

## 基于非线性自回归神经网络的局部大气密度预测方法

常欣卓<sup>1,2</sup>, 杨开忠<sup>2</sup>, 李新<sup>1</sup>, 沈红新<sup>2</sup>, 李恒年<sup>2</sup>

(1. 中国科学技术大学数学科学学院, 安徽合肥 230026; 2. 宇航动力学国家重点实验室, 陕西西安 710043)

**摘要:** 由于现有大气密度模型精度不足, 在对低轨卫星定轨和轨道预报时容易产生较大误差, 而观测手段的缺乏以及对高层大气物理机理缺乏足够了解给大气密度模型的建立带来了一定的困难. 提出了利用神经网络来建立大气密度预测模型. 首先, 利用两行轨道根数对 NRLMSISE-00 大气模型校准得到沿轨道的局部化密度模型, 然后基于非线性自适应回归神经网络(NARX)构建大气密度预测模型. 该模型主要结合校准后 MSIS 模型以及太阳与地磁活动指数来预测未来一段时间内局部大气密度. 将该模型应用于不同的卫星轨道数据, 进行了多个时间段的模拟试验. 与卫星实测密度的比对结果显示, 相对于 MSIS 密度模型, 该模型的预测误差有了一定的减小, 为提高低轨卫星短期轨道预报精度提供了思路.

**关键词:** 低轨卫星; 大气密度; 轨道预报; NARX 神经网络

**中图分类号:** V525      **文献标识码:** A      doi: 10.3969/j.issn.0253-2778.2017.12.007

**引用格式:** 常欣卓, 杨开忠, 李新, 等. 基于非线性自回归神经网络的局部大气密度预测方法[J]. 中国科学技术大学学报, 2017, 47(12): 1015-1022.

CHANG Xinzhuo, YANG Kaizhong, LI Xin, et al. Localized atmospheric density prediction method based on NARX neural network[J]. Journal of University of Science and Technology of China, 2017, 47(12): 1015-1022.

## Localized atmospheric density prediction method based on NARX neural network

CHANG Xinzhuo<sup>1,2</sup>, YANG Kaizhong<sup>2</sup>, LI Xin<sup>1</sup>, SHEN Hongxin<sup>2</sup>, LI Hengnian<sup>2</sup>

(1. School of Mathematical Sciences, University of Science and Technology of China, Hefei 230026, China;

2. State Key Laboratory of Astronautic Dynamics, Xi'an 710043, China)

**Abstract:** Errors of orbit determination and prediction for low earth orbit (LEO) satellites mainly arise from the lack of accuracy in existing atmospheric density models. The lack of observation methods and insufficient understanding of physical mechanism of the upper atmosphere have brought difficulties to the modelling of atmospheric density. Two line element (TLE) was used to calibrate the MSIS atmospheric model, aiming at getting a localized density model along the orbit. Then a predictor was built based on the nonlinear autoregressive neural network with exogenous inputs (NARX). It uses calibrated MSIS model and a set of proxies of solar and geomagnetic activities to predict localized density values along the future orbit of a satellite. This model was applied for different types of satellite orbits and tested for different prediction windows. Comparison with the predictor based on the MSIS model shows a decrease in the mean error of the proposed model, which throws new light on improving the accuracy of LEO satellites' short-

收稿日期: 2017-03-15; 修回日期: 2017-06-02

作者简介: 常欣卓, 男, 1989年生, 硕士生. 研究方向: 轨道动力学、机器学习方法. E-mail: chxz@mail.ustc.edu.cn

通讯作者: 李新, 博士/副教授. E-mail: lixustc@ustc.edu.cn

time prediction.

**Key words:** low earth orbit satellite; atmospheric density; orbit prediction; nonlinear autoregressive neural network with exogenous inputs (NARX)

## 0 引言

目前在轨卫星大多数是低地球轨道(low earth orbit, LEO)卫星,大气阻力是除了地球引力之外对其轨道影响最重要的因素.卫星在大气阻力的影响下,其轨道高度会随着时间的推移而不断降低.大气阻力受到高层风、阻力系数、卫星迎风面积和质量比(简称面质比)、大气密度等因素的影响,而大气密度是其中最难以精确估计的一项.大气密度随着空间的不同而不断变化,而且由于受太阳活动的影响,还呈现出日周期变化(地球自转引起的日夜循环)、月周期变化(太阳旋转周期)、季节周期变化(太阳与地球位置变化)以及 11 年周期变化(即太阳黑子爆发周期)<sup>[1]</sup>.建立精确的大气密度模型成为低轨卫星轨道确定与轨道预报的关键性因素之一.因此,有效估计和预测大气密度成为了一个十分重要的课题.

目前普遍采用的大气密度模型有 Jacchia 系列、MSIS 系列以及 DTM 系列等经验大气密度模型,其中应用最广泛的是 Jacchia 系列和 MSIS 系列. Jacchia 系列模型最初被用于模拟大气温度,后来经过不断改进,发展成为了全球大气模型,目前最新发布的版本是 JB2008 (Jacchia-Bowman 2008)<sup>[2]</sup>. MSIS 系列<sup>[3]</sup>利用非相干散射雷达和星载仪器测量数据建立得到全球大气模型,最新版本是由美国海军实验室于 2000 年发布的 NRLMSIS-00 (Naval Research Laboratory Mass Spectrometer And Incoherent Scatter Radar Extended)模型<sup>[4]</sup>.总体而言,在太阳活动平静期,现有大气模型对于大气密度的估计误差范围在 15%~30%之间<sup>[5]</sup>,当出现极端天气时,模型误差可达到 100%甚至更高.

为了提高大气密度模型的精度,主要的方法就是利用卫星轨道数据或者卫星搭载载荷在太空中采集到的相关数据来对现有大气密度模型进行修正.两行轨道根数(two line element, TLE)数据时间记录跨度大、空间覆盖广,为修正大气密度模型提供了良好的数据源.目前,国外学者 Picone, Emmert 以及 Doornbos 等<sup>[7-9]</sup>在这方面已取得了一定的研究

成果.国内学者任廷领等<sup>[10]</sup>根据该方法在不同高度不同特征的卫星轨道上进行了实验,结果表明:反演得到密度与参考密度(加速度计数据计算得到的大气密度)符合较好.然而由于多数低轨卫星 TLE 数据每天只更新 1 次,因此反演得到的密度只是一个时间区间内的平均值,并不能完全反映其随时间空间变化的趋势.苗娟等<sup>[11]</sup>以神舟飞船探测数据为基础,提出了一种基于实时大气密度观测数据的修正方法.考虑维度与地方时 2 个因素,建立了一种平均误差修正方法,提高了大气密度估计的精度.陈旭杏等<sup>[12]</sup>则进一步考虑了地方时、经纬度、太阳活动等因素对模型进行修正,也显示出较好的结果.此外,美国的高精度密度模型(the high accuracy satellite density model, HASDM)<sup>[13]</sup>根据美国空间监视网(Space Surveillance Net, SSN)的 75 颗校准卫星的轨道观测数据,来校准 Jacchia 模型,模型精度较高.但是该方法依赖于对一系列广泛分布在空间中的校准卫星进行精密定轨,成本难以控制.

此外,还可以利用高精度的星载仪器直接测量由大气密度变化引起的阻碍卫星运动的大气阻力,从而计算得到实时的大气密度.德国和美国发射的 CHAMP (Challenging Mini-Satellite Payload) 和 GRACE (Gravity Recovery and Climate Experiment) 卫星上搭载了高精度加速度计,可以较为精确地估计出大气阻力<sup>[6]</sup>.该方法得到了目前被认为是最准确的密度数据,也经常被用作真实密度.然而由于设备的成本较高,此类数据的空间和时间覆盖较小,无法满足实际需要.

在大气密度预测方面,文献[14]提出了一种利用 CHAMP 卫星的加速度计反演密度数据,基于线性化模型沿着其卫星轨道进行大气密度预测的方法.结果表明:在预测时间小于 1 个轨道周期时,模型预测偏差要小于 HASDM 和 JB2008.文献[15]则是基于神经网络来进行大气密度的预测,同样使用上述数据,结果表明:在预测时间小于 2 d 时,模型偏差小于 HASDM 和 JB2008,也优于文献[14]使用的模型.然而不足在于,无论是构建线性化模型还是

搭建神经网络,都需要有准确的大气密度作为目标值来对模型进行修正,才能得到较好的预测性能.而如上一段所述,目前满足这样要求的只有 CHAMP, GRACE 等少数卫星,所以难以在工程实际中应用他们的成果,但是可以从中看到将神经网络应用到此类问题上的巨大潜力.

本文基于非线性自回归神经网络(Nonlinear Autoregressive Neural Network With Exogenous Inputs, NARX)<sup>[16-17]</sup>对大气密度进行预测,将使用 TLE 校准过的大气密度数据以及太阳和地磁活动指数分别作为网络的目标值与外部输入值进行训练,并将计算得到的预测密度与参考密度进行比较,从而评价本文提出模型的准确性.

## 1 大气密度反演和校准方法

TLE 轨道根数是北美防空联合司令部(north american aerospace defense, NORAD)利用空间探测网对空间物体进行跟踪观测,进而利用 SGP4 (simplified general propagation)模型计算得到平均开普勒轨道根数,低轨道目标精度一般在百米到千米量级.每一组 TLE 数据都包含了空间物体的编号、制造单位、历元时间以及一系列轨道根数. NORAD 空间目标库中存储了 29 000 多个空间物体约 640 万条 TLE 记录,部分空间物体从 1960 年就开始记录,有多达 50 多年的丰富数据,并且多数会每天更新一次,为利用空间物体轨道反演大气密度提供了大量有效数据<sup>[18]</sup>.

卫星在轨道中运行时,大气阻力产生的加速度为

$$\mathbf{a}_D = -\frac{1}{2}\rho B \mathbf{v}_r v_r \quad (1)$$

式中,  $\mathbf{a}_D$  是卫星的加速度;  $\rho$  为大气密度;  $B = C_d A/m$  为反弹道系数( $C_d$  为物体的表面阻力系数,  $A$  为迎风面积,  $m$  是物体的质量);  $\mathbf{v}_r = v_r$  为卫星相对在高空风下的速度.

大气阻力作用在卫星上主要表现在卫星的平均平运动  $n_M$  上,卫星轨道在大气作用下不断衰减,使得轨道半长轴  $a$  不断减小,从而导致卫星平均平运动  $n_M$  逐渐增加.考虑卫星的半长轴变化,可将半长轴的变化率分离成

$$\frac{da}{dt} = \frac{da_M}{dt} \Big|_D + \frac{da}{dt} \Big|_G + \frac{da}{dt} \Big|_{D-G} + \frac{da}{dt} \Big|_{SRP} \quad (2)$$

式(2)右边第 1 项是阻力引起的变化,后面几项依次为重力、阻力-重力耦合以及太阳光压(solar radiation pressure, SRP)引起的半长轴变化.第 1 项中由于只考虑了阻力对半长轴的影响,是一个长期项,因而可将  $a$  换成平均半长轴  $a_M$ .又由于 SGP4 模型本身可以计算出重力对于半长轴的影响,阻力-重力耦合项远小于阻力项<sup>[1]</sup>,当卫星轨道的近地点小于 600 km 时,太阳光压摄动项可忽略,故卫星半长轴在大气阻力作用下的变化规律可表示为<sup>[19]</sup>

$$\frac{da_M}{dt} = \frac{2a_M^2 v}{\mu} \mathbf{a}_D \cdot \mathbf{e}_v \quad (3)$$

将式(1)代入式(3)可得

$$\frac{da_M}{dt} = -\frac{a_M \rho B v^3 F}{\mu} \quad (4)$$

式中,  $\mu = GM_e$  是地球引力常数;  $F$  为无量纲的风速因子,可近似为

$$F \cong \left(1 - \frac{r_s \omega}{v} \cos(i)\right)^2 \quad (5)$$

式中,  $r_s$  是卫星到地心的距离;  $\omega$  是地球自转角速度;  $i$  是卫星轨道倾角.与平行风场模型(HWM-93)计算结果相比,该近似误差不大于 3%<sup>[19]</sup>.得到平均平运动  $n_M$  为

$$\frac{dn_M}{dt} = \frac{3}{2} n_M^{1/3} \mu^{-2/3} \rho B v^3 F \quad (6)$$

可以求得一段时间  $[t_i, t_k]$  内的平均密度为

$$\bar{\rho}(t_{ik}) = \frac{\frac{2}{3} u^{-2/3} \Delta n_M(t_{ik})}{\int_{t_i}^{t_k} \bar{n}_M^{1/3}(t_{ik}) B F v^3 dt} \quad (7)$$

式中,  $\bar{n} = (n_{t_i} + n_{t_k})/2$ ;  $\Delta n = n_{t_k} - n_{t_i}$ ;  $\bar{\rho}$  为时间  $[t_i, t_k]$  内卫星轨道上的平均大气密度.该密度值仅由 TLE 计算得到,不依赖于任何经验大气模型.

在反演计算大气密度的过程中,反弹道系数  $B$  的精度直接决定了所求大气密度的精度.由  $B$  的定义可知,它不仅与卫星运行姿态及表面物理特性相关,还与所在环境的大气组成有关,因而很难确定.本文采用 Emmert 方法<sup>[8]</sup>,计算求出一段时间的平均密度值,该值可近似当作真实值.

想要计算出一定时间  $[t_i, t_k]$  内的大气密度,首先要求得这段时间内的反弹道系数.在不考虑卫星姿态调整的情况下,卫星的面质比保持不变.而  $C_d$  与卫星表面的材料特性有关,随时间变化较小.因而

我们可以认为在一个太阳周期内  $B$  恒定不变. 假设参考卫星的真实反弹道系数已知为  $B_{\text{exist}}^T$ , 又由式 (7) 可算得该卫星在某一大气模型下对应的  $B_{\text{exist}}^M$ , 再在同一大气模型下算出目标卫星的  $B_{\text{target}}^M$ , 则目标卫星的真实反弹道系数  $B_{\text{target}}^T$  近似为

$$B_{\text{target}}^T = \frac{B_{\text{target}}^M}{B_{\text{exist}}^M} B_{\text{exist}}^T \quad (8)$$

TLE 数据反演大气密度准确度高, 但是由于 TLE 数据时间分辨率限制, 反演得到的大气密度数据较为稀疏, 无法满足使用需求. 而 MSIS 模型密度准确度较低, 但是时间分辨率高. 为了综合 2 种模型的优势, 利用平均 TLE 反演大气密度来对局部 MSIS 模型密度校准.

计算第  $k$  d 的 TLE 反演密度均值  $\bar{\rho}_{\text{TLE}}(k)$  以及所对应第  $k$  d 的 MSIS 模型密度均值  $\bar{\rho}_{\text{MSIS}}(k)$ , 对于落在第  $k$  d 内的 MSIS 密度, 得到对应的校准后密度为

$$\rho_{\text{calibrated}} = \frac{\bar{\rho}_{\text{TLE}}(k)}{\bar{\rho}_{\text{MSIS}}(k)} \rho_{\text{MSIS}} \quad (9)$$

## 2 非线性自回归神经网络

人工神经网络 (artificial neural network, ANN) 是用来模拟生物大脑神经运作模式的数学系统, 具有良好的非线性特性和高容错率等特点. 此外, ANN 具有学习能力, 可随时根据新的数据进行自我学习和训练, 调整内部存储的权重参数来适应不断变化的需求, 在许多方面都取得了良好的应用.

NRAX 网络是一种动态神经网络模型. 它利用神经网络良好的非线性映射能力, 并引入了动态自回归模型 (autoregressive with external input, ARX) 的时间序列概念, 使得 NARX 网络具备良好的动态特性和抗干扰能力, 对于处理时间序列预测问题有很好的效果<sup>[20-21]</sup>. NARX 定义为

$$y(n+1) = f \begin{bmatrix} y(n), y(n-1), \dots, y(n-d_y+1), \\ u(n), u(n-1), \dots, u(n-d_u+1) \end{bmatrix} \quad (10)$$

式中,  $y(n)$  为目标量在  $n$  时刻的值;  $d_y$  为网络关于目标量的延迟;  $u(n)$  为外部输入量 (可影响到目标量的其他分量) 在  $n$  时刻的值;  $d_u$  为网络关于外部输入量的延迟; 在网络训练过程中,  $y(n+1)$  为网络目标, 而  $y(n), y(n-1), \dots, y(n-d_y+1)$  及

$u(n), u(n-1), \dots, u(n-d_u+1)$  为网络输入;  $f(\cdot)$  是一个非线性函数. NARX 网络与一般的 BP 神经网络最大的不同在于 NARX 网络加入了延迟量. 这可以使得网络在计算时不仅将现在的值进行计算, 还可以将现在时刻之前  $d_u$  个时间节点的值共同加入计算, 并通过不断学习目标和输入之间的非线性关系来调整神经网络内部权重参数, 从而计算目标量的未来估计值, 达到预测的目的.

不同的网络隐藏层神经元个数以及延迟使得神经网络可以适用于解决各类不同的问题. 隐藏层神经元个数越多, 神经网络可以处理的问题越复杂; 延迟越大, 神经网络可以记忆的信息越多. 然而使用的神经元个数和延迟过多或是过少可能引起网络训练过拟合或者欠拟合, 都会影响网络的性能. 网络在初始化权重参数矩阵时采用随机初始化的方式, 在训练过程中有时可能会落入局部极小值而难以收敛到全局最优, 因此将多次重复训练 NARX 网络来选取性能最优的网络.

在预测模型中对预测性能的分析是优化模型性能的关键, 本文使用均方误差 (mean squared error, MSE) 和相关系数  $R$  来评价 NARX 模型的预测性能的指标. 均方误差是用来描述“系统误差”的一种指标, 可用于衡量 2 个变量偏离的程度. MSE 越接近于 0, 2 个变量之间的偏差越小, 即神经网络的性能越好. 相关系数是用以反映变量之间相关关系密切程度的统计指标. 相关系数的取值在  $[-1, 1]$  之间,  $|R|$  越接近 1 说明变量之间的线性相关程度越高, 即

$$\text{MSE} = \frac{\sum_{i=1}^n (x_i - y_i)^2}{n} \quad (11)$$

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (12)$$

## 3 仿真结果

### 3.1 TLE 数据反演结果

本文选用 NRLMSISE-00 模型, 参考卫星选择 starshine1 和 starshine3<sup>[8]</sup>, 分别计算 CHAMP 卫星和 GRACE-A 卫星的平均反弹道系数. 这 2 颗卫星的主要参数及反弹道系数如表 1 所示.

表 1 CHAMP 卫星和 GRACE-A 的轨道参数

Tab.1 The orbital parameters of CHAMP and GRACE-A satellite

卫星名称	发射/回收时间	近地点高度/km	偏心率	倾角/(°)	反弹道系数/(m <sup>2</sup> /kg)
CHAMP	2000-06-15/2010-09-19	381~362	0.0007	87.18	0.003 2
GRACE-A	2002-03-17 至今	483	0.0010	89.0	0.006 7

本文使用星载加速度计反演得到的密度数据作为真实密度,并根据节 1 描述的反演方法,分别计算利用 CHAMP 卫星及 GRACE-A 卫星的 TLE 数据反演得到的大气密度.为了保证计算的准确性,在计算平均密度时式(7)中积分的时间间隔  $[t_i, t_k]$  一般大于 3 d.由于 TLE 数据点较为稀疏,得到的有效密度值较少,因此本文采取了滑动窗口的方法来增加有效密度值.

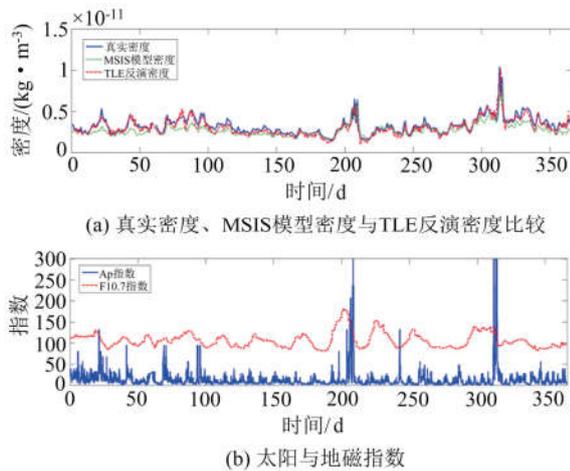


图 1 2004 年 CHAMP 卫星利用 TLE 反演密度结果

Fig.1 Derived density results of CHAMP in 2004 based on TLE data

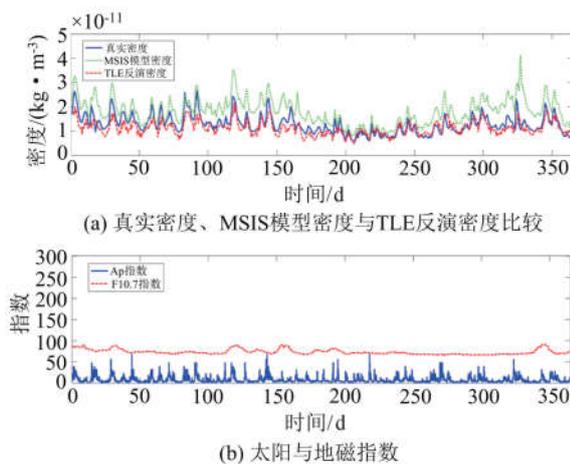


图 2 2007 年 GRACE-A 卫星利用 TLE 反演密度结果

Fig.2 Derived density results of GRACE-A in 2007 based on TLE data

图 1 和图 2 分别给出 CHAMP 卫星在 2004 年和 GRACE-A 卫星在 2007 年的反演结果,包括真实密度、MSIS 模型密度与反演密度之间的关系以及

太阳与地磁活动指数,每年 TLE 反演密度值约有 500 多个.由图 1 与图 2 可知,2004 年太阳活动水平较高,而 2007 年太阳活动水平较低,反演得到的大气密度在不同的条件下平均趋势都比 MSIS 模型更为接近真实密度.

### 3.2 MSIS 模型校准结果

根据第一节提出的校准方法,分别利用 CHAMP 卫星在 2004 年和 GRACE-A 卫星在 2007 年的 TLE 数据对沿着轨道上的局部 MSIS 模型进行校准.结果表明,CHAMP 卫星校准前 MSIS 模型值与真实值相对偏差为 16.30%,校准后相对偏差为 11.50%,校准前后 MSIS 模型密度与真实密度的差值分布如图 3 所示.

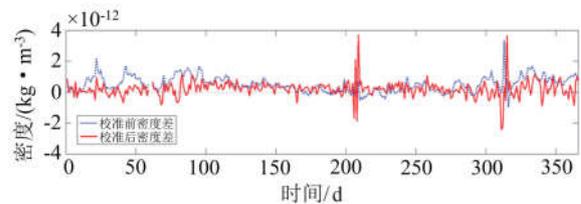


图 3 CHAMP 卫星校准前后误差分布

Fig.3 Error distribution before/after calibration of CHAMP

由图 1(b)和图 3 可知,在太阳活动水平较高的年份,每一次太阳活动剧烈的时候,MSIS 模型密度与真实密度之间的偏差较大,说明 MSIS 模型对于剧烈的空间环境变化的反应不够灵敏.通过 TLE 校准后这一情况得到了改善,除了在 210 d 和 310 d 两次最剧烈的太阳活动时刻,校准后的密度偏差明显小于 MSIS 模型密度与真实值之间的偏差.

GRACE-A 卫星校准前 MSIS 模型值与真实值平均差 23.46%,校准后相对偏差为 7.95%,校准前后 MSIS 模型密度与真实密度的差值分布如图 4 所示.

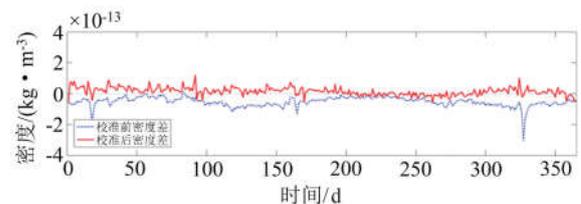


图 4 GRACE-A 卫星校准前后误差分布

Fig.4 Error distribution before/after calibration of GRACE-A

由图 4 可知,在太阳活动水平相对较低的年份,校准方法表现出更好的效果.整体来说,这一校准方法有效地减少了 MSIS 模型密度与真实密度之间的偏差.

### 3.3 模型预测性能

在密度预测的过程中,神经网络的目标值为上一节中计算得到的密度数据.太阳与地磁活动会显著影响大气密度的变化,因此本文分别选取 F10.7 和  $A_p$  来表征太阳和地磁活动的强度作为 NARX 网络的外部输入.由于密度数据分布并不均匀,因此采用线性插值使连续采样点之间的时间间隔统一.经试验后确定采样间隔为 60 s.此外,大气密度的数值一般较小,在  $10-12 \text{ kg/m}^3 \sim 10-13 \text{ kg/m}^3$  的范围之间,因此本文在训练和测试神经网络时使用的是密度值的自然对数而非本身,避免输入数据的量级不同而对网络的性能产生影响,数据在使用时被分为两个部分,一部分当作过去的的数据,用来对网络进行训练和验证,另一部分则当作未来的数据,用以检验网络的预测性能.CHAMP 卫星与 GRACE 卫星的加速度计反演密度值经线性插值后时间间隔也是 60s,这部分数据仅作为参考密度在最后与模型预测值进行比较,不参与中间的模型计算,保证了反演及预测方法的有效性.

给定神经网络的结构后,需要确定合适的隐藏层神经元个数以及目标和外部输入的延迟.为了找到合适的神经元个数,我们首先固定网络延迟为 100(卫星周期约为 93 min),然后不断改变神经元个数的大小测试不同网络的性能;之后固定神经元个数,不断改变延迟的大小.经实验后发现神经元个数为 40 个,延迟量为 100 时网络的性能最优.网络的训练算法采用 Levenberg-Marquardt 算法,此算法综合了牛顿法和梯度下降算法的优点,具有较高的鲁棒性且收敛速度较快<sup>[16]</sup>.

在第 1 个实验中,本文利用 CHAMP 卫星 2004 年第 1 d~第 20 d 的校准密度数据以及对应时间的太阳与地磁活动指数来训练神经网络,然后分别利用未来 12,24,36 以及 48 h 的 F10.7 和  $A_p$  来预测对应时间的大气密度.经过计算,预测密度与真实密度值之间的相对偏差比 MSIS 模型密度与真实密度的相对偏差分别减小了 3.1%,4.1%,4.2%及 4.6%.

表 2 表明在不同预测时间长度内,网络预测值与目标值之间的关系.由表 2 可知,随着预测的时间长度不断增加,神经网络的预测性能不断下降,符合之前的实验预期.

表 2 CHAMP 卫星的神经网络预测性能

Tab.2 analysis network performance for CHAMP satellite

预测时间	12 h	24 h	36 h	48 h
MSE	0.0 013	0.0015	0.0016	0.0025
R	0.9917	0.9905	0.9902	0.9842

表 3 CHAMP 卫星的神经网络预测值与参考值结果分析

Tab.3 Comparison between prediction of network and reference density

预测时间	12 h	24 h	36 h	48 h
MSE	0.0158	0.0213	0.0220	0.0228
R	0.9059	0.8807	0.8744	0.8640

此外,表 3 表明了网络预测值与真实密度在不同预测时间下的偏差,其均方误差与相关系数也表现出了随着预测时间增加而变差的趋势,而且神经网络预测值与参考值之间的偏差要大于预测值与目标值的直接偏差,这是因为目标值是在 MSIS 模型基础上校准得到的,本身就带有一定偏差.但是总体而言,在预测时间小于 48 h 的情况下,预测结果优于 Pérez<sup>[15]</sup>的结果,也优于现有的大气模型,如 MSIS,JB2008 等.不同时间段的预测结果如图 5 所示.

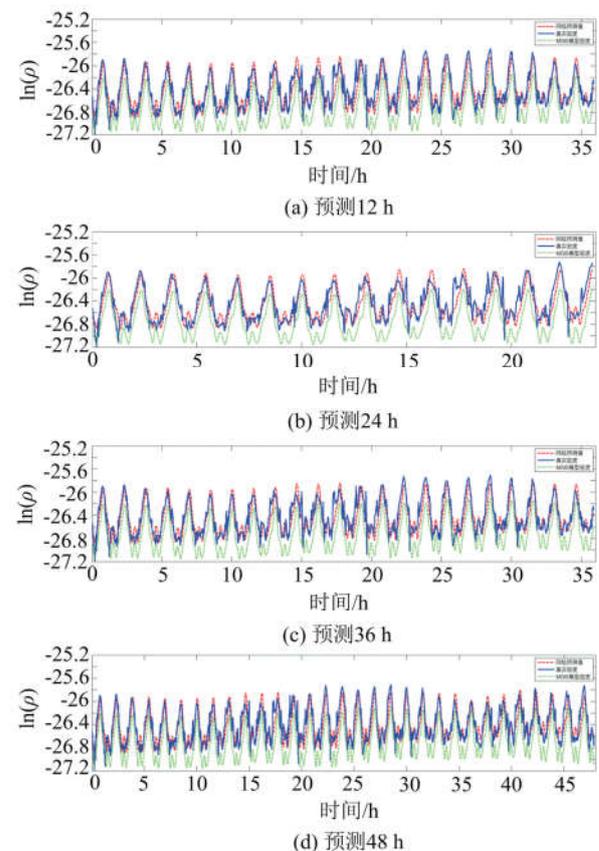


图 5 CHAMP 卫星预测密度、参考密度及 MSIS 模型密度的比较

Fig.5 Comparison between predicted density, real density and MSIS model density for CHAMP satellite

在第 2 个实验中,利用 GRACE-A 卫星 2007 年第 90 d~第 110 d 的数据来训练网络,分别预测 12, 24, 36 以及 48 h, 2007 年太阳活动水平较低,可以看出此时 MSIS 模型密度值与真实值之间偏差较大. 经过计算,本模型的预测值与真实密度之间的相对偏差比 MSIS 模型密度值与真实密度值的相对偏差分别减小了 2.7%, 3.1%, 4.4% 及 5.7%, MSE 与  $R$  的变化趋势与 CHAMP 卫星的相同. GRACE-A 卫星的大气密度预测效果如图 6 所示.

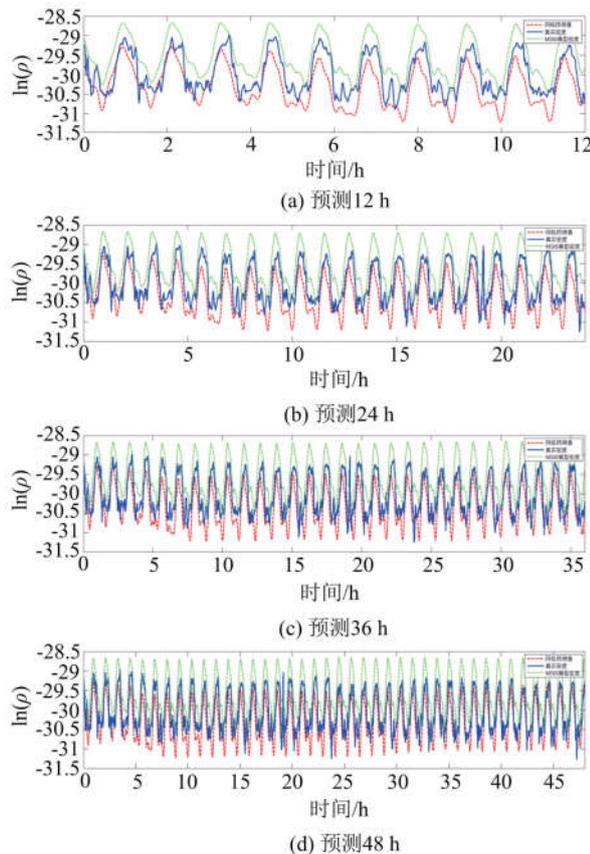


图 6 GRACE-A 卫星预测密度、参考密度及 MSIS 模型密度比较

Fig.6 Comparison between predicted density, real density and MSIS model density for GRACE-A satellite

由上述仿真结果可知,本文通过利用卫星轨道数据反演得到大气密度对 MSIS 大气模型进行校准,有效提高了 MSIS 模型的精度.在使用 NARX 神经网络对密度值进行预测时,当预测时间小于 48 h 时,网络预测模型的预测值的准确度相比于 MSIS 模型的预测准确度明显提高.此外,MSIS 模型密度的准确度随着太阳与地磁活动的减弱而不断降低<sup>[22]</sup>,这也会进一步影响利用模型进行预测的精度,而神经网络预测模型在太阳活动较弱的年份也

表现出了很好的效果.

## 4 结论

本文提出了基于 NRAX 网络的大气密度预测模型.该模型利用低轨卫星轨道数据反演大气密度,并在此基础上对现有大气模型进行校准,然后基于非线性自回归网络对未来大气密度进行预测.本文将该模型应用于不同太阳和地磁活动条件的不同卫星轨道上,实验结果表明,相较于 MSIS 模型,该模型的准确性有了明显提升.在同样的预测时间内,预测准确性也优于之前的预测模型.此外,本文提出的利用现有卫星轨道数据来对大气密度进行反演及校准的方法,为今后使用更高精度的轨道数据进行不同经纬度不同高度大气密度的反演与预测提供了思路.

本文使用的是卫星两行轨道数据,然而目前其精度一般在千米量级,而且数据中包含着大量的噪声,对于神经网络的有效计算产生了不利影响.我国利用星载 GPS 设备得到的观测数据精度最高可达亚米级,后续研究将利用低轨卫星的高精度 GPS 数据进行大气密度反演与预测,以期取得更好的结果.此外,现阶段主要研究利用单个航天器的轨道数据,后续将利用多个真实卫星轨道数据来进行反演与预测,并进行多星轨道上的密度数据融合,提高低轨卫星的轨道确定与轨道预报的精度.

## 参考文献 (References)

- [1] VALLADO D A. Fundamentals of Astrodynamics and Applications [M]. New York, USA: Springer-Verlag, 2010: 242-233.
- [2] BOWMAN B, TOBISKA W K, MARCOS F, et al. A new empirical thermospheric density model JB2008 using new solar and geomagnetic indices [C] // Proceedings of AIAA/AAS Astrodynamics Specialist Conference and Exhibit. Reston, USA: AIAA, 2008.
- [3] HEDIN A E. MSIS-86 thermospheric model [J]. Journal of Geophysical Research Space Physics, 1987, 92(A5): 4649-4662.
- [4] PICONE J M, HEDIN A E, DROB D P, et al. NRLMSISE-00 empirical model of the atmosphere: Statistical comparisons and scientific issues [J]. Journal of Geophysical Research Space Physics, 2002, 107(A12): SIA 15-1-SIA 15-16.
- [5] PARDINI C, ANSELMO L. Comparison and accuracy assessment of semi-empirical atmosphere models

- through the orbital decay of spherical satellites [J]. *Journal of the Astronautical Sciences*, 2001, 49(2): 255-268.
- [6] SUTTON E K, NEREM R S, FORBES J M. Density and winds in the thermosphere deduced from accelerometer data [J]. *Journal of Spacecraft & Rockets*, 2007, 44(6): 1210-1219.
- [7] PICONE J M, EMMERT J T, LEAN J L. Thermospheric densities derived from spacecraft orbits: Accurate processing of two-line element sets [J]. *Journal of Geophysical Research Atmospheres*, 2005, 110(A3): 103-115.
- [8] EMMERT J T. A long-term data set of globally averaged thermospheric total mass density [J]. *Journal of Geophysical Research Space Physics*, 2009, 114(A6): 61-69.
- [9] DOORNBOS E, KLINKRAD H, VISSER P N. Use of two-line element data for thermosphere neutral density model calibration [J]. *Advances in Space Research*, 2008, 41(7): 1115-1122.
- [10] 任廷领, 苗娟, 刘四清, 等. 利用卫星两行轨道根数反演热层密度 [J]. *空间科学学报*, 2014, 34(4): 426-433.  
REN Tingling, MIAO Juan, LIU Siqing, et al. Research on thermospheric densities derived from two-line element sets [J]. *Chinese Journal of Space Science*, 2014, 34(4): 426-433.
- [11] 苗娟, 任廷领, 龚建村, 等. 基于星载高精度 GPS 观测数据的大气密度反演 [J]. *地球物理学报*, 2016, 59(10): 3566-3572.  
MIAO Juan, REN Tingling, GONG Jiancun, et al. Thermospheric density derived from onboard GPS observation data [J]. *Chinese Journal of Geophysics*, 2016, 59(10): 3566-3572.
- [12] 陈旭杏, 胡雄, 肖存英, 等. 基于卫星数据和 NRLMSISE-00 模型的低轨道大气密度预报修正方法 [J]. *地球物理学报*, 2013, 56(10): 3246-3254.  
CHEN Xuxing, HU Xiong, XIAO Cunying, et al. Correction method of the low earth orbital neutral density prediction based on the satellites data and NRLMSISE-00 model [J]. *Chinese Journal of Geophysics*, 2013, 56(10): 3246-3254.
- [13] BOWMAN B R. True satellite ballistic coefficient determination for HASDM [C] // *Proceedings of AIAA/AAS Astrodynamics Specialist Conference and Exhibit*. Reston, USA: AIAA, 2002.
- [14] STASTNY N, LIN C, LOVELL A, et al. Localized density/drag prediction for improved onboard orbit propagation [C] // *Proceedings of the Advanced Maui Optical and Space Surveillance Technologies Conference*, 2009:7-9.
- [15] PÉREZ D, WOHLBERG B, LOVELL T A, et al. Orbit-centered atmospheric density prediction using artificial neural networks [J]. *Acta Astronautica*, 2014, 98(5): 9-23.
- [16] LIN T, HORNE B G, TIÑO P, et al. Learning long-term dependencies in NARX recurrent neural networks [J]. *IEEE Transactions on Neural Networks*, 1996, 7(6): 1329-1338.
- [17] MENEZES J, MARIA P, BARRETO G A. Long-term time series prediction with the NARX network: An empirical evaluation [J]. *Neurocomputing*, 2008, 71: 3335-3343.
- [18] HOOTS F R, ROEHRICH R L. Spacetrack report # 3: Models for propagation of the NORAD element sets [J]. *Spacetrack Report*, 1998:46-47.
- [19] KING H D. *Satellite Orbits in an Atmosphere: Theory and Applications* [M]. Princeton, USA: Princeton University Press, 1987:87-90.
- [20] ALZHRANI A, KIMBALL J W, DAGLI C. Predicting solar irradiance using time series neural networks [J]. *Procedia Computer Science*, 2014, 36: 623-628.
- [21] CAI L, MA S Y, CAI H T, et al. Prediction of SYH-H Index by NARX neural network from IMF and solar wind data [J]. *Science in China Series E: Technological Sciences*, 2009, 52(10): 2877-2885.
- [22] 翁利斌, 方涵先, 季春华, 等. 基于卫星加速度数据反演的热层大气密度与 NRLMSIS-00 模式结果的比较研究 [J]. *空间科学学报*, 2012, 32(5): 713-719.  
WENG Libin, FANG Hanxian, JI Chunhua, et al. Comparison between the CHAMP/STAR derived thermospheric density and the NRLMSISE-00 model [J]. *Chinese Journal of Space Science*, 2012, 32(5): 713-719.