

doi: 10.3969/j.issn.1000-8349.2024.03.08

基于 BP 神经网络的 FAST 馈源舱 融合测量预测研究

卢朝茂¹, 李明辉¹, 宋本宁², 彭帅¹, 冯禹¹, 于东俊², 骆亚波³

(1. 贵州大学 省部共建公共大数据国家重点实验室, 贵阳 550025; 2. 中国科学院 国家天文台, 北京 100101;
3. 长沙理工大学, 长沙 410114)

摘要: 500 m 口径球面射电望远镜 (Five-hundred-meter Aperture Spherical Radio Telescope, FAST) 的跟踪观测需要馈源的空间运动配合, 馈源舱主要用于实现馈源的精调定位, 因此馈源舱位置的高精度测量对 FAST 望远镜的高效运行意义重大。但当全站仪设备失效时, 无法对采用 Kalman 算法的 GPS/IMU 融合测量结果进行修正, 导致馈源舱测量精度下降。为了解决这个问题, 设计了基于 BP (back propagation) 神经网络的预测模型, 包括数据预处理、模型设计和模型训练验证。模型训练数据为 FAST 真实测量数据, 数据量为 40 GB 左右。为了验证模型的泛化能力, 选取三种运动轨迹数据对模型预测精度进行测试, 结果显示, 三种运动轨迹下精度都满足 15 mm 要求。

关键词: FAST; 馈源舱融合测量预测; 数据预处理; BP 神经网络; 时间序列

中图分类号: P111.44 **文献标识码:** A

1 引言

500 m 口径球面射电望远镜 (Five-hundred-meter Aperture Spherical Radio Telescope, FAST) 被誉为“中国天眼”, 它是国家“十一五”重大科学工程, 是世界上最灵敏的单口径射电望远镜^[1]。FAST 望远镜已开放运行 4 年, 但仍在做技术优化和升级。馈源舱作为望远镜的核心部件, 它的测量精度直接影响望远镜的指向精度。因此, 研制一种高精度、高可靠性和实时性的馈源舱融合测量系统, 对 FAST 正常运行和升级改造具有重要意义。

目前, FAST 馈源舱采用全球卫星定位系统 (Global Positioning System, GPS) 与惯性测量单元 (inertial measurement unit, IMU) 相融合的测量技术, 采用卡尔曼 (Kalman) 算

收稿日期: 2024-01-16; 修回日期: 2024-02-04

资助项目: 国家自然科学基金 (12363010, 42274055); 贵州省科技计划项目 (黔科合基础-ZK[2023] 一般 039, 黔科合支撑 [2023] 一般 352)

通讯作者: 李明辉, limh@gzu.edu.cn

法进行融合计算。其中 IMU 通过融合测量方法将定位精度提高 30% 以上^[2-5]。同时 FAST 馈源舱还采用全站仪 (total station, TS) 设备对融合测量结果进行补偿修正。然而, 由于 TS 设备受到仪器精度、地球曲率、大气折射、天气等因素的限制, 导致目标丢失等问题的产生^[6-8]。根据 FAST 望远镜现场工作人员对 TS 有效工作时长的统计, TS 平均丢失率为 27.16%^[9-10]。本文提出通过研究 GPS、IMU 和 Kalman 融合测量的历史数据, 建立合适的预测模型, 对馈源舱进行位置时间序列预测, 以解决 TS 丢失时馈源舱位置测量精度问题。

时间序列是某一客观现象数据按时间顺序排列而成的序列, 馈源舱测量的数据即时间序列。传统的时间序列经验模型, 如自回归模型、最小二乘法和指数平滑等, 基于理论经验构建数学模型, 但对于规律性较弱的时间序列, 其预测能力有所不足^[11-13]。近年来, 随着人工智能的发展, 数据驱动的时间序列预测模型在处理无规律性时间序列方面取得了显著进展。机器学习和深度学习方法能够从大规模数据中提取特征, 构建非线性映射关系, 因此在解决无规律轨迹预测问题上, 其具有独特优势^[14]。

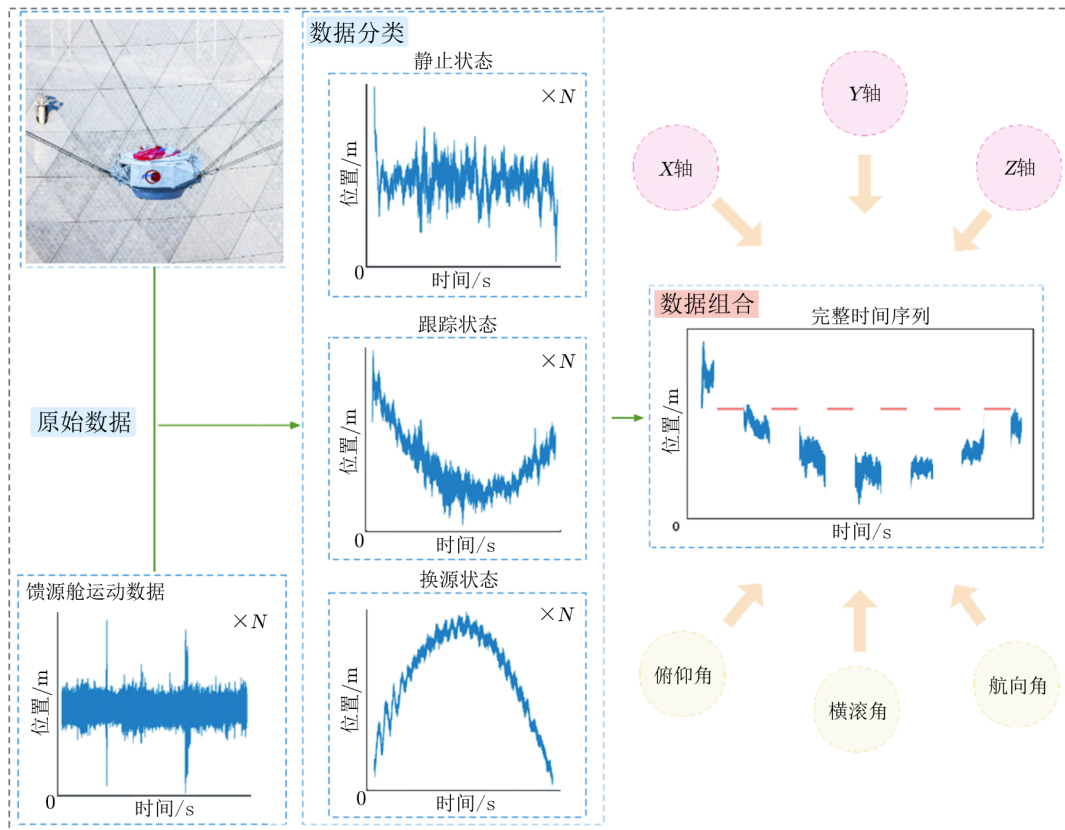
神经网络具有高度非线性的映射能力, 能够更好地捕捉时间序列内部的复杂关联, 适用于处理 FAST 馈源舱测量任务中难以预测的复杂轨迹模式。因此, 本文采用 BP (back propagation) 神经网络与时间序列模型的混合模型, 构建一种馈源舱融合测量的预测模型, 并利用实测数据进行验证。

2 数据预处理

为了提高预测模型的性能和准确性, 需要对参与模型训练的 GPS、IMU 和 Kalman 融合测量结果的数据进行预处理。主要包括两个过程 (见图 1): (1) 数据采样频率统一; (2) 跟踪状态数据提取。首先, 进行数据完整性和频率统一处理。部分测量设备数据丢失是测量设备短时失效所导致的。各种设备的数据频率不一致, GPS 设备的测量频率和数据存储频率都是 10 Hz, IMU 设备的测量频率是 400 Hz, 数据存储频率是 100 Hz。其次, 按照馈源舱运动模式将数据进行分类。馈源舱的运动模式分为静止状态、跟踪状态和换源状态。这三种状态的判断依据是馈源舱速度值。如果速度在零值附近且持续时间大于 300 s, 即为静止状态。馈源舱静止状态时, 其速度也不是零, 因为牵拉馈源舱运动的柔性钢索受到风激后会产生轻微的振动, 振动传递给馈源舱后, 馈源舱也会随着振动。当速度值突然增大且超过 0.1 m/s, 则为换源状态。剩余为跟踪状态 (见图 2)。跟踪状态在总运动中占比最长, 所以本文对跟踪状态的测量数据进行 BP 预测。通过以上对馈源舱各运动状态速度的分析, 提取出跟踪模式下的数据, 为后文对馈源舱位置时间序列预测模型的训练和验证提供数据准备。


3 BP 神经网络预测模型设计

神经网络是一种高度非线性、大规模的连续时间动态系统。在馈源舱融合测量中, 单个测量设备的测量结果与融合测量结果之间的差值, 是通过非线性公式计算所得。同时, 为了保证预测精度, 本文随机选取 5 个月的测量数据 (大于 30 GB) 进行模型训练和验证, 采



注: 左侧表示馈源舱运动状态, 右侧表示数据丢失情况。

图1 数据的预处理流程



注: 依照速度值区分换源和跟踪状态, 换源状态速度大于 0.1 m/s。

图2 换源和跟踪时间与位置的分布

用 1 个月的数据（大于 6 GB）对模型精度进行测试。因此，本研究内容与神经网络的非线性和大规模连续时间性的特点相符合，可以采用神经网络作为预测模型。在神经网络模型中，BP 神经网络是最具代表性且使用最广泛的神经网络模型之一，其具有并行计算和自适应学习能力。BP 神经网络由输入层、隐藏层和输出层构成，隐藏层根据实际需求可由多层网络和多个神经元构成。网络中每一层神经元只与相邻两层的神经元形成完整的连接，与同一层的神经元无连接。

3.1 馈源舱测量预测模型搭建

参与融合测量预测模型训练的数据均为 FAST 坐标系下各种测量设备的真实测量数据。输入层包括 9 类数据，分别是 GPS 接收机的位置信息 X_G 、 Y_G 、 Z_G 值；IMU 测量的馈源舱位置信息 X_I 、 Y_I 、 Z_I 值； T_0 时刻 Kalman 融合结果 X_{T_0} 、 Y_{T_0} 、 Z_{T_0} 。输出层包括 3 类数据，为神经网络融合测量预测 T_1 时刻的馈源舱位置信息 X_{T_1} 、 Y_{T_1} 、 Z_{T_1} 值。隐藏层神经元采用 Sigmoid 作为激活函数，以达到模型的非线性运算。根据训练和验证效果，最终确定网络的输入层为 1 层、隐藏层为 4 层、输出层为 1 层，输入层节点数为 9，隐藏层每层节点数为 10，输出层节点数为 3（见图 3）。网络参数设置，一次数据样本抓取数 (batch_size) 为 256，训练次数 (epoch) 为 30，学习率 (learning_rate) 为 0.001，神经元参数权重衰退 (weight_decay) 为 0.001。

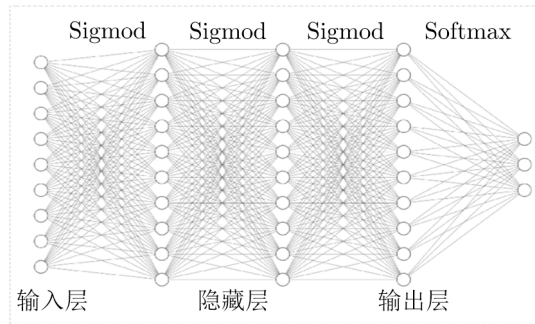


图 3 神经网络的结构

3.2 神经网络融合测量模型的算法流程说明

BP 神经网络的算法流程由正向传播和反向传播构成（见图 4）。在正向传播过程中，将 GPS 和 IMU 测量值、 T_0 时刻 Kalman 融合结果赋值给输入层神经元，然后通过隐含层神经元的权重和偏置进行加权求和，其计算公式为：

$$z = \sum_{i=0}^{10} \sum_{j=1}^9 \omega_{ij} x_j = \omega^T x, \quad (1)$$

其中， ω_{ij} 是隐藏层神经元的权重，下标 ij 表示第 j 层第 i 个神经元， x 是输入层数据向量。

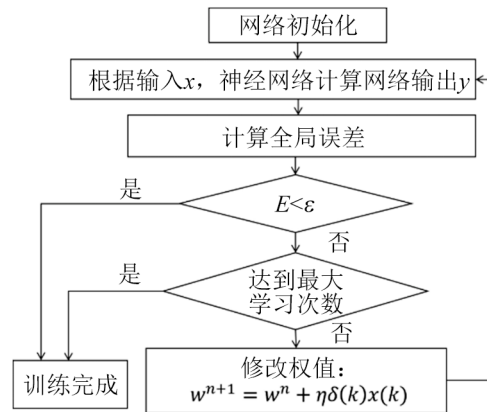


图 4 BP 神经网络的算法流程

再通过 Sigmoid 函数完成非线性计算, 其表示为:

$$y = f_{\text{sigmoid}}(\omega^T x) \quad (2)$$

经过网络一次计算后, 得到 T_1 时刻馈源舱位置预测值, 但是此时的位置值是由神经元初始权重和偏置计算得到的; 再将 T_1 时刻馈源舱位置预测值与 T_1 时刻 Kalman 融合结果进行均方根误差计算, 计算公式为:

$$E = \frac{1}{2m} \sum_{k=1}^m \sum_{o=1}^3 (d_o(k) - y_o(k))^2 \quad (3)$$

其中, d_o 是 T_1 时刻 Kalman 融合结果, y_o 是 T_1 时刻馈源舱位置预测值。

当均方根误差值 E 大于阈值 ε 时, 将进行反向传播。本次搭建的预测网络的阈值设定为 15 mm, 因为 Kalman 融合测量结果与全站仪之间的误差设定为 15 mm。

在 BP 神经网络反向传播过程中, 使用梯度下降算法修正网络隐藏层各个神经元的权重和偏置参数, 梯度下降算法采用求导链式法则, 表示为:

$$\frac{dE}{dw} = \frac{dE}{dy} \frac{dy}{dz} \frac{dz}{dw} \quad (4)$$

然后在正向传播中, 使用新的权重和偏置参数计算新一次迭代的馈源舱位置信息, 使其更靠近 T_1 时刻 Kalman 融合结果。程序将正向传播与反向传播迭代, 直到误差小于阈值或者网络达到最大学习次数, 程序停止。

4 实例分析

4.1 训练测试数据介绍

参与 BP 神经网络训练的数据来源于 FAST 馈源舱的真实数据, 数据的起止时间为 2023 年 1 月—2023 年 6 月, 总数据量约 40 GB。测量原始数据是按观测任务划分文件的,

一个观测任务对应一个文件，每个文件中的数据基本包括设备失效导致的大跳变数据、文件开启等待观测任务执行的0值数据和有效测量数据，有效测量数据又分为静止、跟踪和换源三种状态数据。首先进行大跳变数据和0值数据的清除，然后采用上文提到的速度辨识法，提取出跟踪状态测量数据。为了便于数据排序，将2023年1月1日0时0分设定为0时刻；同时为了提高模型训练效率，采用窗口平均法将数据频率由0.1 s降到1 s。

对静止和换源的删除造成了很多时间段的空缺，使得剩余数据不连续。为解决这个问题，对数据进行遍历并计算相邻两数据点时间差。当时间差大于0.3 s（统计值），在数据头尾加上标记，然后按时间顺序和标记将数据划分为时间连续的数据文件。

4.2 模型训练和验证过程

选取一个月的测量数据对模型进行训练和验证，其中随机选取数据的80%作为训练集，20%作为验证集。选取另一组数据用于测试模型的预测精度。依次交替，最终保证6个月的数据都被用于训练过，以保证模型的泛化能力。为了防止模型过拟合，模型采用L2正则化和批处理方法，批处理方法还可以提高模型训练速度。

为了快速提取数据特征，程序创建了归一化器`Scaler_target.pkl`，并且将归一化器保存以便程序调用。归一化器将输入数据进行归一化处理，使不同类型数据具有相似的尺度和分布，进而消除不同特征间的差异。

4.3 融合测量模型预测结果分析

通过训练和验证得到满足15 mm的预测模型后，我们对模型进行测试。为了说明模型不仅满足预测精度，并且不存在过拟合现象，我们选取三种运动轨迹作为测试集，他们也代表了FAST望远镜三种不同类型的跟踪模式。第一种是馈源舱保持在某一方向上运动（数据集为283.csv，运动和测试结果如图5所示）， X 、 Y 、 Z 的单轴方向可以近似为直线运动，此类型运动相对简单；第二种是馈源舱近似在某一个方向上运动（数据集为258.csv，运动和测试结果如图6所示），但运动路径上不间断地短时折返， X 、 Y 、 Z 这3轴中有1~2个轴呈现不间断地短时折返，其他轴运动平滑；第三种是馈源舱运动为折返运动，但折返路径不重合（数据集为369.csv，运动和测试结果如图7所示）。由于目标值与预测值的差值远小于馈源舱运动范围，为了直观观察到误差变化情况，图8展示了数据集258.csv各轴误差情况。

我们选取了3组测试数据的预测 $RMSE$ 值（见表1），这3组的位置预测误差值都小于规定阈值15 mm。其中最大为数据集258.csv的馈源舱 X 轴位置预测值，其 $RMSE$ 为9.20 mm；最小为数据集283.csv的馈源舱 Y 轴位置预测值，其 $RMSE$ 为1.40 mm。从3组位置预测误差值可以知道，当馈源舱处于不间断短时折返的跟踪状态下，其预测误差值最大；当馈源舱的跟踪路径近似直线时，其预测误差值最小。此结论可以作为预测模型后续升级改造的理论储备。

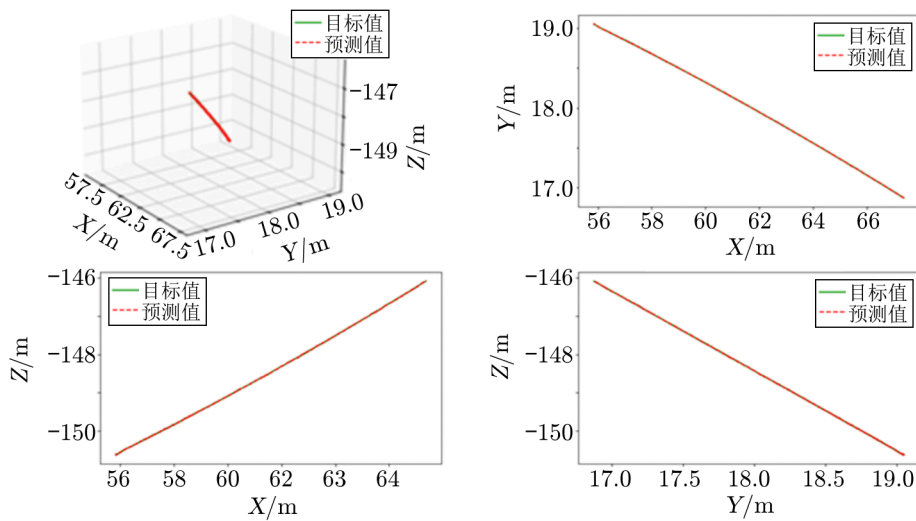


图 5 馈源舱保持在某一方向上运动 (数据集为 283.csv)

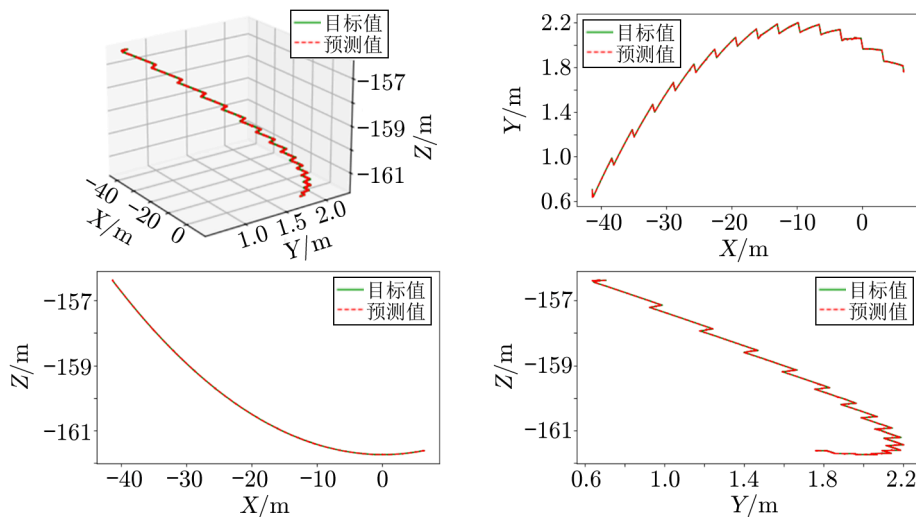


图 6 馈源舱运动路径上有不间断的短时折返 (数据集为 258.csv)

5 总结与展望

针对 FAST 馈源舱融合测量中, 由于全站仪失效导致无法对 Kalman 融合算法结果进行修正的问题, 本文提出基于 BP 神经网络的馈源舱融合测量预测方法。本文主要由三部分组成: 数据预处理、BP 神经网络预测模型设计和实例分析。数据预处理后, 数据完整性、可用性提高, 使模型训练速度加快, 跟踪模式下的馈源舱位置值预测精度提高。BP 神经网络预测模型设计中, 网络基本架构根据测量设备的数据量确定, 不变参数根据模型训练过程中的收敛速度和过拟合程度进行修改。最后, 对训练好的模型进行实证数据测试, 测试结果

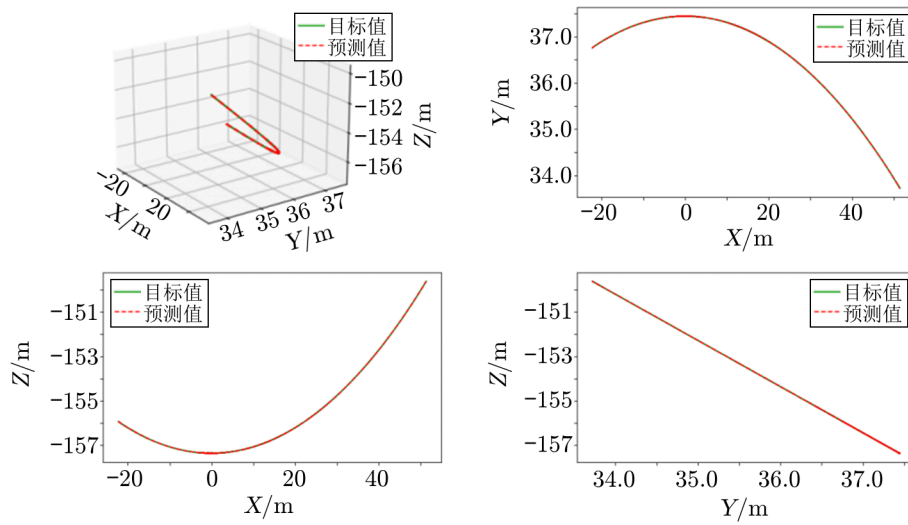


图 7 馈源舱运动为折返运动，但折返路径不重合（数据集为 369.csv）




图 8 测试数据集 258.csv 三轴上的误差值

表 1 3 组馈源舱位置信息预测结果

数据集	X、Y、Z	RMSE/mm
283.csv	X	1.40
	Y	1.40
	Z	1.80
258.csv	X	9.20
	Y	8.50
	Z	3.20
369.csv	X	5.30
	Y	2.50
	Z	3.00

良好, 满足均方根误差小于 15 mm 的要求。

未来我们会在本模型基础上继续优化, 例如, 增加输入层神经元, 对馈源舱姿态信息进行预测; 对全模式状态进行预测, 即对静止、跟踪、换源的混合数据进行预测模型搭建; 只用 IMU 数据作为输入数据进行预测, 因为随着卫星数量的增加, GPS 设备受到干扰的频率也在增加, 这导致 GPS 的测量结果不可信。

致谢

感谢贵州大学省部共建公共大数据国家重点实验室提供算力支持; 感谢国家天文台 FAST 运行与发展中心提供数据支持; 感谢长沙理工大学提供技术指导。

参考文献:

- [1] 李明辉, 姜鹏, 于东俊, 等. 天文学报, 2021, 62: 113
- [2] Farrell J A, Barth M. The Global Positioning System and Inertial Navigation. UK: McGraw-Hill House, 1999: 340
- [3] Nassar S, El-Sheimy N. Gps Solutions, 2006, 10(1): 29
- [4] Wang G, Chong P H J, Seet B C, et al. Materials Science and Engineering, 2018, 394: 032110
- [5] Tang X, Liang J, Sun H, et al. International Conference on Railway Engineering, 2012, 15: 938
- [6] Chen F, Bai M Z, Gao L, et al. New Technologies of Railway Engineering. Beijing: China Railway Publishing House, 2012: 8
- [7] 赖涛, 魏玺章, 黄海风, 等. 系统工程与电子技术, 2022, 44(01): 10
- [8] 林武. 硕士论文, 南京: 南京理工大学, 2021: 7
- [9] 李明辉. 博士论文, 北京: 中国科学院大学, 2021: 7
- [10] Li M H, Jiang P, Yu D J, et al. RAA, 2020, 20(9): 9
- [11] 陈雪. 信息与电脑, 2022, 34: 160
- [12] Gardner E S. Journal of Forecasting, 1985, 4(1): 1
- [13] Lim B, Zohren S. Philosophical Transactions of the Royal Society A, 2021, 379: 2020
- [14] Paranjothi A, Khan M, Nijim M. Journal of Computer and Communications, 2017, 5(6): 1

Research on Fusion Measurement Prediction of FAST Feed Cabin Based on BP Neural Network

LU Chao-mao¹, LI Ming-hui¹, SONG Ben-ning², PENG Shuai¹, FENG Yu¹,
YU Dong-jun², LUO Ya-bo³

(1. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China; 2. National Astronomical Observatories, Chinese Academy of Sciences, Beijing 100101, China; 3. Changsha University of Science and Technology, Changsha 410114, China)

Abstract: When the Five-hundred-meter Aperture Spherical Radio Telescope (FAST) performs the tracking observation task, for cooperating with this task, the feed has got spatial motion. The fine-tuning positioning of the feed is realized by the feed cabin, so the high-precision measurement of the position of the feed cabin is great significance. However, when the total station equipment fails, it is unable to correct the GPS/IMU fusion measurements with the Kalman algorithm, it causes the accuracy of the feed cabin measurements decreasing. In order to solve this problem, this paper designs a prediction model based on BP neural network, which is composed of three parts, the data preprocessing, the model design and the model training validation. And the model training data is the real measurement data of FAST with a data volume of about 40 GB. In order to verify the generalization ability of the model, three kinds of motion trajectory data are selected to test the model prediction accuracy, and the results show that the accuracy meets the 15 mm requirement under three kinds of motion trajectories.

Key words: FAST; feed cabin fusion measurement prediction; data preprocessing; BP neural network; time series