

# 基于神经网络模型误差补偿技术的对流层延迟模型研究

陈 阳<sup>1</sup> 胡伍生<sup>1</sup> 严宇翔<sup>1</sup> 龙凤阳<sup>1</sup> 张 良<sup>1</sup>

1 东南大学交通学院,南京市进香河路 35 号,210096

**摘 要:** 针对传统对流层延迟模型精度较低的缺点,基于神经网络模型误差补偿技术,在 Hopfield 模型基础上建立一个适用于北半球的高精度融合模型。以 Wyoming 大学提供的 2010 年全球 120 多个观测站的气象探空数据精密解算的天顶对流层延迟(ZTD)作为近似“真值”,分析比较 Hopfield 模型、传统 BP 模型和融合模型的计算精度。结果表明,Hopfield 模型的均方根误差(RMSE)为 35.31 mm,传统 BP 模型为 30.34 mm,融合模型为 23.31 mm。

**关键词:** 气象探空数据;顶对流层延迟;误差补偿;神经网络;融合模型

**中图分类号:** P228 **文献标识码:** A

天顶对流层延迟(ZTD)模型大致可分为无实测气象参数的经验 ZTD 模型<sup>[1-5]</sup>和利用实测气象参数的气象参数 ZTD 模型<sup>[6-8]</sup>。前者方便用户使用,但精度难以满足精密工程测量需要;后者需要已知气象参数来计算对流层延迟,计算精度较高,主要有 Hopfield 模型、Saastamoinen 模型、Black 模型等。

对流层受到多种因素影响,存在很多不规则的变化。神经网络模型属于自适应非线性动力学系统,它具有学习、记忆、计算和智能处理功能,可从环境信息复杂、推理规则不明确的非线性空间中挖掘出隐含的规律。有学者利用神经网络建立模型进行对流层延迟变化的拟合<sup>[9-10]</sup>。模型误差一直是测绘领域待解决的难题之一,许多学者对此进行了研究,研究方法主要包括附加系统参数方法、最小二乘配置与推估、半参数模型等<sup>[11-13]</sup>。这些方法虽然取得了很大成效,但因受到人为假定函数关系的约束存在一定的局限性。对于形式简单的线性回归模型,这些方法的补偿

效果较好,但是对于复杂的非线性模型,补偿效果有待提高。

为解决传统 ZTD 模型精度较低这一难题,本文把神经网络和模型误差进行组合,形成基于神经网络的模型误差补偿技术,并建立了一个适用于北半球的高精度 ZTD 融合模型。

## 1 对流层延迟近似“真值”的获取

气象台站每天 08:00 和 20:00 各放飞一次高空探测气球来获得气象台站上空的气象资料。探测气球能获得一定等压面上的气象参数,包括温度、露点温度、风速风向和海拔高度。

本文利用 Wyoming 大学提供的北半球 120 多个测站 2010 年中具有代表性的 6 d 共 753 个气象探空数据进行研究。分析发现,在对流层及平流层范围内,各个气象参数所服从的函数模型与大气折射率随海拔高度呈现 3 段函数变化。因此,在求解对流层延迟时,将该层大气分为 3 段来考虑,具体积分过程如下:

$$\delta = \begin{cases} 10^{-6} \int_{h_0}^{1\,000} [N(h_0) - \Delta N h] dh, h_0 \leq h < 1\,000 m \\ 10^{-6} \int_{1\,000}^{11\,000} [N(1\,000) \times \exp[-c_1(h - 1\,000)]] dh, 1\,000 m \leq h < 11\,000 m \\ 10^{-6} \int_{11\,000}^{h_T} [N(11\,000) \times \exp[-c_2(h - 11\,000)]] dh, 11\,000 m \leq h < h_T \end{cases} \quad (1)$$

式中,  $h_0$  为测站处的海拔高度,  $h_T$  为对流层顶, 指大气折射率为 0 时的海拔高度,  $N(h)$  为海拔  $h$  处的大气折射率指数。

表 1 为测站 1028 (74. 50°N, 19. 00°E) 在 2010-01-01、03-01、05-01、07-01、09-01 和 11-01 每天 08:00 的气象探空数据和由大气理论公式计算的对流层延迟近似“真值”(ZTD\_TRU)。

表 1 测站 1028 的气象探空数据和 ZTD\_TRU  
Tab. 1 The meteorological sounding data of station 1028 and ZTD\_TRU

时间	海拔 高程 /m	地面 气压 /hPa	地面 温度 /℃	地面露 点温度 /℃	水汽压 / hPa	ZTD_TRU /mm
01-01	18	1 022	−0.5	−1.4	5.6	2 384.80
03-01	18	1 006	−5.1	−8.1	3.6	2 335.82
05-01	18	1 004	−5.9	−7.8	3.7	2 329.78
07-01	18	1 016	3.4	2.3	7.1	2 389.70
09-01	18	1 007	3.2	2.0	6.9	2 367.99
11-01	18	995	−1.7	−7.7	3.7	2 312.11

## 2 Hopfield 模型和 BP 神经网络基本原理

### 2.1 Hopfield 模型

Hopfield 模型将大气层分为对流层和电离层, 通过分析对流层中各个气象参数与海拔高度之间的关系, 推导出大气折射率指数和高程的关系, 然后利用地面气象参数进行整个对流层延迟的计算。

折射率指数与大气压强、温度和水汽分压较为准确的一种计算公式为:

$$N(h) = 77.6 \times \frac{P_0}{T_0} \times \left( \frac{H_T - h}{H_T - h_0} \right)^4 + 3.73 \times 10^5 \times \frac{e_0}{T_0^2} \times \left( \frac{H_w - h}{H_w - h_0} \right)^4 \quad (2)$$

式中,  $P_0$ 、 $h_0$ 、 $T_0$ 、 $e_0$  分别为测站处的气压、高程、绝对温度和水汽分压,  $H_w$  为湿对流层顶, 一般情况下  $H_w=11\,000\text{ m}$ 。

Hopfield 模型就是沿海拔高度积分并舍去微小项, 具体计算公式为:

$$\delta = 10^{-6} \times k_1 \times \frac{P_0}{T_0} \times \frac{H_T - h}{5} + 10^{-6} \times [k_3 + 273(k_2 - k_1)] \times \frac{e_0}{T_0^2} \times \frac{H_w - h}{5} \quad (3)$$

式中,  $k_1$ 、 $k_2$ 、 $k_3$  为一组大气折射实验常数, 通常由气象资料分析得到。本文分别取 77.60 K/mbar、64.79 K/mbar、 $3.776 \times 10^5\text{ K}^2/\text{mbar}$ 。

表 2 为测站 1028 在 2010-01-01、03-01、05-01、07-01、09-01 和 11-01 每天 08:00 通过 Hopfield 模型计算的天顶方向对流层延迟(ZTD\_HOP)。

表 2 测站 1028 的气象探空数据和 ZTD\_HOP  
Tab. 2 The meteorological sounding data of station 1028 and ZTD\_TRU

时间	海拔 高程 /m	地面 气压 /hPa	绝对 温度 /K	水汽压 /hPa	对流 层顶 /m	ZTD_HOP /mm
01-01	18	1 022	272.65	5.6	40 062	2 392.31
03-01	18	1 006	268.05	3.6	39 378	2 334.81
05-01	18	1 004	267.25	3.7	39 259	2 331.25
07-01	18	1 016	276.55	7.1	40 642	2 393.04
09-01	18	1 007	276.35	6.9	40 612	2 371.20
11-01	18	995	271.45	3.7	39 883	2 310.15

### 2.2 BP 神经网络基本原理

BP 神经网络是一种按误差反向传播算法训练的多层前馈网络, 它能学习和存储大量输入-输出模式的映射关系。BP 神经网络不需要事先确定数学方程, 而是通过反向传播误差不断调整网络的权值和阈值, 使网络的误差平方和最小。BP 神经网络模型不仅有输入层节点、输出层节点, 而且有隐含层节点。对于输入信号, 要先向前传播到隐含节点, 经过激活函数后, 再把隐含节点的输出信息传播到输出节点, 最后给出输出结果。

BP 神经网络模型的网络参数包括学习速率( $\eta$ )、平滑因子( $\alpha$ )、学习误差( $E$ )。 $\eta$  表示网络对学习样本进行训练学习时的速度, 如果  $\eta$  取大值, 则训练学习前期收敛速度快, 但后期容易震荡; 如果  $\eta$  取小值, 则训练学习前期收敛速度慢, 但后期容易稳定。 $\alpha$  可实现全局学习速率自适应, 加快收敛速度。 $E$  表示控制学习收敛的条件, 一般  $E$  越小, 检验中误差也越小, 但如果  $E$  过小, 会造成过拟合现象。

## 3 传统 BP 模型和融合模型的构建

### 3.1 传统 BP 模型

BP 神经网络中各层节点数的选择对网络的性能影响很大。传统 BP 模型的 3 个输入层节点分别为气压( $P$ )、温度( $T$ )和水汽压( $e$ )。隐含层节点的选择是一个十分复杂的问题, 对比分析后确定隐含层节点数为 15。输出层节点为利用大气基本理论公式求得的天顶方向对流层延迟(ZTD\_TRU)。采用控制变量法分析不同模型参数对训练模型精度的影响。经过大量实验, 确定传统 BP 模型学习速率( $\eta$ )取 1.4, 平滑因子( $\alpha$ )取 0.6, 学习误差( $E$ )取 0.09。传统 BP 模型的网络结构如图 1 所示。

### 3.2 融合模型

Hopfield 模型计算对流层延迟时的模型误差为:

$$DHOP = ZTD\_TRU - ZTD\_HOP \quad (4)$$




图 1 传统 BP 模型的网络结构

Fig. 1 The network structure of traditional BP model

式中,ZTD\_TRU 为根据大气理论公式计算的对流层延迟近似“真值”,ZTD\_HOP 为由 Hopfield 模型计算的天顶对流层延迟。

选择单隐含层模式,经过大量实验最终确定隐含层节点数为 25。输出层节点为 DHOP,表示对流层延迟近似“真值”(ZTD\_TRU)与 Hopfield 模型计算天顶对流层延迟(ZTD\_HOP)之差。融合模型的网络结构如图 2 所示。

4 实验结果与分析

4.1 实验结果

选取 Wyoming 大学提供的北半球 120 多个测站 2010 年有代表性的 6 d(共 753 个全球气象数据)验证融合模型的精度。从 120 多个测站中




图 2 融合模型的网络结构

Fig. 2 The network structure of fusion model

均匀选取 50 个作为学习测站进行神经网络的建模,剩下 70 多个测站作为检验测站来检验融合模型精度。

用平均偏差(BIAS)和均方根误差(RMSE)作为模型精度评价标准,计算公式为:

$$BIAS = \frac{1}{N} \sum_{i=1}^N (ZTD_i^C - ZTD\_TRU) \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (ZTD_i^C - ZTD\_TRU)^2} \quad (6)$$

式中,N 为测试样本数量,ZTD<sub>i</sub><sup>C</sup> 为模型计算值,ZTD\_TRU 为真值。

对这 6 d 分别进行建模分析,Hopfield 模型、传统 BP 模型和融合模型计算检验样本的精度指标具体结果如表 3 所示,BIAS 分布情况如图 3 所示。

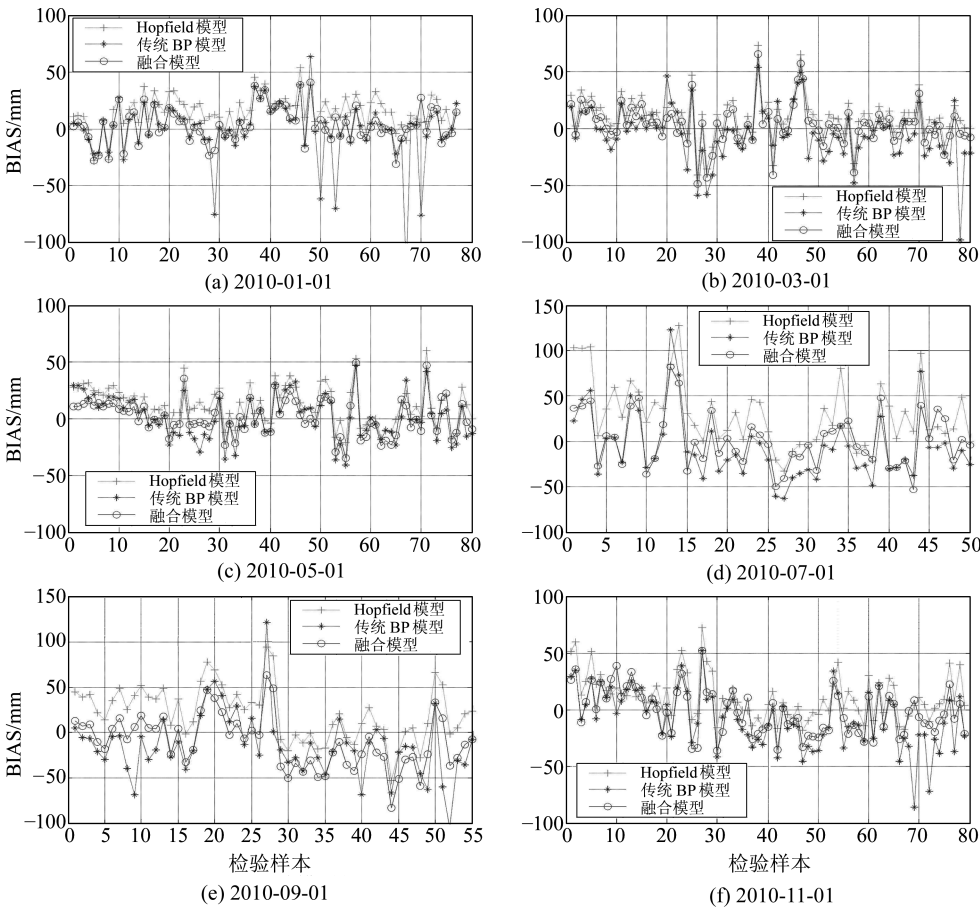


图 3 3 种模型的 BIAS 分布情况  
Fig. 3 BIAS distribution of three models

表 3 检验样本的精度指标

Tab. 3 The accuracy of the test sample

时间	Hopfield 模型		传统 BP 模型		融合模型	
	BIAS /mm	RMSE /mm	BIAS /mm	RMSE /mm	BIAS /mm	RMSE /mm
01-01	15.26	30.12	-1.32	31.64	3.05	22.65
03-01	10.04	20.49	-4.11	24.32	1.93	18.01
05-01	12.39	27.14	0.13	26.72	0.96	18.98
07-01	30.95	48.27	-5.46	34.96	2.20	29.72
09-01	22.81	55.10	-12.41	38.65	-9.09	30.04
11-01	11.12	30.76	-8.16	26.42	-2.14	20.25
平均值	17.10	35.31	-5.22	30.34	-3.09	23.31

4.2 结果分析

分析表 3 和图 3,得到如下结论:

1)相比传统 BP 模型和融合模型,Hopfield 模型的绝对偏差最大,存在检验样本点整体的 BIAS 都大于 0 的现象,说明 Hopfield 模型在计算 ZTD 时存在一定的系统误差。

2)融合模型的 RMSE 最小,为 23.31 mm。传统 BP 模型在 01-01 和 03-01 的 RMSE 大于 Hopfield 模型,其余 4 d 模型精度都优于 Hopfield 模型。可能是因为这 2 d 传统 BP 模型的训练存在过拟合现象,导致预测误差偏大。Hopfield 模型的 RMSE 最大,为 35.31 mm。相比 Hopfield 模型精度,融合模型的精度提高约 34%。

3)Hopfield 模型的 BIAS 整体波动幅度十分明显,检验样本的 BIAS 都相对较大。相比 Hopfield 模型的 BIAS,传统 BP 模型除了 01-01 和 03-01 存在几个检验样本 BIAS 较大之外,整体波动幅度较小,相对比较稳定。融合模型的 BIAS 波动均比较稳定。相比 Hopfield 模型和传统 BP 模型,融合模型在检验样本的 BIAS 相对靠近 0 值。

5 结 语

本文通过提取 Wyoming 大学提供的北半球 120 多个测站 2010 年中 6 d(共 753 个气象探空数据)的对流层延迟“真值”,分析 Hopfield 模型、传统 BP 模型和融合模型的精度。结果表明,融合模型精度较 Hopfield 模型有显著提高。不仅证明了基于神经网络模型误差补偿技术应用于对流层延迟模型误差的可行性,同时也说明本文构建的融合模型精度较 Hopfield 模型和传统 BP 模型有明显改善。

参考文献

[1] Leandro R F, Langley R B, Santos M C. UNB3m\_Pack: A Neutral Atmosphere Delay Package for Radiometric Space

Techniques[J]. GPS Solutions, 2008, 12(1): 65-70

[2] Penna N, Dodson A, Chen W. Assessment of EGNOS Tropospheric Correction Model[J]. Journal of Navigation, 2001, 54(1): 37-55

[3] 李薇,袁运斌,欧吉坤,等. 全球对流层天顶延迟模型 IG-Gtrop 的建立与分析[J]. 科学通报, 2012, 57(15):1 317-1 325(Li Wei, Yuan Yunbin, Ou Jikun, et al. A New Global Zenith Tropospheric Delay Model IGGtrop for GNSS Applications [J]. Chinese Science Bulletin, 2012, 57(15): 1 317-1 325)

[4] 姚宜斌,何畅勇,张豹,等. 一种新的全球对流层天顶延迟模型 GZTD[J]. 地球物理学报, 2013, 56(7):2 218-2 227 (Yao Yibin, He Changyong, Zhang Bao, et al. A New Global Zenith Tropospheric Delay Model GZTD [J]. Chinese Journal of Geophysics, 2013, 56(7):2 218-2 227)

[5] Böhm J, Möller G, Schindelegger M, et al. Development of an Improved Empirical Model for Slant Delays in the Troposphere (GPT2w)[J]. GPS Solutions, 2015, 19(3): 433-441

[6] Hopfield H S. Two-Quartic Tropospheric Refractivity Profile for Correcting Satellite Data[J]. Journal of Geophysical Research Atmospheres, 1969, 74(18):4 487-4 499

[7] Saastamoinen J. Atmospheric Correction for the Troposphere and Stratosphere in Radio Ranging Satellites[J]. Use of Artificial Satellites for Geodesy, 1972, 15 (6): 247-251

[8] Black H D. An Easily Implemented Algorithm for the Tropospheric Range Correction[J]. Journal of Geophysical Research: Solid Earth, 1978, 83(B4): 1 825-1 828

[9] 朱明晨,赵平,陈伟荣. 基于 BP 神经网络的霍普菲尔德模型改进研究[J]. 测绘工程, 2016, 25 (9): 26-30 (Zhu Mingchen, Zhao Ping, Chen Weirong. Improved Research for Hopfield Model Based on BP Neural Network [J]. Engineering of Surveying and Mapping, 2016, 25(9):26-30)

[10] 胡伍生,张志伟. 模型误差补偿的神经网络方法研究[J]. 测绘科学, 2010, 35(增 1):48-51 (Hu Wusheng, Zhang Zhiwei. Study on the Method for Compensating Model Error Based on Neutral Network [J]. Science of Surveying and Mapping, 2010, 35(S1):48-51)

[11] 丁士俊,陶本藻. 自然样条半参数模型与系统误差估计[J]. 武汉大学学报:信息科学版, 2004, 29(11):964-967 (Ding Shijun, Tao Benzao. Semiparametric Regression Model with Natural Spline and Systematic Error Estimation [J]. Geomatics and Information Science of Wuhan University, 2004, 29(11):964-967)

[12] 孙海燕,吴云. 半参数回归与模型精化[J]. 武汉大学学报:信息科学版, 2002, 27(2):172-174(Sun Haiyan, Wu Yun. Semiparametric Regression and Model Refining[J]. Geomatics and Information Science of Wuhan University, 2002, 27(2):172-174)

[13] 高宁,高彩云,徐长海. 补偿最小二乘估计在确定高程异常中的应用[J]. 测绘科学, 2011, 36(1):35-37(Gao Ning, Gao Caiyun, Xu Changhai. Application of Penalized Least Squares Estimation in Height Anomaly [J]. Science of Surveying and Mapping, 2011, 36(1):35-37)