Vol. 38, No.6 Dec. 2019

doi:10.3969/j.issn.1003-2029.2019.06.009

基于 RBF 神经网络的多系统钟差预报算法

王 瑞,柴洪洲,潘宗鹏 (解放军信息工程大学,河南 郑州 450001)

摘要:针对海上条件下,对于实时定位应用,实时数据流无法下载的情况,文中提出一种基于RBF神经网络的卫星钟差预报算法,给出基函数的中心、方差以及隐含层到输出层的权值的计算方法,采用滑动窗口的方法,用样本数据训练后的网络预测下一个历元的钟差值,依次往后训练网络直到预测完整个时间段,通过实验验证了算法的可用性。短期预报中,GPS 预报精度在1 ns 以下,BDS 和 GLONASS 在 2~3 ns 左右;长期预报中,GPS 预报精度在几十纳秒左右,而 BDS 和 GLONASS 在几百纳秒左右,文中给出了相应的结果分析。

关键词:RBF;神经网络;多系统;钟差预报;滑动窗口

中图分类号:P714 文献标志码:A 文章编号:1003-2029(2019)06-0056-06

开展海上精密定位方法研究可为船舶的航行提供精确的空间基准。海上定位是进行海洋测绘以获取海洋地理信息的基础。海上定位是指在海洋中的船舶中应用各种测量仪器来测定船舶所在位置的过程,现代的海上导航定位主要方法有无线电定位、声呐法、惯性导航定位、GNSS 法等定位方法^[1]。其中,GNSS 定位法以其覆盖范围、信号可靠性、准确性和多用性,优于其他定位方式,是当前海上定位的主要方法^[2]。

随着全球卫星导航系统(Global Navigation Satellite System, GNSS)朝着多模多频快速发展,GNSS 精密定位理论和方法也不断演进^[3],联合多模多频、高精度和高可靠的绝对定位技术成为了当今精密定位的发展趋势^[4]。精密单点定位(Precise Point Positioning, PPP) 和实时动态定位(Real -Time Kinematic, RTK)是高精度 GNSS 定位领域的两种最主要的技术手段^[5]。PPP 突破了相对定位中的距离限制,它使用 IGS 发布的精密星历和钟差产品,仅使用 1 台接收机就可进行大范围的静态和动态定位导航,并且可以直接获得毫米至厘米级的静态精度

和厘米至分米级的动态精度^[6]。此外,精密单点定位还具有进行单机作业、便于灵活操作、技术作业范围广、作业效率高等优点^[7]。经过近 20 年的发展,精密单点定位技术已获得巨大的进步,在变形监测^[8]、卫星定轨^[9-10]、气象测绘^[11]和航空^[12]等众多领域有了极为广泛的应用。

由于PPP将卫星钟差改正直接参与解算,其定位性能与卫星钟性能以及系统对卫星钟特征参数的估计和预报能力密切相关[13]。虽然各个GNSS数据中心后处理之后可以得到高精度的钟差产品,IGS最终精密钟差产品精度在0.075 ns左右,却存在着12~18 d的时间延迟,因此,对于海上实时定位,高精度钟差的预报就显得尤为重要。为了提高卫星钟差预报精度,国内外学者做了大量的研究工作。Panfilo等[14]建立了包括确定性模型和随机性模型的卫星钟差预报的数学模型,并对卫星钟差进行了预报分析。Senior等[15]对比分析了采样间隔不同的IGS钟差产品,得到了预报钟差的相关特性。王宇谱等[16]针对GPS钟差,对常用的钟差预报方法进行了详细的预报性能评估,并在此基础上利用小波神经

网络对一次差分后的钟差进行预报,结果表明所建 模型的预报效果优于两种常规模型。崔博斌凹针对 星载钟稳定性较差的问题,提出了顾及起点偏差、 自适应权函数与 BP 神经网络修正的二次项附加周 期项钟差预报模型,采用神经网络与周期模型,有 效降低了多种噪声对钟差预报精度的影响。

由此可见,大部分钟差预报的实验均是建立在 GPS 卫星钟差基础上的。随着 BDS 和 GLONASS 的 蓬勃发展,对于多系统钟差预报的需求也与日俱 增,研究高精度卫星钟差预报模型对拓展精密单点 定位的实际应用具有重要意义。本文采用 RBF 神经 网络对钟差进行预报,讨论了神经网络的基本概 况,详细介绍了径向基神经网络的原理,以及其在 钟差预报上的应用。

基于 RBF 神经网络的钟差预报算法

1.1 人工神经网络原理

人工神经网络(Artificial Neural Network, ANN) 是人工智能算法的一种, 也是该领域的研究热点, 它是模拟人脑的思考方式而提出的一种数学模型[18]。 最近十多年来,大量研究机构和学者对人工神经网 络进行了深入的研究,已经取得了很大的进展,其 在遥感、地图、模式识别、人工智能等领域都表现出 了良好的解决能力。

与生物体的神经系统类似,ANN 也是由众多的 神经网络节点构成,即所谓的神经元。人工神经元作 为神经网络最基本的构成单元,其结构如图 1 所示。

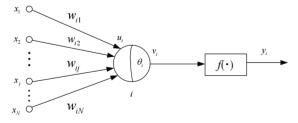


图 1 人工神经元模型

图中 $,x_1,x_2,\cdots,x_i,\cdots,x_n$ 为神经元的n维输入信 号; u_i 为由输入信号组合后的输出,是神经元i的净 输入; $w_{i1}, w_{i2}, \cdots, w_{ij}, \cdots, w_{iN}$ 为从相应节点连接到神 经元的权值; θ ; 为神经元的阈值;v; 为调整后的值, 也称为局部感应区。其中:

$$u_i = \sum_{j=1}^{N} w_{ij} x_j$$

$$v_i = u_i + \theta_i$$
(1)

$$v_{\cdot} = u_{\cdot} + \theta_{\cdot} \tag{2}$$

 $f(\cdot)$ 是激励函数, γ ,为神经元的输出,则有:

$$y_i = f(\sum_{j=1}^{N} w_{ij} + \theta_i)$$
 (3)

1.2 RBF 神经网络

径向基函数(Radical Basis Function, RBF)是多 维空间插值的传统技术,由 Powell 于 1985 年提出, 其定义为只跟距离有关的单调函数,即中心中的任 一点到某一中心点之间的欧式距离。1988年, Broomhead 和 Lowe 根据生物神经元具有局部效应 这一特点,将RBF引入神经网络设计中,产生了 RBF 神经网络[19]。

RBF 神经网络是前向神经网络的一种。它的网 络结构大致分为3层:第一层是输入层,即样本的 输入;第二层是隐含层,即用 RBF 构成神经元单元, 将输入空间的样本数据映射到隐含层空间之中,并 且不需要权来连接;第三层是输出层,将隐含层处 理过的数据线性加权后加以输出,在隐含层中与中 心点越接近的点,即样本与中心点样本越相似,输 出层的值就越大。RBF 网络的基本思想是:用 RBF 作为隐含单元的"基"构成隐含层空间,隐含层对输 入矢量进行变换,将低维的模式输入数据变换到高 维空间内,使得在低维空间内的线性不可分的问题 在高维空间内线性可分。

径向基函数网络的神经元模型如图 2 所示。

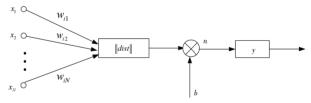


图 2 径向基神经元模型

可以看出,RBF神经网络的神经元激活函数是 以距离 || dist || 作为自变量的,可表示为:

$$R = \phi(\parallel dist \parallel) \tag{4}$$

由上图所示的神经元构成了 RBF 神经网络,其 中 b 为给定的某个阈值参数,用来调节神经元解算 的灵敏度。RBF 神经网络的结构如图 3 所示。

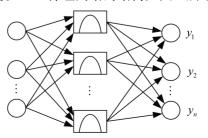


图 3 径向基神经网络结构

1.3 基于 RBF 神经网络的钟差预报算法

由于 RBF 神经网络训练时间短,且具有全局收敛的优点,因此非常适合卫星钟的钟差预报。

由上节可知,RBF 隐含层的解算是神经网络能否训练成功、训练出的网络的泛化能力的关键,而RBF 比较重要的参数有 3 个:基函数的中心、方差以及隐含层到输出层的权值。同时,RBF 核函数的选取也是网络训练的重要方面,通常采用高斯函数,即:

$$R(x_p - c_i) = \exp(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2)$$
 (5)

式中: $\|x_p - c_i\|$ 为欧式距离函数; c_i 为 RBF 激活函数的中心; σ^2 为方差。

由图 3 所示的径向基神经网络的结构可得到 网络的输出为:

$$y_j = \sum_{i=1}^k w_{ij} \exp(-\frac{1}{2\sigma^2} \| x_p - c_i \|^2), j = 1, 2, \dots n$$
 (6)

式中: x_p 为第p个输入样本; $p=1,2,\cdots,P$,P为样本总数; c_i 为网络隐含层节点的中心; w_i 为隐含层到输出层的连接权值; $i=1,2,\cdots,k$,为隐含层节点数; $j=1,2,\cdots,n$,为输出节点数; y_i 为与输入样本对应的网络的第i个输出节点的实际输出。

基于 RBF 神经网络的钟差预报算法,具体步骤如下:

(1) 求取基函数中心 c_i

首先将输入层的输入样本进行分类:随机选取 n 个样本作为基函数的预计中心, 计算其他样本与 这几个预计中心点样本的欧式距离,将距离接近的 样本形成各个集合。其次,计算各个分类后的集合 的平均值, 如果平均值与预计中心点的样本值相 同,则该样本就是基函数的中心,否则就重新分类 求解。

(2) 求解方差 σ

方差 σ 可如式(7)所示进行求解:

$$\sigma_i = \frac{c_{\text{max}}}{\sqrt{2k}} \tag{7}$$

(3) 计算隐含层和输出层之间的权值 w

隐含层至输出层之间的神经元的连接权值可以用最小二乘法直接计算得到,计算公式如下:

$$w = \exp(\frac{k}{2} \| x_p - c_i \|^2) \quad i = 1, 2, \dots, k; \ p = 1, 2, \dots, P \quad (8)$$

2 算例分析

将 GFZ 下载的 5 min 采样间隔的混合精密钟差产品进行重采样,得到 15 min 采样间隔的钟差数据,来进行钟差预报的实验。以 GPSWeek20080 到 GPSWeek20106(2018 年 7 月 1 日 –7 月 21 日)共21 d 的钟差数据为例进行 GPS、BDS 和 GLONASS 3 个卫星导航系统的预报实验。

预报试验中,以下载的 GFZ 精密事后钟差数据作为真值,使用均方根误差(RMS)和极差(Range)作为统计量,分析各类模型以及卫星系统的预报效果。设计以下方案,对该模型以及各卫星系统进行钟差的预报效果分析。

使用 1 d 的钟差数据进行建模,预报接下来 0.5 d、1 d 以及 10 d 的钟差:

由于采样间隔为 15 min, 故 1 d 的钟差数据表示样本数为 96,即用 96 个样本数据进行训练,采用滑动窗口的方法,窗口大小即为样本的大小 96,使用训练好的网络来预测接下来的一个历元的数据,直到预测完接下来的 48,96 以及 960 个数据,并验证结果。

由于篇幅问题,本文只给出某一颗 GPS 卫星的 钟差预报效果图。将两种不同的方案的统计结果整理到同一个统计表中,不同的卫星系统整理在不同的统计表里。

图 4 为 G01 两种方案的钟差预报结果以及误差,按顺序分别为使用 1 d 数据预报 0.5 d,1 d,10 d的钟差,各卫星两种方案的统计结果整理到表 1 中。

根据图 4 及表 1 的预报结果可知:(1)基于RBF 神经网络的钟差预报模型对 GPS 卫星钟的钟差预报有着很强的可靠性,无论是短期预报还是长期预报都有很好的表现;(2)从 GPS 的 5 种类型原子钟相互对比来看,Cs 钟的预报精度低于 Rb 钟,整体而言每种原子钟精度的数量级大致相同,这与GPS 卫星钟自身的特性相符;(3)从表 1 的最后一列可以看出,RBF 神经网络模型的精度和稳定性与GPS 钟的种类密切相关,不同类别的原子钟的精度和稳定性有所不同。

BDS 和 GLONASS 的各卫星两种方案的统计结果整理到表 2~表 3 中。

根据表 2~表 3 的预报结果可知:(1)从 RMS 均值来看,BDS 均值最大,GLONASS 次之,GPS 最小,

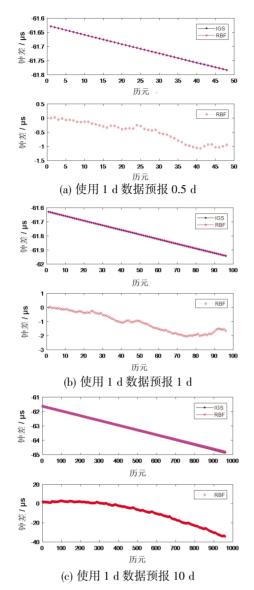


图 4 G01 卫星 RBF 神经网络模型预报结果与误差

表 1 GPS RBF 神经网络模型预报结果

单位·ns

					平世:ns
卫星号	统计量	1 d–12 h	1 d–24 h	1 d–10 d	平均值
G18	RMS	0.5603	1.2500	22.660 4	8.1569
${ m I\hspace{1em}I}$ A Rb	Range	2.158 5	3.373 2	54.691 1	20.0743
G16	RMS	0.6258	0.630 1	29.934 0	10.3967
IIR Rb	Range	1.2770	1.277 0	63.597 6	22.0505
G07	RMS	0.5976	0.975 1	70.7926	24.1218
IIR–M Rb	Range	1.1399	2.5966	261.5142	88.4169
G08	RMS	1.0024	2.4593	44.585 2	16.0156
$\operatorname{IIF} \operatorname{Cs}$	Range	4.0073	7.185 1	73.163 0	28.1185
G01	RMS	0.597 1	1.272 4	14.490 1	5.4532
IIF Rb	Range	1.094 5	2.075 5	37.468 1	13.5460
平均值	RMS	0.6766	1.3174	36.492 5	12.8288
	Range	1.935 4	3.301 5	98.0868	34.4412

表 2 BDS RBF 神经网络模型预报结果

单位:ns

卫星号	统计量	1 d-12 h	1 d-24 h	1 d-10 d	平均值
C01	RMS	4.450 1	9.043 9	467.535 6	160.343 2
GEO	Range	9.935 3	16.778 7	993.627 8	340.113 9
C08	RMS	1.736 9	1.605 7	310.551 8	104.631 5
IGSO	Range	3.339 7	4.143 2	939.572 7	315.685 2
C11	RMS	1.879 5	3.260 0	207.286 1	70.808 5
MEO	Range	5.928 3	7.987 6	766.784 0	260.233 3
平均值	RMS	2.688 8	4.636 5	328.457 9	111.927 7
	Range	6.401 1	9.636 5	899.994 9	305.344 2

表 3 GLONASS RBF 神经网络模型预报结果

单位:ns

卫星号	统计量	1 d-12 h	1 d-24 h	1 d-10 d	平均值
R04	RMS	4.619 4	14.028 2	239.291 9	85.979 8
	Range	11.388 9	27.926 7	415.438 4	151.584 7
R17	RMS	1.638 4	7.134 7	207.952 6	72.241 9
	Range	5.387 2	14.354 9	347.235 3	122.325 8
R24	RMS	4.326 9	11.749 0	188.885 8	68.320 6
	Range	11.695 7	25.853 5	322.705 5	120.084 9
平均值	RMS	3.528 2	10.970 6	212.043 4	75.514 1
	Range	9.490 6	22.711 7	361.793 0	131.331 8

说明 BDS 钟相比 GLONASS 以及 GPS 钟精度稍差,稳定性也比较差,但短期预报整体精度也在纳秒级,并且随预报时间段的不同而变化;(2)对比 BDS 3 种原子钟预报精度及稳定性可以看出,MEO 卫星预报的 RMS 值最小,其次是 IGSO 卫星,GEO 卫星最差,而对于 GLONASS,不同轨道的预报精度和稳定性差距也较大,出现这种结果的原因主要与卫星的轨道类型以及卫星的运行时间有关,说明轨道类型和高度在一定程度上也会影响卫星钟的预报性能。

将 RBF 神经网络与灰色模型的预报结果进行对比,结果如表 4~表 5 所示。

表 4 RBF 神经网络模型与灰色模型对比情况

单位:ns

卫星	统计量	1 d–12 h		1 d–10 d		
系统	シャクリ 生	GM(1,1)	RBF	GM(1,1)	RBF	
GPS	RMS	1.8998	0.6766	58.8150	36.492 5	
	Range	2.844 1	1.935 4	122.405 5	98.0868	
BDS	RMS	5.424 1	2.6888	623.1448	328.4579	
	Range	7.187 2	6.401 1	1 373.055 1	899.9949	
平均值	RMS	3.6619	1.6827	340.9799	182.475 2	
	Range	5.0157	4.168 3	747.7303	499.040 9	

由表 4 可知:

- (1) 短期预报中,RBF 神经网络模型在精度和稳定性上较灰色模型都有显著的提升,平均精度在1~2 ns 左右。因此,该模型在短期预报上可作为灰色模型的改进模型来更好地预报钟差。
- (2)长期预报中,RBF神经网络模型在精度和稳定性上较灰色模型都有显著的提升,平均精度在100~200 ns 左右。因此,该模型在长期预报上可作为灰色模型的改进模型来更好地预报钟差。

表 5 GLONASS 系统 RBF 神经网络模型与灰色模型的对比 单位:ns

卫星系统	统计量	1 d-12 h		1 d–10 d	
			RBF	GM(1,1)	RBF
GLONASS	RMS	1.456 5	3.528 2	39.137 7	212.043 4
	Range	4.363 0	9.490 6	69.193 0	361.793 0

由表 5 可以看出,RBF 神经网络模型在GLONASS上表现不好,其原因可能是,RBF 神经网络对非线性的样本具有较好的逼近能力,而GLONASS原子钟良好的频漂特性以及稳定的频率数据严重影响了神经网络的训练,所以精度会不如灰色模型。

3 结论

本文提出一种基于 RBF 神经网络的卫星钟差 预报算法,采用滑动窗口的方法,用样本数据训练 后的网络预测一个历元的钟差值,依次往后训练网络直到预测完整个时间段,通过实验验证了算法的 可用性,并与灰色模型预报结果进行了对比分析,结果表明:

短期预报中,RBF 神经网络模型在精度和稳定性上较灰色模型都有显著的提升,三系统的平均精度在 1~2 ns 左右;在长期预报中,平均精度在 100~200 ns 左右,因此该模型可作为灰色模型的改进模型来更好地预报钟差。但该模型在 GLONASS 上表现不佳,这与其自身原子钟特性有关。通过对比试验可以看出,GNSS 在钟差预报模型的选取上,要根据原子钟的不同以及预报时间段的差别来挑选最优的预报模型,很难找到一个预报模型适合各种预报的情况。

参考文献:

- [1] 刘帅, 包敬海. 基于北斗卫星的海上定位解算方法的研究[J]. 电子科技, 2018, 31(11):84-86.
- [2] 宋超, 郝金明. GPS 设备海上动态定位精度检测新方法[J]. 测绘科学技术学报, 2012, 29(3):183-187,191.
- [3] 徐绍铨. GPS 测量原理及应用(修订版)[M]. 武汉:武汉大学出版社, 2003.
- [4] 宁津生,姚宜斌,张小红.全球导航卫星系统发展综述[J].导航定位学报, 2013, 01(1): 3-8.
- [5] 叶世榕. GPS 非差相位精密单点定位理论与实现[D]. 武汉:武汉大学, 2002.
- [6] Gao Y, Shen X. A new method for Carrier-Phase-based precise point positioning[J]. Navigation, 2002, 49(2): 109-116.
- [7] Geng J, Teferle F N, Meng X, et al. Kinematic precise point positioning at remote marine platforms [J]. GPS Solutions, 2010, 14(4): 343-350.
- [8] Chen K, Zamora N, Babeyko A, et al. Precise positioning of BDS, BDS/GPS: Implications for tsunami early warning in South China Sea [J]. Remote Sensing, 2015, 7(12):15955–15968.
- [9] 张小红, 何锡扬, 李星星. TriP 软件非差几何法精密定轨精度分析[J]. 武汉大学学报(信息科学版), 2010, 35(11):1327-1330.
- [10] 李星星, 张小红, 李盼. 固定非差整数模糊度的 PPP 快速精密定位定轨[J]. 地球物理学报, 2012, 55(3): 833-840.
- [11] Li X, Dick G, Lu C, et al. Multi-GNSS meteorology: Real-time retrieving of atmospheric water vapor from BeiDou, Galileo, GLONASS, and GPS observations[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(12):6385-6393.
- [12] Li X, Ge M, Dai X, et al. Accuracy and reliability of multi-GNSS real-time precise positioning: GPS, GLONASS, BeiDou, and Galileo [J]. Journal of Geodesy, 2015, 89(6):607–635.
- [13] Judah Levne. A review of time and frequency transfer methods[J]. Metrologia, 2008, 45(6): 162-174.
- [14] G Panfilo, P Tavella. Atomic clock prediction based on stochastic differential equations[J]. Metrologia, 2008, 45:108–116.
- [15] Senior K L, Ray J R, Beard R L. Characterization of periodic variations in the GPS satellite clocks [J]. GPS Solution, 2008, 12(3): 211-225.

- [16] 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.
- [17] 崔博斌.GNSS 卫星钟时频特性及预报算法研究[D].西安:长安大学,2018.
- [18] 胡伍生.神经网络理论及其工程应用[M].北京:测绘出版社, 2006.
- [19] 王国成, 柳林涛, 徐爱功, 等. 径向基函数神经网络在 GPS 卫星钟差预报中的应用[J]. 测绘学报, 2014, 43(8):803-807.

Satellite Clock Bias Prediction Algorithm with Multi System Based on RBF Neural Network

WANG Rui, CHAI Hong-zhou, PAN Zong-peng

PLA Information Engineering University, Zhengzhou 450001, Henan Province, China

Abstract: For real –time location applications, real –time data streams cannot be downloaded for maritime conditions. A satellite clock bias prediction algorithm based on RBF neural network is proposed, then this paper gives the calculation of the center of the basis function, the variance and the weight of the hidden layer to the output layer. The sliding window method is used to prediction the clock bias of the next epoch with the network trained by the sample data, and then train the network backwards until the whole time period is predicted. The availability of the algorithm is verified. In the short–term prediction, the GPS prediction accuracy is below 1 ns, and BDS and GLONASS are around 2 ns to 3 ns; in the long–term prediction, the GPS prediction accuracy is about tens of nanoseconds, while the BDS and GLONASS are in the hundreds of nanoseconds. Besides, the corresponding results analysis is given in this paper.

Key words: RBF; neural network; multi-system; satellite clock bias prediction; sliding window