

WANG Yupu, LÜ Zhiping, CHEN Zhengsheng, et al. Research on the Algorithm of Wavelet Neural Network to Predict Satellite Clock Bias[J]. Acta Geodaetica et Cartographica Sinica, 2013, 42(3): 323-330. (王宇谱, 吕志平, 陈正生, 等. 卫星钟差预报的小波神经网络算法研究[J]. 测绘学报, 2013, 42(3): 323-330.)

卫星钟差预报的小波神经网络算法研究

王宇谱, 吕志平, 陈正生, 崔 阳

信息工程大学 地理空间信息学院, 河南 郑州 450052

Research on the Algorithm of Wavelet Neural Network to Predict Satellite Clock Bias

WANG Yupu, LÜ Zhiping, CHEN Zhengsheng, CUI Yang

Institute of Surveying and Mapping, Information Engineering University, Zhengzhou 450052, China

Abstract: Satellite clock bias (SCB) prediction plays an important role in satellite navigation system, such as optimizing clock parameters in navigation message, meeting the needs of real-time dynamic precise point positioning and providing the required information for satellite autonomous navigation. It is proposed that a wavelet neural network (WNN) model based on a once difference method to predict clock bias considering the characteristic of SCB in this paper. The main ideas are as follows: two SCB values of adjacent epoch firstly make once difference to obtain the corresponding once difference sequences, then modeling based on the sequences to predict once difference values of the following time series. At last, the predicted sequences are recovered to the corresponding predicted SCB. This method makes that the WNN model of SCB prediction is simple in structure and the predicting precision is higher. Finally through predicting examples, the new model is compared with two frequently-used models, for example, quadratic polynomial (QP) model and GM(1,1) model. The results show that the once difference method can evidently improve the prediction precision of SCB for the given WNN, and the results also turn out that the new model possesses better performance than the common models in SCB prediction.

Key words: satellite clock bias (SCB); prediction; once difference; wavelet neural network

摘 要: 卫星导航系统中星载原子钟的钟差预报在优化导航电文中的钟差参数、满足实时动态精密单点定位的需求和提供卫星自主导航所需的先验信息方面具有重要的作用。根据星载原子钟钟差的特点,提出一种基于一次差方法的小波神经网络钟差预报算法:首先对钟差相邻历元间作一次差后的差值进行建模,根据时间序列预报一次差的值,然后再将预报的一次差还原,得到钟差预报值。该方法使得预报钟差的小波神经网络不但模型结构简单,而且预报精度高。最后,通过算例将本文所建模型与常用的二次多项式模型和灰色模型进行对比,结果表明:一次差方法可以使给定结构的小波神经网络的钟差预报精度得到显著提高,而且所建模型的预报效果优于两种常规模型。

关键词: 卫星钟差; 预报; 一次差; 小波神经网络

中图分类号: P228

文献标识码: A

文章编号: 1001-1595(2013)03-0323-08

基金项目: 国家自然科学基金(41274015); 国家 863 计划(2013AA122501)

1 引 言

卫星钟差(satellite clock bias, SCB)的预报在卫星导航定位系统中具有重要的作用:导航卫星任意时刻的钟差是通过导航电文发布的钟差参数外推得到的,研究钟差预报有利于提高参数预报的可靠性和准确性、优化卫星钟差改正数据上传时间间隔^[1];在实时动态精密单点定位中需要采用钟差预报结果参与计算来实现高精度定位^[2];卫星自主导航需要地面预报一段时间的钟差作为其先验信息^[3]。因此,提高导航卫星钟差

的预报精度非常重要。

目前已有的研究表明,星载原子钟频率总的波动是白噪声调相、白噪声调频和闪变噪声调相、闪变噪声调频以及随机游走调频 5 种噪声线性叠加的结果^[4],这使得建立精准的星载原子钟运行模型变得比较困难,从而也使高精度的钟差预报变得相当困难。因此,针对卫星钟差预报,有关学者进行了大量的研究,建立了多种预报模型^[5-9],其中,二次多项式(QP)模型和灰色系统(GM(1,1))模型是常用的预报模型。QP 模型具有物理意义明确、短期预报比较理想和计算简单等优

点^[10],但同时存在着预报误差会随着预报时间的增加而不断变大的不足^[11-12];GM(1,1)模型具有建模所需数据样本少、适合长期钟差预报等优点,在钟差预报方面的应用已经开始得到同行的认可^[13],但实际预报中该模型预报效果有时会出现很大误差甚至完全失去预报作用,而且在钟差短期预报中该模型的预报精度不理想^[14]。

因此,本文结合钟差数据的特点,利用小波神经网络(WNN)在非线性的时间序列预报方面的优良特性,首先对钟差相邻历元间作一次差后的差值进行建模,根据时间序列求出一次差的预报值,然后再将预报的一次差还原成预报钟差,给出了结构简单、适合较高精度钟差预报的WNN算法。

2 钟差的一次差预报原理和常用钟差预报模型

2.1 钟差一次差预报原理

通常得到的原子钟钟差相邻历元的数值变化不大,钟差序列相邻历元间作一次差,可以得到一组有效数字位数减少的数据序列。设 $L = \{l(i), i=1, 2, \dots, n\}$ 为不同历元时刻的一组钟差值,对该序列中相邻两个历元钟差 $l(i), l(i-1), (i=2, 3, \dots, n)$ 作差得到一组新的数据序列 $\Delta L = \{\Delta l(i), i=2, \dots, n\}$ 。

通常建立钟差预报模型是根据已知的钟差序列 L 利用最小二乘原理求出模型参数进而得到预报模型,然后利用所建模型预报 n 历元以后的 $m (m \geq 1)$ 个历元钟差序列 $L_1 = \{l(j), j=n+1, n+2, \dots, n+m\}$;而本文的不同之处是利用一次差后的数据序列 ΔL 进行建模型预报 n 个历元以后的一次差序列 $\Delta L_1 = \{\Delta l(j), j=n+1, n+2, \dots, n+m\}$,最后通过将一次差预报序列和钟差值 $l(n)$ 对应相加便可得到所求历元的钟差,即

$$l(k) = l(n) + \sum_{n+1}^k \Delta l(k) \quad n+1 \leq k \leq n+m \quad (1)$$

2.2 QP 模型

钟差预报的QP模型观测方程为

$$L_i = a_0 + a_1(t_i - t_0) + a_2(t_i - t_0)^2 + \Delta \quad (i=1, 2, \dots, n) \quad (2)$$

式中, L_i 是 t_i 时刻 GPS 卫星钟的钟差; t_0 为星历表参考时刻; t_i 表示历元时刻;待估参数 a_0, a_1 和 a_2 分别表示参考时刻 t_0 的卫星钟差、钟速及卫星钟的频漂。当 $n > 3$ 时,依最小二乘法则可求解得到

$\hat{a} = [\hat{a}_0 \quad \hat{a}_1 \quad \hat{a}_2]^T$,代入式(2)即可预报钟差。

2.3 GM(1,1)模型

设 $L^{(0)} = \{l^{(0)}(i), i=1, 2, \dots, n\}$ 为不同历元的钟差值,则钟差的灰色模型表达式为^[14]

$$l^{(0)}(k) = (1 - e^a) \left[l^{(0)}(1) - \frac{u}{a} \right] e^{-a(k-1)} \quad k > 1 \quad (3)$$

记参数为 $\hat{a} = [\hat{a} \quad \hat{u}]^T$,根据最小二乘法则可得

$$\hat{a} = (A^T A)^{-1} A^T L \quad (4)$$

式中

$$A = \begin{bmatrix} -\frac{1}{2}[l^{(1)}(1) + l^{(1)}(2)] & 1 \\ -\frac{1}{2}[l^{(1)}(2) + l^{(1)}(3)] & 1 \\ \vdots & \vdots \\ -\frac{1}{2}[l^{(1)}(n-1) + l^{(1)}(n)] & 1 \end{bmatrix}, L = \begin{bmatrix} l^{(0)}(2) \\ l^{(0)}(3) \\ \vdots \\ l^{(0)}(n) \end{bmatrix}$$

$l^{(1)}$ 表示初始钟差序列的一次累加。解得参数代入式(3)便可进行钟差的预报。

3 钟差预报的WNN模型

已有的研究成果表明,人工神经网络通过对样本的学习可以相当准确地估计任何非线性的时间序列^[15]。这对于像钟差这种难以得到严密数学表达式的预报问题是非常合适的,特别是希望得到一种简明的预报形式。同时,在大量的科学研究中发现BP神经网络是众多人工神经网络模型中最实用的一种网络模型^[16]。但是,BP神经网络却存在着易受局部极值影响而致预报精度不高和网络收敛比较缓慢的不足,文献[17]通过小波基函数对BP神经网络进行优化建立了预报性能更加好的WNN模型。因此本文根据钟差的特点,构造适合钟差预报的WNN模型。

3.1 WNN模型的工作原理

WNN与传统的BP神经网络最大的不同是WNN采用小波基函数 $f_i(x) (i=1, 2, \dots, k)$ 代替了BP神经网络隐含层的激活函数。这种结合使得WNN模型既保持了BP神经网络的优点,同时又利用小波变换具有能够通过放大信号来提取局部信息的优点,对BP神经网络的权值及阈值进行优化,克服了BP网络易受局部极值影响而致预报结果精度较低的不足^[17]。图1是一个由输入层(input layer)、隐含层(hidden layer)、输出层(output layer)组成的具有3层结构的WNN

模型。




图 1 WNN 的结构图

Fig. 1 Framework of WNN

对给定的 WNN(输入层、隐含层及输出层的神经元个数分别为 m, n, N), 设输入、输出向量为 $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_m]^T, \mathbf{Y} = [y_1 \ y_2 \ \dots \ y_N]^T$, 则其模型输出可以表示为^[18]

$$y_i = h \left[\sum_{j=0}^n \omega_{i,j} f_{a,b}(net_j) \right] \quad i = 1, 2, \dots, N \quad (5)$$

式中, $net_j = \sum_{k=0}^m \omega_{j,k} x_k, f_{a,b}(net_j) = f\left(\frac{net_j - b_j}{a_j}\right)$; x_k, y_i 分别为向量 \mathbf{X} 的第 k 个输入和输出层的第 i 个输出, a_j, b_j 分别为第 j 个隐含层结点的小波基伸缩因子及平移因子; $\omega_{j,k}, \omega_{i,j}$ 分别为 I 层结点 k 和 H 层结点 j 以及 H 层结点 j 和 O 层结点 i 的连接权值; $h(x)$ 为 Sigmoid 函数。

当样本给定后, 网络学习过程的关键是要确定一组合适的权值和小波基, 使得如下目标函数值最小

$$E(\mathbf{P}) = \frac{1}{2} \sum_{i=1}^N \|\mathbf{Y}_i - \mathbf{t}_i\| \quad (6)$$

式中, $\mathbf{P} = (\mathbf{w} \ \mathbf{c})^T$; \mathbf{w}, \mathbf{c} 分别为网络中所有权值和小波基组成的向量, \mathbf{t}_i 为网络的期望输出。对于这种非线性函数平方和最小问题, Levenberg-Marquardt(LM)算法^[19-20]作为解决此类问题的参考解法能够通过迭代的方法得到最小解。

3.2 钟差预报的 WNN 模型构造

利用 WNN 解决具体问题时, 最关键的是针对具体对象的特点确定合适的网络结构(网络层数和每层的单元数)^[21]。相关研究表明, 两层(只有一个 H 层)结构的神经网络可以实现任意非线性映射^[12]。但是对于网络每层神经元数量的确定目前还没有明确的理论依据可以遵循^[20], 通常 O 层神经元的个数等于需要输出的不同类型变量的个数^[22], 而网络 H 层神经元个数的确定则是

整个 WNN 模型的重难点。

确定本文所建 WNN 模型 H 层单元个数时, 首先需要考虑单元数多少的优缺点。当 H 层的神经元个数较多时, 网络的映射表现能力比较强, 但此时的网络计算比较复杂、网络收敛速度变慢, 同时容易造成网络训练过度, 导致模型容错性和泛化能力下降; 当 H 层单元数较少时, 网络的结构比较简单、学习训练时间短, 但容易导致网络的表现能力不足, 使得预报结果的精度不高。因此具体应用时, 一般要求在不影响网络性能的前提下, 尽可能减少神经元的个数。最后, 在得出 H 层神经元具体数量时还需要结合具体的试验^[20]。

在通过试验分析 H 层单元数的变化对模型预报结果的影响之前, 有必要先对网络中的其他相关构成进行说明, 主要包括小波基函数的选取和模型预报过程中所采用的学习训练算法。构造 WNN 模型时选择什么类型的小波函数, 需要根据不同情况进行合理选取。考虑到卫星钟差是一组非线性性的时间序列, 所以本文的小波基函数选用适合非线性时间序列预报的 Morlet 小波函数^[17]。在网络学习训练算法的选择上, 基于梯度下降的最优化的反向传播算法具有理论依据坚实、推导过程严谨、通用性强的优点, 是目前多层前向神经网络的最主要学习算法^[21](本文所构造的 WNN 模型属于前向型神经网络)。因此, 文中的 WNN 模型预报过程中采用的是这种学习训练算法; 同时, 为了避免逐个训练时引起网络权值和阈值在修正时发生震荡, 采用了成批训练样本的方法^[23]。最后是关于 O 层的说明: 由于网络最终的输出只有钟差这一种变量, 因而 O 层神经元个数为 1 个; 同时在钟差的预报过程中, 当已经预报出了一部分钟差值的情况下, 后面的钟差是根据其所对应的历元通过移动窗口的的方法而获得。至此, 除了 H 层单元数外, 所要建立的 WNN 模型已经确定。图 2 给出了 WNN 模型钟差预报学习训练的具体实现步骤。

下面任选一颗导航卫星某段时间的钟差进行预报建模, 分析 H 层神经元个数的不同对 WNN 模型预报结果的影响情况(这里使用 GPS 系统的 PRN 02 卫星, 数据条件同试算结果一)。图 3 给出了 H 层单元数从 2 到 16 变化时钟差预报结果的 RMS 变化情况。从图中试验结果中可以发现, 当 H 层神经元数量达到 5 个以后, 在接下来的一定范围内改变 H 层单元数时预报结果的变化不明显, 特别是预报结果的精度都不理想(参考

下一部分实算中的对比情况)。但是,从理论上分析应该存在一个合适的 H 层单元数可以满足钟差的高精度预报,而这需要进一步构造更加复杂的网络结构和进行更多的试验。为了避免这种情况,本文使用钟差历元间一次差的序列进行预报然后还原预报结果从而取得了较好的预报效果(下一部分做具体分析)。最终,结合试验确定本文的 WNN 模型 H 层神经元个数为 6 个。

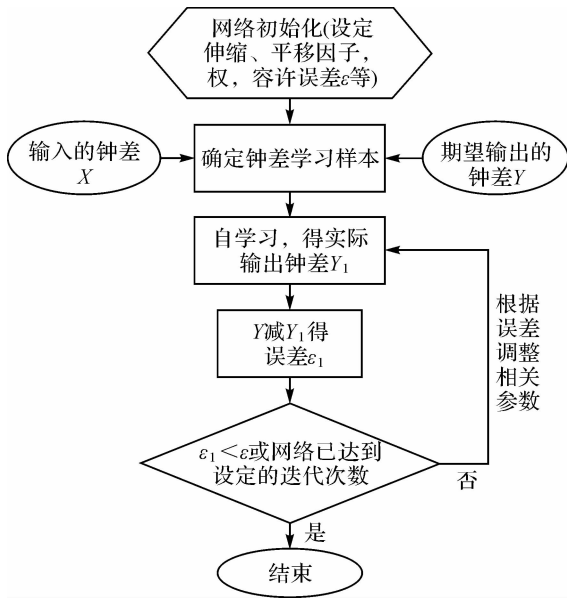


图2 WNN 钟差预报学习训练的原理

Fig. 2 Principle of learning and training by using WNN to predict clock bias

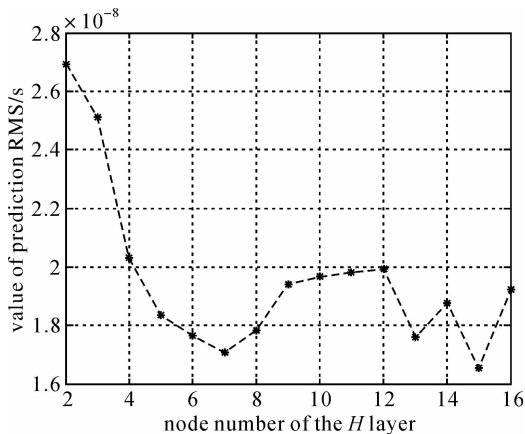


图3 H 层单元数变化时预报结果的 RMS 变化情况
Fig. 3 Variation behavior of prediction results' RMS when nodes of H layer changing



4 试算与分析

为了验证文中给出的一次差方法和所建模型



的有效性,使用 IGS 网站提供的 GPS 系统最终精密星历中 15 min 间隔的精密卫星钟差数据进行试算分析。以 GPS week 1468 第 2 天(2008 年 2 月 25 日)的数据为例(其他天的数据均可),同时考虑此时的星载原子钟包括 Block II A 铯钟、II A 铷钟、II R 铷钟及 II R-M 铷钟 4 类,随机选取每类钟的一颗卫星进行试验。本文选取的是 PRN 02、PRN 09、PRN 25 及 PRN 31 这 4 颗卫星。最后,以 IGS 相应的精密钟差值为基准、使用均方根误差(RMS)和极差(Range,最大误差与最小误差之差的绝对值)作为统计量,比较分析各模型使用两种数据序列时的预报效果。

4.1 试算结果 I

为了对比 WNN 模型和两种常用模型的钟差预报效果,使用该天前 20 历元(5 h)的钟差数据进行建模,预报接下来 8 个历元(2 h)的钟差。图 4 以 PRN 02 卫星钟差预报结果为例(其他 3 颗卫星亦可),给出了该卫星使用一次差方法前后的预报结果和预报误差。



(a) 使用一次差方法前



(b) 使用一次差方法后

图4 PRN02 卫星钟差的预报结果

Fig. 4 Prediction result of PRN02'SCB

从预报结果左边的图可以看到,未使用一次差方法时,两种常用模型的预报精度明显优于 WNN 模型。然而,理论上讲,WNN 模型可以较高精度地预报各种复杂非线性时间序列,但这需要根据不同时间序列的特性确定合适的神经网络结构。如前文所述,本文给出了两层结构的 WNN 模型,在确定 H 层单元个数时,通过很多试验发现改变神经元的个数对于提高预报精度没

有明显的改善,因此,为了避免构造更加复杂的网络结构,这里对原钟差序列相邻历元作一次差,然后使用一次差后的序列进行建模,最后还原得到最终预报结果。从预报结果右边的图可以看出,使用一次差方法后,WNN 模型的预报效果有了明显的提高。为了定量的对比预报效果,表 1 给出了 4 颗卫星在 3 种模型使用一次差方法前后(case one 和 case two)的预报结果统计值。

表 1 预报结果统计表

Tab. 1 Statistics of prediction results

scheme	case one						case two					
	QP		GM(1,1)		WNN		QP		GM(1,1)		WNN	
model	range	RMS	range	RMS	range	RMS	range	RMS	range	RMS	range	RMS
statistics	$(\times 10^{-9})$		$(\times 10^{-9})$		$(\times 10^{-9})$		$(\times 10^{-9})$		$(\times 10^{-9})$		$(\times 10^{-9})$	
PRN 02	0.170	0.094	0.134	2.792	23.330	17.636	0.919	0.740	0.386	0.391	0.196	0.067
PRN 09	9.662	6.031	5.145	3.812	19.991	16.207	11.898	7.280	10.932	6.815	3.844	2.585
PRN 25	0.370	0.554	0.796	6.005	80.428	64.885	1.521	0.576	0.362	0.488	0.614	0.204
PRN 31	1.098	0.844	0.443	1.319	23.383	18.193	1.051	0.645	0.746	0.493	0.627	0.381

从表 1 可以看出,QP 模型使用一次差方法时预报精度和算法稳定性较不使用时有所降低;GM(1,1)模型在该方法下铷钟的预报精度有所提高,稳定性变化不明显;WNN 模型在使用该方法时预报精度和算法稳定性均得到了显著提高。同时发现,本文所建的一次差 WNN 模型在进行较少历元的钟差预报时,预报结果的精度

(RMS)优于两种常预报模型,而模型的稳定性(range)和两种常用模型相当。

4.2 试算结果 2

为了进一步对比预报效果,同样使用该天前 20 历元的数据建模,预报该天接下来 76 个历元(19 h)的钟差。图 5 为 4 颗卫星不使用一次差方法和使用一次差方法后的预报误差。

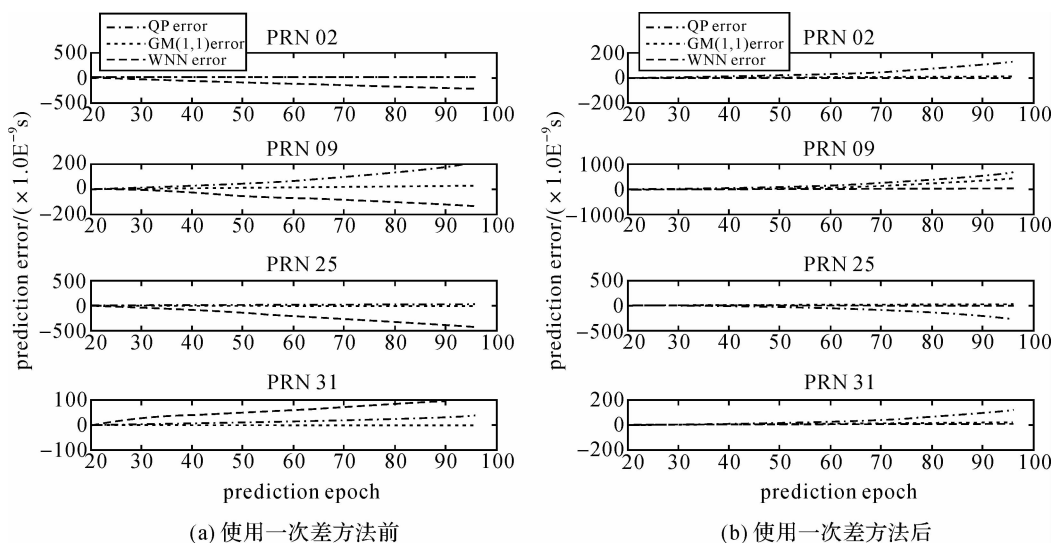


图 5 卫星钟差的预报误差

Fig. 5 Prediction error of SCB

由于本次预报的时间比较长,从 4 颗卫星的预报误差图中可看出,QP 模型在使用一次差方法前后一定程度上均表现出了随着预报时间的增

加预报误差不断变大的现象,且在使用一次差方法时预报误差随着时间的增加而积累的更快。同样,在不使用一次差时两种常用模型的预报精度

优于 WNN 模型,而使用一次差方法后 WNN 模型的预报效果有了显著的提高。表 2 给出了预报结果的统计情况。

表 2 预报结果统计表
Tab.2 Statistics of prediction results

scheme	case one						case two					
	QP		GM(1,1)		WNN		QP		GM(1,1)		WNN	
	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)	range ($\times 10^{-9}$)	RMS ($\times 10^{-9}$)
PRN 02	2.246	0.928	0.999	2.617	220.753	134.641	125.829	52.032	11.913	5.776	1.417	0.462
PRN 09	197.472	97.400	29.524	17.572	135.185	73.780	664.836	284.898	426.020	183.724	19.516	8.884
PRN 25	25.646	12.280	7.331	3.620	430.275	242.114	273.962	109.322	24.941	11.839	2.723	0.982
PRN 31	31.376	14.667	2.954	2.991	97.871	61.248	109.669	44.737	16.600	7.657	3.210	1.582

从表 2 可以发现,随着预报时间的变长 QP 模型使用一次差方法时的预报精度和算法稳定性较不使用时变得更差;GM(1,1)模型在使用一次差方法时同样精度和稳定性变差;而 WNN 模型在使用该方法时预报精度和算法稳定性均有显著提高。

对比表 1 和表 2 可以看出,在建模条件相同而预报的时间长度不同时,QP 模型随预报时间的增加导致其预报精度和稳定性都变差;GM(1,1)模型的预报精度与稳定性不但和需要预报的时间长短有关还跟星钟类型有关,不同的原子钟表

现出了不同的特点;而 WNN 模型随着预报时间长度的增加其预报精度和稳定性一定程度上亦有所下降。

4.3 试算结果 3

根据实算 2 的预报结果知道 WNN 模型随着预报时间长度的增加其预报精度和稳定性均有所降低,为了对其作进一步分析,使用该天的全部数据建模,预报接下来一天(GPS week 1468 第 3 天)前 76 历元(19 h)的钟差。图 6 为 4 颗卫星使用一次差方法前后 3 种模型的预报误差;同时为了便于和图 5 对比,该图中的预报历元起止同图 5。

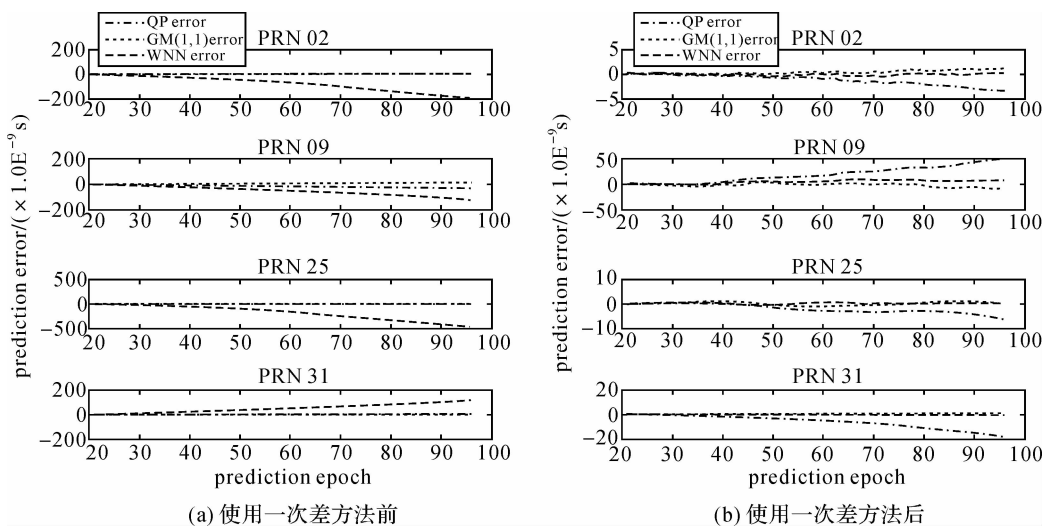


图 6 卫星钟差的预报误差
Fig.6 Prediction error of SCB

从预报误差图中可以看出,不使用一次差时两种常用模型的预报精度优于 WNN 模型,而使用一次差方法后 WNN 模型的预报效果有了显著的提高。表 3 是预报结果的统计情况。

从表 3 可以看出,使用一次差方法可以明显

改善 WNN 模型的稳定性和预报精度,使其预报效果明显优于两种常用模型。同时还可以看出使用较多钟差数据建模时,一次差方法可以一定程度上提高 GM(1,1)模型的预报精度。

表 3 预报结果统计表
Tab.3 Statistics of prediction results

scheme	case one						case two					
	QP		GM(1,1)		WNN		QP		GM(1,1)		WNN	
	range	RMS	range	RMS	range	RMS	range	RMS	range	RMS	range	RMS
statistics	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)	($\times 10^{-9}$)
PRN 02	1.699	0.982	0.937	3.160	188.197	94.637	3.645	1.585	1.137	0.521	0.688	0.218
PRN 09	25.673	14.063	14.928	10.462	117.566	63.063	50.403	24.218	11.568	3.430	11.902	5.824
PRN 25	4.279	2.340	11.169	3.338	466.914	232.977	6.639	2.727	2.192	0.692	1.041	0.307
PRN 31	2.111	1.831	0.822	0.615	109.591	61.316	17.839	7.806	1.380	0.799	1.240	0.292

对比表 2 和表 3 可以发现,钟差建模数据的增多总体上可以改善 QP 模型随着预报时间的变长导致预报误差变大的不足,特别是对使用一次差方法的时候。而建模数据的增多对 GM(1,1) 模型预报效果的影响不明显,但对该模型使用一次差方法时的精度和稳定性有改善,而且使其预报性能优于不使用一次差方法。钟差建模数据的增多对 WNN 模型的预报精度和算法稳定性均有显著提高,因此使用较多的钟差数据建模,WNN 模型可以高精度地实现较长时间的钟差预报。

最后,对各模型使用一次差方法时表现出的特点进行分析说明:由于使用的是 IGS 提供的精密钟差数据,其钟差序列自身误差很小,但是经过数据的一次差处理和预报后的钟差还原,根据误差传播定律可知道,这样会使预报结果所含的误差变大,特别对于 QP 模型来说,这种影响非常明显。而对于 GM(1,1)模型来说,模型本身具有一定的抗干扰能力,同时该模型建模时就要对数据序列进行自加和最后自减,因此该模型在使用一次差方法前后的预报性能难以给出定性的结论。然而对 WNN 模型来说,使用一次差方法时其钟差预报效果比不使用时得到了明显提高,一方面是因为该模型自身就有一定的抗差性,另一方面说明在网络拓扑结构一定的情况下,由原钟差序列有效数位太多引起的 WNN 模型难以较好地拟合钟差模型造成的预报误差远大于由相邻历元作差对建模所造成的预报误差。值得一提的是,如果钟差预报模型建模时,所使用的钟差数据含有一定的系统误差,则本文提出的基于一次差方法的钟差预报模型会得到更好的预报效果。

5 结 论

本文提出了一种使用一次差方法的 WNN 钟差预报模型,通过试算证明了该模型比常用模型更能有效地预报钟差。对预报结果进行分析,得

到以下结论:① 使用神经网络模型进行时间序列预报,数据有效位数的多少对网络的预报性能有影响,因此在使用神经网络前对有效位数多的原数据序列进行适当的处理可以提高神经网络的预报性能。② 通过相邻历元间一次差的建模方法,WNN 模型可以实现卫星钟差的较高精度预报,同时避免了构造复杂的网络结构。

参考文献:

- [1] JUDAH L. A Review of Time and Frequency Transfer Methods[J]. Metrologia, 2008, 45(6):162-174.
- [2] 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.)
- [3] CUI Xianqiang, 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] ALLAN D W. Time and Frequency (Time-Domain) Characterization, Estimation, and Prediction of Precision Clocks and Oscillators [J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 1987, 34(6): 647-654.
- [5] JAMES P C, EVERENTT R S, FRANK M. Improvement of the NIMA Precise Orbit and Clock Estimates[C]// Proceedings of the 11th International Technical Meeting of the Satellite Division of The Institute of Navigation. Nashville:[s. n.], 1998: 1587-1596.
- [6] GREG H, JACK T. Navigation Upload Performance[C]// Proceedings of the 13th International Technical Meeting of the Satellite Division of The Institute of Navigation. Salt Lake City:[s. n.], 2000: 425-431.
- [7] PAUL A K, DEMETRIOS M, MIHRAN M. Alternate Algorithms for Steering to Make GPS Time[C]// Proceedings of the 13th International Technical Meeting of the Satellite

- Division of the Institute of Navigation. Salt Lake City: [s. n.], 2000: 933-936.
- [8] 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.)
- [9] ZHU Xiangwei, XIAO Hua, YONG Shaowei, et al. The Kalman Algorithm Used for Satellite Clock Offset Prediction and Its Performance Analysis [J]. *Journal of Astronautics*, 2008, 29(3): 966-970. (朱祥维, 肖华, 雍少为, 等. 卫星钟差预报的 Kalman 算法及其性能分析[J]. *宇航学报*, 2008, 29(3): 966-970.)
- [10] GUO Hairong. Study on the Analysis Theories and Algorithms of the Time and Frequency Characterization for Atomic Clocks of Navigation Satellite [D]. Zhengzhou: Information and Engineering University, 2006. (郭海荣. 导航卫星原子钟时频特性分析理论与方法研究[D]. 郑州: 信息工程大学, 2006.)
- [11] 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.)
- [12] WANG Jigang. Research on Time Comparison Based on GPS Precise Point Positioning and Atomic Clock Prediction [D]. Beijing: Graduate University of CAS, 2007. (王继刚. 基于 GPS 精密单点定位的时间比对与钟差预报研究[D]. 北京: 中国科学院研究生院, 2010.)
- [13] YUAN Haibo, WANG Zhengming, DONG Shaowu, et al. Dynamic Grey-autoregressive Model of an Atomic Clock [J]. *Metrologia*, 2008, 45(6): S1-S5.
- [14] ZHENG Zuoya, CHEN Yongqi, LU Xiushan. An Improved Grey Model for the Prediction of Real-time GPS Satellite Clock Bias [J]. *Acta Astronomica Sinica*, 2008, 49(3): 306-320. (郑作亚, 陈永奇, 卢秀山. 灰色模型修正及其在实时 GPS 卫星钟差预报中的应用研究[J]. *天文学报*, 2008, 49(3): 306-320.)
- [15] MOHAMMAD A G, RAHMAN K, AYTEK A, et al. Sea Water Level Forecasting Using Genetic Programming and Comparing the Performance with Artificial Neural Networks [J]. *Computers & Geosciences*, 2010, 36(5): 620-627.
- [16] ERFAN M, PEJMAN T, DAVOOD G. Application of Artificial Neural Networks for Prediction of Coercivity of Highly Ordered Cobalt Nanowires Synthesized by Pulse Electrodeposition [J]. *Measurement*, 2012, 45: 1387-1395.
- [17] WANG Yupu, LÜ 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.)
- [18] FU Huixuan, ZHAO Hong. Application Design of Neural Network by MATLAB [M]. Beijing: China Machine Press, 2010: 204-206. (傅荟璇, 赵红. MATLAB 神经网络应用设计[M]. 北京: 机械工业出版社, 2010: 204-206.)
- [19] LEVENBERG K. A Method for the Solution of Certain Non-linear Problems in Least Squares [J]. *Quarterly of Applied Mathematics*, 1944, 2(2): 164-168.
- [20] LI X. Comparing the Kalman Filter with a Monte Carlo-based Artificial Neural Network in the INS/GPS Vector Gravimetric System [J]. *Journal of Geodesy*, 2009, 83(9): 797-804.
- [21] Wang Qijie. Studies on the Prediction of Earth's Variable Rotation by Artificial Neural Networks [D]. Shanghai: Shanghai Astronomical Observatory, Chinese Academy of Sciences, 2007. (王琪洁. 基于神经网络技术的地球自转变化预报[D]. 上海: 中国科学院上海天文台, 2007.)
- [22] ASIMAKOPOULOU G E, KONTARGYRI V T, TSEKOURAS G J, et al. Artificial Neural Network Optimization Methodology for the Estimation of the Critical Flashover Voltage on Insulators [J]. *Science, Measurement & Technology*, 2009, 3(1): 90-104.
- [23] NIE Peng, SHEN Xin, XU Tao, et al. State Recognition of Tool Wear Based on Wavelet Neural Network [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2011, 37(1): 106-109. (聂鹏, 谌鑫, 徐涛, 等. 基于小波神经网络的航空刀具磨损状态识别[J]. *北京航空航天大学学报*, 2011, 37(1): 106-109.)

(责任编辑: 陈品馨)

收稿日期: 2012-10-08

修回日期: 2013-01-20

第一作者简介: 王宇谱(1988—), 男, 硕士生, 主要从事测量数据处理方法与理论研究。

First author: WANG Yupu (1988—), male, postgraduate, majors in studying the theory and method of surveying data processing.

E-mail: 987834660@qq.com