

基于Takagi-Sugeno模糊神经网络模型的 卫星钟差预报方法*

蔡成林^{1,2} 于洪刚^{1,2†} 韦照川^{1,2} 潘军道^{1,2}

(1 桂林电子科技大学信息与通信学院 桂林 541004)

(2 广西精密导航技术与应用重点实验室 桂林 541004)

摘要 卫星钟差预报精度的不断提升是精密导航的关键问题. 为了进一步提高钟差的预报精度和更好地反映钟差的变化特性, 提出一种基于Takagi-Sugeno模糊神经网络(Fuzzy Neural Network, FNN)的钟差预报方法. 该方法首先根据钟差数据的特点对钟差进行预处理, 然后以预处理后的数据建立一种高精度预报钟差的Takagi-Sugeno模糊神经网络算法. 采用IGS (International Global Navigation Satellite System Service)不同采样间隔的精密钟差数据进行了短期预报试验, 并与ARIMA (Auto-Regressive Integrated Moving Average)模型、GM(1, 1)模型及QP (Quadratic Polynomial)模型进行了对比试验, 分析结果表明: 对不同类型原子钟, 该方法用于钟差短期预报是可行的、有效的, 其获得的卫星钟差预报结果明显优于常规方法.

关键词 天体测量学; 时间; 方法: 数据分析; 方法: Takagi-Sugeno

中图分类号: P127; **文献标识码:** A

1 引言

星载原子钟的钟差预报是精密导航中一项非常重要的工作, 研究钟差预报在满足高精度导航与定位的需求、提高时间同步精度、实现接收机自主完好性的高效检测等方面具有非常关键的作用^[1-5]. 因此, 针对钟差预报, 国内外许多学者建立了多种预报模型, 把这些模型概括起来主要有灰色模型(GM(1, 1))、二次多项式(Quadratic Polynomial, QP)模型、自回归积分滑动平均(Auto-Regressive Integrated Moving Average, ARIMA)模型、神经网络模型等. 陆晓峰等^[6]指出: GM(1, 1)具有使用数据量少、建模快的特点, 显著提高了钟差的预报精度, 但是由于其本身存在不足, 有时难以实现钟差的预报作用. 郑作亚等^[7-8]提出了一种附加周期项的QP预报模型, 该模型能够更加真实地反映卫星钟特性, 但在长期预报时, 误差累积效应比较明显. 为了

2016-11-29收到原稿, 2016-12-31收到修改稿

*国家自然科学基金项目(61263028)、桂林电子科技大学研究生教育创新计划资助项目(2016YJCX14)资助

[†]hgyugnss@163.com

弥补以上模型的不足, 席超等^[9-10]利用基于差分处理的ARIMA模型对提取钟差趋势项后的随机项进行建模, 充分考虑了钟差变化的随机性, 在钟差预报中显示出了优良的特性, 但是在拟合模型参数时, 模型的识别与定阶不准会极大地影响钟差的预报精度. 王国成等^[11]指出: 神经网络由于其强大的自学习能力和非线性系统逼近能力被广泛应用于预测控制领域, 但并不适合基于规则的表达并且收敛较慢, 如何选取隐藏层的最优节点数仍然需要进一步研究. 吴艳辉等^[12]创造性地提出了模糊神经网络(Fuzzy Neural Network, FNN)建模方法, 将模糊逻辑引入神经网络, 使用模糊数学来处理 and 表达不精确问题, 同时吸收了神经网络自学习能力强的优点, 避免神经网络的“黑箱”工作模式, 实现了优势互补. 模糊神经网络模型在诸如工业、煤矿和电力等领域得到了较为广泛的应用^[13-15], 而此种方法在钟差预报领域的应用效果还鲜有讨论.

鉴于此, 为了进一步提高钟差预报精度, 充分发挥模糊神经网络在预测控制领域的独特优势, 本文根据钟差序列的变化特点, 提出了一种基于Takagi-Sugeno模糊神经网络模型的卫星钟差预报方法. 该方法首先对数据进行预处理, 即将相邻历元钟差进行一次差分, 并归一化, 然后根据预处理后的数据建立Takagi-Sugeno模糊神经网络模型进而完成预报, 最后将预报所得数据经反归一化和反差分还原即得钟差预报值. 采用IGS (International Global Navigation Satellite System Service)提供的不同采样间隔的精密钟差数据, 将本文所提预报方法与常规方法分别用于钟差的短期预报试验中, 并作对比分析, 证明了新方法的预报效果较常规方法更优.

2 Takagi-Sugeno模糊神经网络模型

采用Takagi-Sugeno型模糊神经网络, 模糊规则形式如下:

R^i : 如果 x_1 是 A_1^i and x_2 是 A_2^i and $\cdots$ and x_n 是 A_n^i , 则 $y_i = p_{i0} + p_{i1}x_1 + \cdots + p_{in}x_n$, 式中, R^i 代表第 i 条规则; $x_1, x_2, \cdots, x_n$ 为输入变量; $A_1^i, A_2^i, \cdots, A_n^i$ 分别为高斯型隶属函数 $\mu_{A1}, \mu_{A2}, \cdots, \mu_{An}$ 所代表的模糊集合; y_i 为相应的输出变量; p_{in} 为第 i 层节点处的连接权.

2.1 模糊神经网络结构

在模糊系统中, Takagi-Sugeno模糊模型的模糊规则后件是输入语言变量的函数, 典型的情况是输入变量的线性组合. 根据多输入单输出模糊系统的模型, 可以设计出如图1所示的Takagi-Sugeno模糊神经网络结构. 该网络由输入层、模糊化层、模糊规则计算层和输出层4部分构成. 前件网络用来匹配模糊规则的前件, 后件网络用来产生模糊规则的后件^[16-17].




图1 Takagi-Sugeno模糊神经网络结构

Fig. 1 Structure of Takagi-Sugeno fuzzy neural network

网络结构的第1层为输入层. 设输入为 n 维向量 $\mathbf{x}=(x_1, x_2, \dots, x_n)^T$, 它的每个节点与输入向量的各分量 x_i 相连接, 起着将输入向量传入下一层的作用. 第2层为模糊化层. 该层的每一个节点代表语言变量值, 如负中(Negative Medium, NM)、正小(Positive Small, PS)等. 它的作用是计算各输入分量属于各语言变量值模糊集合的隶属函数 μ_i^j . 常见的隶属函数主要有三角形函数、梯形函数和铃形函数等. 隶属函数的形状对模糊神经网络的性能有着非常重要的影响. 为了增强模糊神经网络的局部逼近能力, 本文在综合考虑神经网络的灵敏性、钟差一次差分序列的特性后, 选取具有高斯分布的铃形函数作为隶属函数, 对输入量 x_i 的第 j 个模糊化层节点计算的隶属函数如下:

$$\mu_i^j = e^{-\frac{(x_i - c_{ij})^2}{\delta_{ij}^2}},$$

式中 c_{ij} 和 δ_{ij} 分别代表高斯型隶属函数 μ_i^j 的中心值和宽度值.

第3层为模糊规则计算层, 又称模糊推理层. 当节点数为 m 时, 该层的每个节点代表了一条模糊规则, 实现模糊输入的“与”运算, 它的作用是用来匹配模糊规则的前件, 计算出每条规则的适应度. 假设第 j 个节点计算出的适应度为 α_j :

$$\alpha_j = \mu_1^{i_1} \mu_2^{i_2} \cdots \mu_n^{i_n},$$

同时, 这一层各节点之间具有耦合关系, 用于实现适应度值的归一化:

$$\bar{\alpha}_j = \alpha_j / \sum_{i=1}^m \alpha_i.$$

第4层为输出层, 包括两部分: 一是根据每个节点映射的模糊规则计算出每一条规则的后件 y_{ij} , 二是将各规则的后件加权求和, 得到系统的输出 y_i . 加权系数为模糊规则计算层适应度值的归一化结果 $\bar{\alpha}_j$, 则输出 y_i 为:

$$y_i = \sum_{j=1}^m \bar{\alpha}_j p_{ij},$$

可以根据后续的学习算法来修正.

2.2 模糊神经网络学习算法

钟差预报模型的输入模糊分割数通常是固定的, 为了得到精确的输出, 需要学习的参数为模糊化层各节点高斯型隶属函数的中心值 c_{ij} 、宽度值 δ_{ij} 和模糊规则计算层与输出层之间的连接权系数 p_{ij} .

Takagi-Sugeno模糊神经网络的本质也是一种多层前馈网络. 本文仿照BP (Back Propagation)网络误差反传的算法, 将误差信号依次由输出层向输入层反传, 通过梯度下降法来训练参数学习网络.

设用于模糊神经网络离线学习的总样本量为 L , 取误差代价函数为 E , L 个样本总误差代价函数为 J , 则有:

$$E = \frac{1}{2} \sum_{i=1}^m (t_i - y_i)^2,$$

$$J = \frac{1}{L} \sum_{i=1}^L E,$$

式中, t_i 和 y_i 分别为样本的期望输出值和实际输出值.

将 c_{ij} 、 δ_{ij} 和 p_{ij} 随机初始化后, 根据 Delta 原则对参数进行调整, 因此有各参数误差反向传播的优化公式为:

$$p_{ij}(t+1) = p_{ij}(t) - \eta_1 \frac{\partial J}{\partial p_{ij}} + \beta_1 \Delta p_{ij}(t),$$

$$c_{ij}(t+1) = c_{ij}(t) - \eta_2 \frac{\partial J}{\partial c_{ij}} + \beta_2 \Delta c_{ij}(t),$$

$$\delta_{ij}(t+1) = \delta_{ij}(t) - \eta_3 \frac{\partial J}{\partial \delta_{ij}} + \beta_3 \Delta \delta_{ij}(t),$$

式中, η_i 为学习速率, β_i 为动量系数. 在参数优化时, 引入动量系数, 可以减弱学习过程中的振荡趋势, 改善算法的收敛性.

3 模糊神经网络的预报流程

模糊神经网络具有强大的并行信息处理能力, 它可以通过学习来逼近任意的非线性系统, 在非线形预测方面显示出了独特的优势. 针对钟差预报, 模糊神经网络模型预测原理是利用已知的 N 个历元钟差数据建模, 对未来 M 个历元钟差数据进行估计, 实现从输入空间 R_N 到输出空间 R_M 的非线性映射. 目前, 已有多种方法用于模糊神经网络预测, 如单步预测、多步预测和滚动预测, 其中滚动预测方式比较适合应用于实际的钟差预报. 滚动预测又称迭代一步预测, 首先根据输入对输出进行一步预测, 然后将预测值作为输入的一部分, 用于下一步预测, 输入样本长度与输出样本长度在预测过程中始终保持不变, 如此迭代反复, 便可以得到一段时期内钟差的预报值. 表1给出了本文所选的滚动预测数据划分方法. 本文从预测精度和稳定性两方面考虑, 训练样本选为前 m 个历元的钟差数据 ($m=6$), 输出为后一个历元的钟差预报值.

表 1 滚动预测数据划分方式

Table 1 The data compartmentalization mode of rolling prediction

Input	Output
$x_1, x_2, \cdots, x_m$	x'_{m+1}
$x_2, x_3, \cdots, x'_{m+1}$	x'_{m+2}
$\cdots$	$\cdots$
$x_k, x_{k+1}, \cdots, x'_{k+m-1}$	x'_{k+m}

根据前述数据的划分方式, 本文所提方法的具体钟差预报流程如下:

步骤1: 数据预处理. 获取的钟差数据难免会存在误差, 同时原始数据并不适于直接输入模糊神经网络模型进行钟差预报. 有鉴于此, 本文先对相邻历元钟差数据进行一次

差分, 然后将差分序列按表1划分为不同的样本集. 为了提高网络的收敛速度、避免数据过大引入的网络麻痹问题, 进一步将一次差归一化到区间 $(-1, 1)$ 上.

步骤2: 网络初始化. 模糊神经网络的初始化分为两部分: 结构初始化和参数初始化. 先确定网络结构各层的节点数, 初始化网络结构. 根据以往的实践经验, 综合考虑神经网络的收敛速度与预报精度, 将网络最小均方误差、学习率以及最大训练次数等预设一个数值, 并对后件网络的连接权、高斯型隶属函数的中心及宽度在 $(0, 1)$ 之间随机赋值.

步骤3: 参数学习. 根据划分的数据样本对模糊神经网络的参数进行训练, 通过一阶梯度寻优算法来优化网络参数.

步骤4: 模型改进. 根据经验预设的参数值, 往往不一定能实现模型的最优输出. 除了步骤3优化参数外, 还要不断地调整网络各层的节点数以及网络最小均方误差、学习率以及最大训练次数等, 最终根据预报残差, 选择残差最小的一组网络结构和参数建立最优的模糊神经网络预报模型.

步骤5: 在步骤1-4的基础上建立最优的模糊神经网络预报模型并进行卫星钟差的预报应用, 将预报值依次经过反归一化、反差分两步操作后, 即可还原原始钟差预报值.

4 算例与分析

目前, GPS在轨卫星搭载的原子钟有4种类型: Block IIF Cs钟、Block IIF Rb钟、Block IIR-M Rb钟和Block IIR Rb钟, 受Cs钟本身物理特性及元件老化的影响, 其稳定性和精度较其他3类原子钟低2-3倍. 为了评估本文所提方法和常规方法在不同类型原子钟预报中的应用性能, 我们从IGS提供的30 s间隔和15 min间隔GPS精密钟差数据中随机选取不同类型原子钟对应的一颗卫星进行预报试验, 分别是PRN01 (Block IIF Rb)、PRN08 (Block IIF Cs)、PRN23 (Block IIR Rb)和PRN29 (Block IIR-M Rb). 另外, 以预报时间段对应的已知IGS精密钟差为基准, 统计预报结果的均方根误差(RMS)、最大残差、最小残差和残差均值, 并进行对比分析.

4.1 模糊神经网络模型预报精度分析

选取2015年10月5日至2015年10月6日不同采样间隔的精密钟差为实验数据, 分别使用4颗卫星各自对应的10月5日一天的数据作为输入来建立模糊神经网络模型, 预报6日3 h、12 h和24 h的钟差数据. 设置网络的学习率为0.3、动量系数为0.7、最大训练次数为2000、最小均方误差为0.00001.

限于篇幅, 以采样间隔为15 min的钟差数据为例, 图2-5是PRN01、PRN08、PRN23和PRN29 4颗卫星在模糊神经网络模型下的预报流程及结果图, 图中FNN代表本文所提的模糊神经网络模型. 图2-5中的(a)图为预处理阶段使用的24 h原始钟差数据. 分析得知, 该原始钟差序列不可避免地会引入一定的系统误差, 且钟差数据有效位数过多, 数据过大, 因此不适于直接作为样本来进行建模分析. (b)图为将(a)图相邻历元钟差数据作差形成的一次差分序列. 采用一次差原理对原始钟差数据进行预处理, 可以在一定程度上消除钟差趋势项及部分系统误差的影响, 得到一组更易于模糊神经网络建模的数据. (c)图为模糊神经网络模型的24 h钟差预报值与IGS实际钟差数据的比较. (d)图为模糊神

经网络模型的预报残差, 反映了模型的预报精度与稳定性.




图 2 PRN01 FNN的预报结果. 上面两个图为PRN01的原始钟差数据(a)及其一次差分序列(b). 下面两个图为FNN的预报结果与IGS钟差的比较(c)和FNN的预报残差(d).

Fig.2 The FNN model prediction of PRN01. The two top panels are the SCB of PRN01 (a) and the first order difference of SCB (b), respectively. The two bottom panels are the comparison of prediction results of FNN with the SCB provided by IGS (c), and the prediction errors of FNN (d), respectively.




图 3 PRN08 FNN的预报结果. 上面两个图为PRN08的原始钟差数据(a)及其一次差分序列(b). 下面两个图为FNN的预报结果与IGS钟差的比较(c)和FNN的预报残差(d).

Fig.3 The FNN model prediction of PRN08. The two top panels are the SCB of PRN08 (a) and the first order difference of SCB (b), respectively. The two bottom panels are the comparison of prediction results of FNN with the SCB provided by IGS (c), and the prediction errors of FNN (d), respectively.




图 4 PRN23 FNN的预报结果. 上面两个图为PRN23的原始钟差数据(a)及其一次差分序列(b). 下面两个图为FNN的预报结果与IGS钟差的比较(c)和FNN的预报残差(d).

Fig. 4 The FNN model prediction of PRN23. The two top panels are the SCB of PRN23 (a) and the first order difference of SCB (b), respectively. The two bottom panels are the comparison of prediction results of FNN with the SCB provided by IGS (c), and the prediction errors of FNN (d), respectively.




图 5 PRN29 FNN的预报结果. 上面两个图为PRN29的原始钟差数据(a)及其一次差分序列(b). 下面两个图为FNN的预报结果与IGS钟差的比较(c)和FNN的预报残差(d).

Fig. 5 The FNN model prediction of PRN29. The two top panels are the SCB of PRN29 (a) and the first order difference of SCB (b), respectively. The two bottom panels are the comparison of prediction results of FNN with the SCB provided by IGS (c), and the prediction errors of FNN (d), respectively.

从图2-5中可以看出, 模糊神经网络对使用铯钟的卫星预报精度较差. 究其原因, 主要是由于铯钟发射时间较早, 元件老化, 同时还因其本身原子频标特性的影响, 导致预报结果相对较差. 结合PRN08号卫星预报流程及结果来看, 其一次差分序列波动较为剧烈, 预报残差在4 ns以内, 且随着预报步长的增加, 预报误差逐渐增大. 而将铷钟作为星载原子钟的PRN01、PRN23和PRN29 3颗卫星的一次差波动幅度较小, 预报结果稳定性也较好, 在约1 ns以内, 24 h预报残差的均方根分别保持在0.2 ns、0.6 ns和0.5 ns以内, 有很好的预报效果, 特别是对于PRN01, 预报效果最优. 从4颗卫星的算例分析来看, 新方法的预报精度与稳定性不仅与星载原子钟类型有关, 还与卫星钟差的波动性有关, 其对变化比较稳定的卫星钟差的预报精度比较可靠.

为更好地验证分析模糊神经网络模型对应不同采样间隔、不同预报时长的预报效果, 在短期预报的基础上, 我们统计了采样间隔分别为30 s、15 min的4颗卫星各自3 h、12 h和24 h的预报精度, 最后所得统计结果如表2所示. 表2中, T 代表预报时间, 单位为h; Max、Min、Mean、RMSE分别为预报残差的最大值、最小值、均值和均方根误差, 单位均为ns.

从表2的统计结果可以看出, 同一采样间隔的钟差数据, 当预报步长相同时, 预报精度在各颗卫星间表现出了一定的差异性. 对于短期预报, 铷钟的预报精度普遍优于铯钟的预报精度, 误差波动性也较小. 目前, GPS的星载原子钟主要是铷钟, 不同的铷钟之间, 预报精度和稳定性也不尽相同. 采用15 min采样间隔钟差数据进行试验, 对铷钟预报3 h均方根误差可以控制在0.3 ns以内, PRN01、PRN29和PRN23一整天即24 h的预报极差分别为0.314 ns、0.990 ns和1.199 ns, 均方根误差分别为0.129 ns、0.467 ns和0.553 ns, 极差即预报残差的最大值与最小值之差, 代表了预报结果的稳定性. 将30 s钟差数据用于短期预报, 对铷钟预报3 h均方根误差优于0.2 ns, 铯钟的预报精度保持在0.6 ns以内, 取得了更为理想的预报结果, 预报精度和稳定性均优于15 min采样间隔钟差数据的预报结果. 这说明在相同时间段内, 增加用于模糊神经网络建模的样本量, 所建模型能够更好地反映钟差的实际变化规律, 从而有着更优良的预报效果. 从总体来看, 随着预报时长的增大, 铷钟的预报误差表现较为稳定, 并没有出现明显的误差累积效应, 对其进行钟差预报可以获得更高的预报精度.

4.2 模糊神经网络模型与常规模型的对比

由于模糊神经网络汇集了模糊系统与神经网络的众多优点, 集并行处理、自学习、联想、识别于一体, 因此在处理非线性、模糊性等问题上有很大的优越性. 为了进一步比较模糊神经网络模型与常规模型的预报性能, 将本文所提方法与常用的ARIMA模型、GM(1,1)模型和QP模型的预报结果进行深入对比分析. 采用PRN01、PRN08、PRN23和PRN29 4颗卫星在2015年10月5日24 h内不同采样间隔的钟差数据来建立前述4种模型, 预报接下来24 h的钟差数据; 而QP模型的建模方案类似于文献[18-19]中所提的方法, 在建模的时候考虑卫星钟差的12 h以及6 h主周期项的影响, 即采用附有周期项的QP模型来预报卫星的24 h钟差. 表3给出了不同采样间隔、不同卫星ARIMA建模时各参数的取值情况, 本文在数据预处理阶段根据钟差的变化特点采用2阶差分对其进行平稳化处理, 然后建模分析. 图6-9为钟差采样间隔15 min时4颗卫星在不同模型下的预报误差对比图, 相应的预报结果统计情况如表4所示.

表 2 模糊神经网络模型预报结果的统计值
Table 2 Statistics of prediction results of the fuzzy neural network model

Sampling interval	Satellite number	<i>T</i> /h	Max/ns	Min/ns	Mean/ns	RMSE/ns
30 s	PRN01 (BLOCK IIF Rb)	3	0.135	0.011	0.028	0.033
		12	0.157	0.001	0.049	0.067
		24	0.265	0.001	0.072	0.091
	PRN08 (BLOCK IIF Cs)	3	1.102	0.023	0.451	0.535
		12	1.587	0.013	0.517	0.598
		24	2.931	0.005	1.113	1.252
	PRN23 (BLOCK IIR Rb)	3	0.212	0.053	0.103	0.101
		12	0.915	0.002	0.326	0.411
		24	0.973	0.002	0.413	0.470
	PRN29 (BLOCK IIR-M Rb)	3	0.251	0.002	0.152	0.191
		12	0.560	0.001	0.239	0.330
		24	0.775	0.001	0.251	0.362
15 min	PRN01 (BLOCK IIF Rb)	3	0.181	0.012	0.037	0.050
		12	0.183	0.001	0.054	0.073
		24	0.315	0.001	0.097	0.129
	PRN08 (BLOCK IIF Cs)	3	1.207	0.037	0.534	0.617
		12	1.993	0.010	0.722	0.841
		24	3.615	0.009	1.282	1.572
	PRN23 (BLOCK IIR Rb)	3	0.269	0.071	0.142	0.151
		12	1.009	0.004	0.496	0.521
		24	1.202	0.003	0.508	0.553
	PRN29 (BLOCK IIR-M Rb)	3	0.491	0.003	0.226	0.278
		12	0.863	0.002	0.359	0.425
		24	0.992	0.002	0.401	0.467

表 3 ARIMA模型的阶数
Table 3 The order numbers of ARIMA model

Order	Satellite		PRN01 (Rb)		PRN08 (Cs)		PRN23 (Rb)		PRN29 (Rb)	
			30 s	15 min	30 s	15 min	30 s	15 min	30 s	15 min
d			2	2	2	2	2	2	2	2
p			1	2	2	4	10	13	15	16
q			8	5	9	7	4	9	11	3




图 6 PRN01的预报结果

Fig. 6 Prediction results of PRN01




图 7 PRN08的预报结果

Fig. 7 Prediction results of PRN08




图 8 PRN23的预报结果

Fig. 8 Prediction results of PRN23




图 9 PRN29的预报结果

Fig. 9 Prediction results of PRN29

表 4 不同模型预报结果的统计值
Table 4 Statistics of prediction results of different models

Sampling interval	Satellite number	Model	Max/ns	Min/ns	Mean/ns	RMSE/ns
30 s	PRN01 (BLOCK IIF Rb)	QP	1.431	0.003	0.573	0.752
		GM(1, 1)	2.011	0.007	0.891	1.021
		ARIMA	0.637	0.013	0.201	0.309
		FNN	0.265	0.001	0.072	0.091
	PRN08 (BLOCK IIF Cs)	QP	8.837	0.735	4.851	5.133
		GM(1, 1)	8.051	0.507	2.978	3.211
		ARIMA	4.322	0.033	1.790	2.080
		FNN	2.931	0.005	0.901	1.015
	PRN23 (BLOCK IIR Rb)	QP	1.992	0.013	1.015	1.311
		GM(1, 1)	2.790	0.920	1.750	1.926
		ARIMA	1.261	0.150	0.802	0.930
		FNN	0.973	0.002	0.413	0.470
	PRN29 (BLOCK IIR-M Rb)	QP	2.018	0.009	0.772	0.925
		GM(1, 1)	4.265	0.002	2.102	2.310
		ARIMA	3.126	0.002	1.330	1.521
		FNN	0.775	0.001	0.251	0.362
15 min	PRN01 (BLOCK IIF Rb)	QP	1.767	0.006	0.769	0.918
		GM(1, 1)	2.360	0.009	1.064	1.255
		ARIMA	0.796	0.056	0.402	0.444
		FNN	0.315	0.001	0.097	0.129
	PRN08 (BLOCK IIF Cs)	QP	10.915	0.860	5.445	6.089
		GM(1, 1)	10.250	0.773	5.108	5.712
		ARIMA	6.632	0.051	2.894	3.387
		FNN	3.615	0.009	1.282	1.572
	PRN23 (BLOCK IIR Rb)	QP	2.206	0.021	1.382	1.520
		GM(1, 1)	3.358	0.115	2.011	2.212
		ARIMA	1.491	0.238	0.940	1.109
		FNN	1.202	0.003	0.508	0.553
	PRN29 (BLOCK IIR-M Rb)	QP	2.284	0.010	1.005	1.187
		GM(1, 1)	4.475	0.004	2.260	2.630
		ARIMA	3.513	0.006	1.656	1.969
		FNN	0.992	0.002	0.401	0.467

综合图6-9、表3-4的结果可见:

(1)本文所选附有周期项的QP模型实际上是对前24 h钟差数据整体变化趋势的最小二乘拟合,在相同的样本数据情况下,附有周期项的QP模型预报精度要优于GM(1,1)模型,但是随着预报步长的增加,QP模型和GM(1,1)模型仍然会表现出一定的误差累积效应,这进一步说明二者并不适合应用于钟差的长期预报。

(2)因为ARIMA模型在提取卫星钟差趋势项的基础上,针对随机项建模,所以在多数情况下其短期预报精度及稳定性要优于QP模型和GM(1,1)模型。在实际建模时,要根据每颗卫星钟差的变化规律来选择适合的ARIMA模型,才能实现对钟差的最优预报。此外,对比4颗卫星的预报均方根误差可以看出,部分卫星ARIMA模型的预报结果发散较快,QP模型的预报精度反而优于ARIMA模型,这说明当建模数据较少时,模型识别与定阶不准会在一定程度上劣化ARIMA模型的预报效果。

(3)无论钟差呈何种形式的变化,在建模数据一定的条件下,模糊神经网络模型的预报效果更优,预报精度较其他3种模型能够提高约2倍以上,这充分体现了本文所提方法的有效性和优越性。由表4可知,采用15 min间隔钟差预处理后的数据建模,模糊神经网络模型在各类型原子钟的钟差预报中均表现出较强的稳定性,并未出现预报误差快速递增或递减的情况,PRN08的预报残差基本处于(0.01, 3.62)区间内,而PRN01、PRN23和PRN29 3颗卫星预报残差也基本都控制在1.3 ns以内。类似地,模糊神经网络模型对30 s间隔的钟差预报也取得了较常规模型更优的预报结果,PRN08的预报残差接近1 ns, PRN01、PRN23和PRN29最小预报残差分别为: 0.001 ns、0.002 ns和0.001 ns,最大预报残差分别为: 0.265 ns、0.973 ns和0.775 ns。

特别地,从表4可以看出,每颗卫星的统计结果中模糊神经网络模型的均方根误差值和预报极差均为最小,这说明针对不同采样间隔的钟差进行短期预报,新模型的预报精度及稳定性要优于常规模型。当预报步长相同时,新模型对采样间隔较小的钟差数据有更优的预报效果,这进一步说明在使用新方法进行钟差预报时,扩大用于建模的样本量,能够较大幅度地改善钟差的预报结果。综上,在卫星钟差的短期预报中,对不同类型原子钟和采样间隔的钟差数据,本文所提方法能够极大地改善卫星钟差的预报效果,在预报精度及稳定性方面明显优于常规模型,可以在实际应用中代替常规模型。

5 结论

为了进一步提高卫星钟差的预报精度,本文根据钟差序列的变化特点,将Takagi-Sugeno模糊神经网络模型引入钟差的短期预报中,建立了一种精度更高、稳定性更强的钟差预报模型。通过实际的算例与分析,可以说明:基于Takagi-Sugeno模糊神经网络模型的钟差预报方法,能够克服常规模型发散较快、波动性较强的缺点,取得了更为理想的预报结果,对不同采样间隔的钟差数据,在预报精度及稳定性两方面,均优于常规模型;新模型在数据预处理阶段采用的一次差方法,能够在一定程度上降低系统误差及其他噪声对钟差预报的影响,得到的差分序列更易于模糊神经网络建模分析,这在处理噪声污染较为严重的钟差数据时,具有一定的指导意义。上述Takagi-Sugeno模糊神经网络的网络结构是通过大量实验所得,因此针对卫星的钟差预报,选择合适的模糊神经网络结构显得尤为重要,它直接决定着GPS卫星钟差预报的精度。由此可见,如何优化模糊神经网络的网络结构,从而得到更优的钟差预报模型,有待进一步理论研究。

参 考 文 献

- [1] 雷雨, 赵丹宁, 高玉平. 时间频率学报, 2013, 36: 156
- [2] 王宇谱, 吕志平, 陈正生, 等. 武汉大学学报: 信息科学版, 2016, 41: 373
- [3] 郭承军, 滕云龙. 天文学报, 2010, 51: 395
- [4] 赵书红, 王正明, 尹东山. 天文学报, 2014, 55: 313
- [5] Zhao S H, Wang Z M, Yin D S. ChA&A, 2015, 39: 118
- [6] 陆晓峰, 杨志强, 贾小林, 等. 武汉大学学报: 信息科学版, 2008, 33: 492
- [7] 郑作亚, 陈永奇, 卢秀山. 天文学报, 2008, 49: 306
- [8] Zheng Z Y, Chen Y Q, Lu X S. ChA&A, 2009, 33: 72
- [9] 席超, 蔡成林, 李思敏, 等. 天文学报, 2014, 55: 78
- [10] Xi C, Cai C L, Li S M, et al. ChA&A, 2014, 38: 342
- [11] 王国成, 柳林涛, 徐爱功, 等. 测绘学报, 2014, 43: 803
- [12] 吴艳辉, 陈雄. 复旦学报: 自然科学版, 2005, 44: 56
- [13] 郝天轩, 宋超. 中国安全科学学报, 2011, 21: 36
- [14] 罗周全, 左红艳, 王爽英, 等. 中南大学学报: 自然科学版, 2011, 42: 2812
- [15] 刘兴杰, 岑添云, 郑文书, 等. 中国电机工程学报, 2014, 19: 3162
- [16] 董早鹏, 刘涛, 万磊, 等. 仪器仪表学报, 2015, 36: 863
- [17] Abe S. ITSMC, 1995, 25: 119
- [18] 刘志强, 王解先, 李浩军, 等. 测绘科学技术学报, 2014, 3: 226
- [19] Senior K L, Ray J R, Beard R L. GPS Solutions, 2008, 12: 211

The Satellite Clock Bias Prediction Method Based on Takagi-Sugeno Fuzzy Neural Network

CAI Cheng-lin^{1,2} YU Hong-gang^{1,2} WEI Zhao-chuan^{1,2} PAN Jun-dao^{1,2}

(1 School of Information and Communication, Guilin University of Electronic Technology,
Guilin 541004)

(2 Guangxi Key Laboratory of Precision Navigation Technology and Application, Guilin 541004)

ABSTRACT The continuous improvement of the prediction accuracy of Satellite Clock Bias (SCB) is the key problem of precision navigation. In order to improve the precision of SCB prediction and better reflect the change characteristics of SCB, this paper proposes an SCB prediction method based on the Takagi-Sugeno fuzzy neural network. Firstly, the SCB values are pre-treated based on their characteristics. Then, an accurate Takagi-Sugeno fuzzy neural network model is established based on the preprocessed data to predict SCB. This paper uses the precise SCB data with different sampling intervals provided by IGS (International Global Navigation Satellite System Service) to realize the short-time prediction experiment, and the results are compared with the ARIMA (Auto-Regressive Integrated Moving Average) model, GM(1,1) model, and the quadratic polynomial model. The results show that the Takagi-Sugeno fuzzy neural network model is feasible and effective for the SCB short-time prediction experiment, and performs well for different types of clocks. The prediction results for the proposed method are better than the conventional methods obviously.

Key words astrometry: time, methods: data analysis, methods: Takagi-Sugeno