对应的预报钟差。确定输入层神经元个数时, 应和输出层类似; 但为了避免逐个训练时引起网络权值和阈值在修正过程中发生震荡, 同时又要使网络结构不至太过复杂进而保证模型的时效性, 本文取输入层神经元个数为 4 个。对于网络隐含层单元个数的确定目前还没有十分明确的理论依据可以遵循, 一般应用中可参考 Kolmogorov 定理来确定, 即满足隐含层单元数 = 输入层单元数 $\times 2 + 1$ 。所以最终确定的 WNN 模型结构为 4-9-1。

③ 网络训练算法的选取。用最速下降法对网络进行训练, 即网络各参数调整公式:

$$\begin{aligned} w_{hi}^{(k+1)} &= w_{hi}^{(k)} - \eta \frac{\partial E}{\partial w_{hi}^{(k)}} + \alpha \Delta w_{hi}^{(k)} \\ w_{tj}^{(k+1)} &= w_{tj}^{(k)} - \eta \frac{\partial E}{\partial w_{tj}^{(k)}} + \alpha \Delta w_{tj}^{(k)} \\ a_t^{(k+1)} &= a_t^{(k)} - \eta \frac{\partial E}{\partial a_t^{(k)}} + \alpha \Delta a_t^{(k)} \\ b_t^{(k+1)} &= b_t^{(k)} - \eta \frac{\partial E}{\partial b_t^{(k)}} + \alpha \Delta b_t^{(k)} \end{aligned} \quad (2)$$

式中, $E = \frac{1}{2} \sum_{k=1}^P \sum_{n=1}^L (O_n^T(k) - O_n(k))^2$ 为网络训练的误差函数, $O_n^T(k)$ 、 $O_n(k)$ 为网络的期望输出和实际输出; η 为学习速率; α 为动量因子。

2) 基于 GA 优化 WNN 模型的过程。采用 GA 对 WNN 模型的权参数和平移、伸缩因子的优化训练分为初次训练和再次训练。

初次训练是在给定的 WNN 模型下, 通过 GA 获取网络中各参数相对较好的初始值, 具体步骤包括: ① 编码。使用 GA 优化参数前, 需对 w_{hi} 、 w_{tj} 和 a_t 、 b_t 进行编码, 并将这些参数记为初始种群 Q 。因优化的参数较多同时为了避免影响网络的学习精度, 本文使用浮点数法进行编码; 同时初始化网络参数, 给出种群 Q 的规模、遗传最大迭代次数和交叉概率 P_c 、变异概率 P_m 。② 计算适应度。本文 WNN 模型中的待优化参数, 其适应度值可用网络的误差函数 E 来衡量。GA 优化的目标函数就是求 E 的全局最小值, 因此, 本文适应度函数取为 $f = 1/E$ 。③ 遗传操作。采用“轮盘赌法”进行种群的选择操作, 将得到的适应度较大的个体直接复制到下一代; 同时分别对需要进行交叉、变异的个体以概率 P_c 、 P_m 来完成交

叉、变异操作,这两种操作均采用“浮点法”;最后,产生出新的下一代个体。④ 计算新种群的适应度,若达到指定条件,则结束,否则转到步骤③。⑤ 将最终群体里面的最优个体解码,所得结果作为优化的网络连接权值和伸缩、平移因子。

再次训练是在初次训练的基础上用 WNN 模型的最速下降法进行第二次优化训练。两次优化后所得参数作为 GWNN 模型的最终网络参数对钟差进行预报。至此,适合钟差预报的 GWNN 模型完全确定。

2 实验与分析

采用 GPS 系统 1 570 周第一天 15 min 采样间隔的 IGR 钟差作为建模数据,预报接下来一天不同时间段的钟差;以预报时刻所对应的 IGS 最终钟差产品作为参考值,分析由新算法得到的预报产品的精度,并将其与 IGU-P 钟差产品进行对

比。这两天的钟差数据中,由于 1、3、6、21、25、26 号卫星的数据不完整,故使用其他 26 颗卫星的钟差数据进行试验;而这 26 颗卫星中,除了 8、9、10、24、27、30 号卫星使用 Cs 原子钟外,剩余卫星均使用的是 Rb 原子钟。分别采用均方根误差(RMS)、最大最小误差之差的变化值(Range)来评价预报结果的精度和算法的稳定性。其中均方根误差计算公式为:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (\Delta t_i)^2}, \Delta t_i = t_i - \hat{t} \quad (3)$$

式中, t_i 是 IGS 最终精密钟差; \hat{t} 为预报钟差。

2.1 试算 1

首先对比 WNN 模型和 GWNN 模型的预报性能。随机选取两颗使用不同类型原子钟的卫星进行预报,这里取使用 Cs 钟的 PRN10 卫星和使用 Rb 钟的 PRN02 卫星的钟差数据,预报接下来一天前 6 h 的钟差,预报 10 次,对比两种模型预报结果的 RMS 变化情况,如图 1 所示。

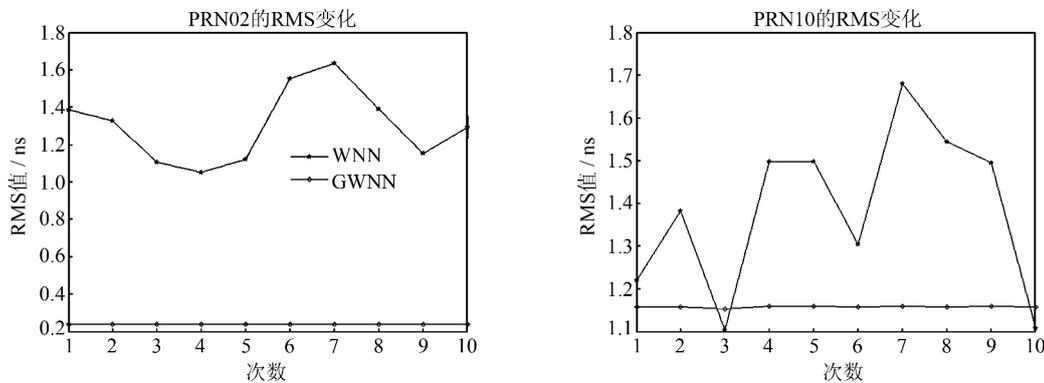


图 1 WNN 和 GWNN 预报 10 次 RMS 的变化

Fig. 1 Variation of RMS by Respectively Using WNN and GWNN to Predict SCB About 10 Times

依图可知,相同条件下不论是对 Rb 钟还是 Cs 钟的预报,GWNN 模型的预报稳定性和平均预报精度均优于 WNN 模型,GWNN 模型可以作为一种相对较稳定的预报算法用于导航卫星钟差的预报。同时说明了通过 GA 能有效改善在钟差预报过程中 WNN 模型的网络初始参数选取和网络收敛到局部极值对预报结果的影响。

2.2 试算 2

本文为了全面分析 GWNN 模型的预报性

能,并将使用该模型得到的预报结果与 IGU-P 结果进行比较,对 26 颗卫星的 SCB 分别进行 3 h、12 h 和 1 d 的预报实验。考虑文章的篇幅,这里仅给出使用 Rb 钟的 PRN02、PRN29 卫星和使用 Cs 钟的 PRN09、PRN10 卫星在进行 1 d 的预报时,GWNN 模型与两种常用预报模型以及和 IGU-P 钟差的详细对比情况(表 1 和图 2);其余卫星的只给出新方法的预报结果与 IGU-P 钟差的统计对比情况(表 2 和图 3)。

表 1 4 颗卫星 1 d 预报结果统计值/ns

Tab. 1 Statistics of Prediction Results of the Four Satellites' SCB in One Day/ns

Method	PRN02		PRN09		PRN10		PRN29	
	RMS	Range	RMS	Range	RMS	Range	RMS	Range
IGU-P	7.748	1.135	10.396	13.660	13.515	10.791	6.111	4.732
QP	2.273	3.296	11.556	23.966	3.034	10.181	0.796	1.924
GM(1,1)	3.218	0.906	5.098	16.275	6.503	8.995	4.997	4.658
GWNN	0.781	1.973	3.746	14.861	2.624	10.656	0.677	2.213

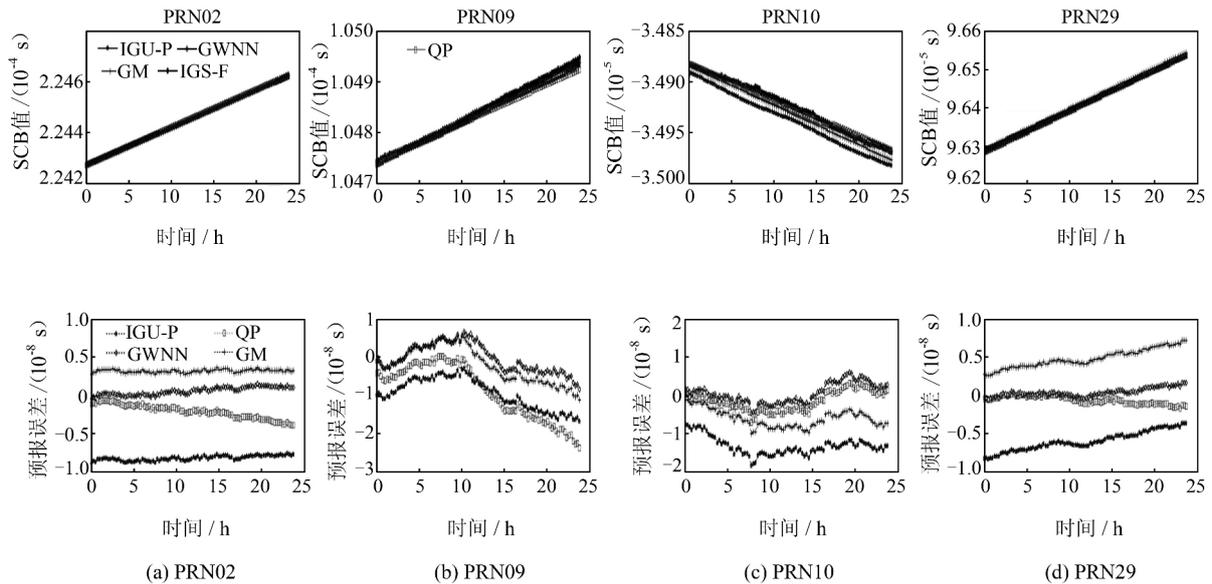


图2 4颗卫星1d钟差预报结果对比图

Fig. 2 Comparing Prediction Results of the Four Satellites' SCB in One Day

由图2和表1可知, GPS系统星载Rb原子钟的预报精度和稳定性要好于其星载Cs原子钟。同时, 对比4颗卫星1d的预报结果, 精度方面, 对于星载Rb来说, GWNN模型的预报结果比IGU-P产品高出约10倍, 而对于星载Cs钟, GWNN模型也明显好于IGU-P产品, 同时本文所建模型的预报精度高于两种常用模型; 而预报结果的稳定性方面, 本文所提方法的预报结果与IGU-P产品基本相当, 而两种常用模型预报结果的稳定性则随着卫星的不同而变换, 稳定性相对较差。同时, 需要说明的是, 由于对QP模型、GM(1,1)和GWNN模型所使用的建模数据均为IGR产品, 而IGU-P产品是基于IGS超快速钟差产品中观测部分来建模的, 所以两种常用预报模型的预报结果的精度也基本上优于IGU-P钟差, 这说明在实际应用中可以通过使用IGR钟差产品对常用钟差预报模型进行建模来获取较IGU-P钟差产品更好的预报结果。

表2 预报精度的对比/ns

Tab. 2 Comparing the Prediction Precision/ns

RMS/ ns	3 h		12 h		24 h	
	GWNN	IGU-P	GWNN	IGU-P	GWNN	IGU-P
Cs	3.451	10.665	5.144	13.065	6.317	14.579
Ru	0.817	8.542	1.014	8.449	1.192	8.268
All	2.134	9.604	3.079	10.757	3.755	11.424

图3给出了26颗卫星不同预报时间段GWNN模型预报结果与IGU-P钟差的统计对比情况。表3给出了按原子钟类型进行分类的预报

精度对比情况, 其中Rb钟和Cs钟的RMS分别是其所对应卫星RMS之和的均值。

从各颗卫星不同预报时间段预报RMS和Range图可以看出, 本文所建GWNN模型的预报精度明显高于IGU-P钟差产品的精度, 而两者预报的稳定性则基本一致。图中明显表现出较差预报精度的均是使用Cs钟的卫星; 这些卫星是GPS系统早期发射的, 由于长时间的运行其相关设备逐渐老化, 同时还因Cs原子钟自身的一些时频和物理特性等因素, 导致这些卫星的SCB可预报性相对较差。同时需要说明一点的是, 由于本文所建神经网络模型相对比较简单, 在实验过程中使用1d的钟差数据建模预报24h的钟差, 整个过程的耗时不超过2min, 这使得本文模型能够保持相对较好的实时性。

3 结语

为了提高导航卫星预报钟差的精度和实时性, 提出了一种基于遗传算法优化小波神经网络的遗传小波神经网络钟差预报算法。通过多组具体的预报实验证明了该方法能够以较高的精度和相对稳定的预报性能来获取钟差预报数据; 且预报得到的钟差其精度比IGS提供的满足实时应用需求的超快预报产品的精度有了较大的改善; 同时所建模型简单且能够较好地保证实时性; 这些特点使得该方法为导航卫星钟差预报提供了一种新的参考方法。

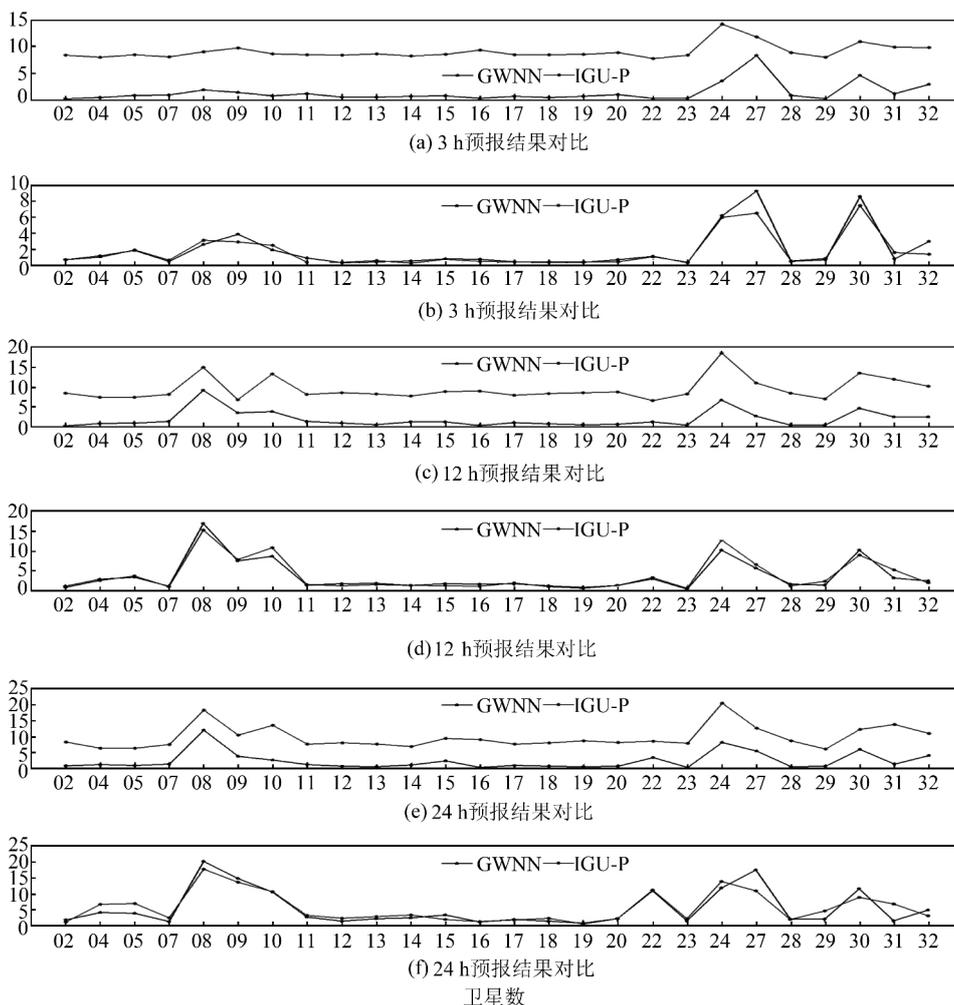


图 3 预报结果的对比

Fig. 3 Comparison of Prediction Results

参 考 文 献

[1] IGS. IGSCB [OL]. <http://igsceb.jpl.nasa.gov/components/prods.html>, 2013

[2] Heo Y J, Cho J, Heo M B. Improving Prediction Accuracy of GPS Satellite Clocks with Periodic Variation Behaviour [J]. *Measurement Science and Technology*, 2010, 21(7): 3 001-3 008

[3] Cui Xianqing, Jiao Wenhai. Grey System Model for the Satellite Clock Error Predicting[J]. *Geomatics and Information Science of Wuhan University*, 2005,30(5):447-450(崔先强,焦文海.灰色系统模型在卫星钟差预报中的应用[J].武汉大学学报·信息科学版,2005,30(5):447-450)

[4] Guo Hairong, Yang Sheng, Yang Yuanxi, et al. Numerical Prediction Methods for Clock Difference Based on Two-Way Satellite Time and Frequency Transfer Data[J]. *Geomatics and Information Science of Wuhan University*, 2007, 32(1): 43-46(郭海荣,杨生,杨元喜,等.基于卫星双向时间频率传递进行钟差预报的方法研究[J].武汉大学学报·信息科学版,2007,32(1):43-46)

[5] Lu Xiaofeng, Yang Zhiqiang, Jia Xiaolin, et al. Parameter Optimization Method of Gray System Theory for the Satellite Clock Error Predicating[J]. *Geomatics and Information Science of Wuhan University*, 2008, 33(5): 492-495(路晓峰,杨志强,贾晓林,等.灰色系统理论的优化方法及其在卫星钟差预报中的应用[J].武汉大学学报·信息科学版,2008,33(5):492-495)

[6] Zheng Zuoya, Dang Yamin, Lu Xiushan, et al. Prediction Model with Periodic Item and Its Application to the Prediction of GPS Satellite Clock Bias [J]. *Acta Astronomica Sinica*, 2010, 51(1):95-102(郑作亚,党亚民,卢秀山,等.附有周期项的预报模型及其在GPS卫星钟差预报中的应用研究[J].天文学报,2010,51(1):95-102)

[7] Huang Guanwen, Yang Yuanxi, Zhang Qin. Estimate and Predict Satellite Clock Error Using Adaptively Robust Sequential Adjustment with Classified Adaptive Factors Based on Opening Windows[J].

- Acta Geodaetica et Cartographica Sinica*, 2011, 40(1):15-21(黄观文, 杨元喜, 张勤. 开窗分类因子抗差自适应序贯平差用于卫星钟差参数估计与预报[J]. *测绘学报*, 2011, 40(1): 15-21)
- [8] Wang Jigang, Hu Yonghui, He Zaimin, et al. Prediction of Clock Errors of Atomic Clocks Based on Modified Linear Combination Model[J]. *Chinese Astronomy and Astrophysics*, 2011, 35: 318-326
- [9] Senior K L, Ray J R, Beard R L. Characterization of Periodic Variations in the GPS Satellite Clocks[J]. *GPS Solutions*, 2008, 12(3): 211-225
- [10] Moya A, Irikura K. Inversion of a Velocity Model Using Artificial Neural Networks[J]. *Computers & Geosciences*, 2010, 36:1 474-1 483
- [11] Wang Yupu, Lv Zhiping. Research on Algorithm of Wavelet Neural Network for Forecasting Length of Day[J]. *Journal of Geodesy and Geodynamics*, 2012, 32(1): 127-131(王宇谱, 吕志平. 小波神经网络日长预报算法研究[J]. *大地测量与地球动力学*, 2012, 32(1): 127-131)
- [12] Tabaraki R, Khayamian T, Ensafi A A. Solubility Prediction of 21 Azo Dyes in Supercritical Carbon Dioxide Using Wavelet Neural Network[J]. *Dyes and Pigments*, 2007, 73(2):230-238
- [13] Kerh T, Gunaratnam D, Chan Y. Neural Computing with Genetic Algorithm in Evaluating Potentially Hazardous Metropolitan Areas Result from Earthquake[J]. *Neural Computing & Applications*, 2010, 19(4):521-529
- [14] Hornik K, Stinchcombe M, White H. Multilayer Feedforward Networks Are Universal Approximators[J]. *Neural Network*, 1989, 2(5):359-366
- [15] García-Pedrajas N, Hervás-Martínez C, Muñoz-Pérez J. COVNET: A Cooperative Coevolutionary Model for Evolving Artificial Neural Networks[J]. *Neural Networks, IEEE Transactions on*, 2003, 14(3): 575-596

Predicting Navigation Satellite Clock Bias Using a Genetic Wavelet Neural Network

WANG Yupu¹ LV Zhiping¹ CUI Yang¹ LV Hao¹ LI Linyang¹

¹ Institute of Surveying and Mapping, Information Engineering University, Zhengzhou 450001, China

Abstract: Aiming to solve satellite clock bias (SCB) that is difficult to formulate for prediction, this paper employs a genetic algorithm to optimize the network parameters of a wavelet neural network suitable for prediction nonlinear time series. First, a genetic wavelet neural network (GWNN) with better prediction performance was obtained. Secondly, the SCB values were preprocessed based on their characteristics and a GWNN model was established to accurately predict SCB in near real time. Finally, the paper carries out SCB prediction tests within one day using the SCB data from GPS satellites to validate the proposed model. The results show that the proposed prediction model outperforms IGS ultra-rapid predicted SCB products.

Key words: satellite clock bias; genetic algorithm; wavelet neural network; prediction

First author: WANG Yupu, PhD candidate, specializes in the theory and method of survey data processing. E-mail: 987834660@qq.com

Foundation support: The National Natural Science Foundation of China, No. 41274015; the National 863 Program of China, No. 2013AA122501.