

CAO Qingpeng, HUANG Liupeng, WEI Chunbo, GU Defeng. Calibration of Thermospheric Atmospheric Density Empirical Model Based on SegRNN (in Chinese). *Chinese Journal of Space Science*, 2025, 45(6): 1460–1470. CSTR:32142.14.cjss.2024-0179. DOI:10.11728/cjss2025.06.2024-0179

基于 SegRNN 的热层大气密度经验模型校准*

曹庆鹏¹ 黄柳朋¹ 韦春博² 谷德峰^{1,3}

1(中山大学人工智能学院 珠海 519082)

2(中国科学院国家授时中心 西安 710600)

3(中山大学天琴计划教育部重点实验室/天琴前沿科学中心/国家航天局引力波研究中心 珠海 519082)

摘要 大气阻力是低轨卫星受到的最大非引力摄动, 大气阻力的计算误差主要来源于热层大气密度经验模型误差, 目前经验模型的误差较大, 普遍在 30% 以上. 为提高经验模型的预报精度, 提出一种基于 SegRNN (Segment Recurrent Neural Network) 的热层大气密度经验模型校准方法. 该方法使用 SegRNN 的分块和并行策略进行模型训练和推理, 避免了传统 RNN (Recurrent Neural Network) 因迭代次数过多而引起误差累积与梯度不稳定的问题. 通过分析大气密度与 A_p , $F_{10.7}$ 和 $F_{10.7a}$ 外部环境参数的变化关系, 提出了一种改进的神经网络架构 SegRNN with Residual Block. 该架构通过引入外部环境参数作为动态协变量 (Covariates), 使用 Residual Block (RB) 提取预报时段的密度相关信息, 从而进一步提高 SegRNN 的预报精度. 利用 GRACE (Gravity Recovery and Climate Experiment) 星载加速度计反演得到的密度数据对 NRLMSISE 2.0 进行校准实验. 结果表明, NRLMSISE 2.0 模型原始误差为 31.3%, 经 SegRNN 校准后, 误差降低至 8.0%, 引入动态协变量后, 模型误差进一步降低至 7.2%, 最终校准模型误差下降了 24.1%, 校准效果显著.

关键词 大气密度, 经验密度模型, 神经网络, 模型校准, GRACE 加速度计数据

中图分类号 P353

Calibration of Thermospheric Atmospheric Density Empirical Model Based on SegRNN

CAO Qingpeng¹ HUANG Liupeng¹ WEI Chunbo² GU Defeng^{1,3}

1(School of Artificial Intelligence, Sun Yat-sen University, Zhuhai 519082)

2(National Time Service Center, Chinese Academy of Sciences, Xi'an 710600)

3(MOE Key Laboratory of TianQin Mission, Sun Yat-sen University / Frontiers Science Center for TianQin / CNSA Research Center for Gravitational Waves, Zhuhai 519082)

Abstract Atmospheric drag is the largest non-gravitational perturbation experienced by low-orbit satellites, and the main source of error in calculating atmospheric drag stems from inaccuracies in the

* 中山大学中央高校基本科研业务费专项资金项目资助

2024-12-05 收到原稿, 2025-05-25 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

empirical models of thermospheric density. Currently, these empirical models generally exhibit errors exceeding 30%. To enhance the prediction accuracy of these models, a calibration method for thermospheric density empirical models based on Segment Recurrent Neural Network (SegRNN) is proposed. This method employs the segmentation and parallelism strategies of SegRNN for model training and inference, mitigating the issues of error accumulation and gradient instability that arise from excessive iterations in traditional RNN. By analyzing the relationship between atmospheric density and external environmental parameters such as A_p , $F_{10.7}$, and $F_{10.7a}$, an improved neural network architecture named SegRNN with Residual Block is proposed. This architecture introduces external environmental parameters as dynamic covariates and employs a residual block to encode these covariates, thereby extracting density-related information for the prediction period and further enhancing the prediction accuracy of SegRNN. Finally, the density data derived from the onboard accelerometer of the GRACE (Gravity Recovery and Climate Experiment) satellite is used to calibrate the NRLMSIS 2.0 model. The results indicate that the original error of the NRLMSIS 2.0 model is 31.3%. After calibration with SegRNN, the error was reduced to 8.0%. By introducing dynamic covariates, the model error was further reduced to 7.2%. Ultimately, the error of the final calibrated model decreased by 24.1%, demonstrating significant calibration effects.

Key words Atmospheric density, Empirical density model, Neural network, Model calibration, GRACE accelerometer data

0 引言

热层大气是地球大气层的关键组成部分, 海拔高度约 90~600 km, 这一区域不仅运行着众多低轨卫星, 也是地球空间环境研究的重要领域. 在轨道预报中需要考虑太阳光压摄动、地球反照光压摄动和大气阻力等多种误差因素^[1]. 在这些因素中, 大气阻力是卫星受到的最大非引力摄动^[2,3]. 大气密度计算的误差会导致卫星大气阻力估算的偏差, 进而影响卫星轨道预报的精度. 在神舟八号飞船的轨道预报中发现, 热层大气密度计算中出现 10% 以上的偏差, 会导致轨道位置预报在 20 d 后出现 800 km 以上的误差^[4]. 然而, 由于热层大气密度的高度动态性和复杂性, 热层大气密度的精确建模一直是极具挑战性的研究热点.

目前主要使用经验大气密度模型来计算大气密度. 常用的大气密度经验模型包括 Jacchia 系列^[5]、MSIS (Mass Spectrometer/Incoherent Scatter Mode) 系列^[6]和 DTM (Drag Temperature Model) 系列^[7,8]. Jacchia 系列模型最初由意大利 Jacchia 开发, 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, 目前最新发布版本是 JB2008^[9,10]. MSIS 系列模型由美国海军实验室开发, 使用非相干散射雷达和星载仪器测量数据建模, 目前最新版本是 NRLM-

SIS 2.0. DTM 系列模型是欧洲空间局开发, 结合了卫星阻力、大气成分和温度等多种测量数据改进模型, 目前最新发布版本是 DTM2020. 尽管经过多次版本迭代, 现有的经验模型普遍仍存在约 30% 的误差^[11].

为提高大气密度预报的精度, 需要对经验模型进行校准. 根据实现方式可以分为两类校准方法: 一类是通过改正经验模型内部参数来间接实现大气密度校准, 另一类是直接校准经验模型计算的大气密度结果. 第一类方法的代表是美国空军指挥部提出的高精度卫星阻力模型 HASDM (High Accuracy Satellite Drag Model)^[12], 该方法利用美国空间监测网的 75 颗卫星雷达跟踪数据, 采用 DCA (Dynamic Calibration Atmosphere) 算法^[13], 实现了对 Jacchia70 温度参数的动态校准, 校准后模型在 200~800 km 高度内精度约为 7%^[14]. Doornbos 等^[15]以 MSIS-86 模型计算的密度作为基准, 使用修正温度参数的方法, 对 CIRA-1972 (COSPAR International Reference Atmosphere) 模型的顶层大气温度和 125 km 高度处的转折点温度参数进行动态校准, 并通过 TLE (Two-Line Element) 数据进行评估, 校准后模型预报误差下降了约 2.4%.

第一类方法高度依赖解析模型, 不适用于非解析模型, 使用上有一定的局限性; 第二类方法利用大气

密度实测数据直接校准经验模型的密度结果, 克服了这一局限性. Cefola 等^[16]建立了 GOST 经验模型密度与高度的线性关系, 使用 TLE (Two-Line Element) 数据和最小二乘拟合算法计算出经验模型的校准因子, 校准后模型轨道预报的精度显著提高. Bergstrom 等^[17]利用空间碎片测量得到的大气密度数据, 计算出不同轨道高度下的校准因子, 实现了对 NRLMSISE-00 (Naval Research Laboratory Mass Spectrometer/Incoherent Scatter Model) 模型校准, 校准后模型的偏离程度显著下降, 改善了模型精度. Chen 等^[18]建立了校准因子与高度、经纬度、时间和 $F_{10.7}$ 的二次多项式模型, 利用 GRACE (Gravity Recovery and Climate Experiment) 和 CHAMP (CHALLENGING Minisatellite Payload) 卫星大气密度实测数据拟合得到校准因子, 然后对 NRLMSISE-00 模型的计算结果进行校准, 在太阳活动中低年时, 修正模型的误差从 59.21% 降低到 27.85%.

神经网络在探索复杂高维数据的隐含结构及相关性方面具有优势. 近年来, 神经网络开始被应用于大气经验模型校准研究. Pérez 等^[19,20]提出了 FTDNN (Fast Time-Delay Neural Network) 和 RTDNN (Real-Time Time-Delay Neural Network) 神经网络模型, 利用 CHAMP 和 GRACE 星载加速度计反演密度数据, 对 DTM-2013 模型进行校准, FTDNN 校准模型误差下降了 8.5%, RTDNN 校准模型误差下降了 9.9%. Chen 等^[21]使用 DNNs (Deep Neural Networks) 神经网络结合 A_p 和 Dst 地磁指数, 对地磁暴期间的 NRLMSISE-00 和 JB2008 模型进行了校准, 校准后模型改善了卫星短期轨道预报的精度. Zhang 等^[22]使用 LSTM (Long Short-Term Memory) 神经网络, 以 CHAMP 卫星加速度计反演的密度数据为基准, 对 NRLMSISE-00 模型进行了校准, 校准后模型在 2007 年的预报中均方根误差下降了 $6.4 \times 10^{-13} \text{ kg} \cdot \text{m}^{-3}$. 但 LSTM 等传统循环神经网络 (RNN) 在处理历史或预报数据较长任务时, 迭代次数过多会出现梯度爆炸或消失问题, 导致预报精度下降^[23,24]. 为了克服这些问题, SegRNN (Segment Recurrent Neural Network) 应运而生, 其通过两个核心策略来大幅减少网络训练和预报的迭代次数: 一是以数据块 (Segment) 作为每次的训练单位, 替代传统的数据点; 二是采用并行多步预报 (PMF) 策略, 替

代原有的迭代多步预报 (RMF) 策略^[25].

基于上述研究, 提出了一种基于 SegRNN 对大气经验模型进行校准的方法, 并使用外部环境参数获取未来时刻的密度相关信息. 以 GRACE-A 星载加速度计反演密度数据作为基准, 并通过 Residual Block 对 A_p 、 $F_{10.7}$ 及其 81 d 平均值 $F_{10.7a}$ 等外部环境参数进行编码, 将编码结果作为校准模型的输入, 共同校准 NRLMSIS 2.0 模型.

1 模型与数据

1.1 NRLMSIS 2.0

MSIS 系列模型广泛应用于计算各种高度下的大气密度, 致使校准研究不断深入. 随着大气密度探测技术的进步, 该系列模型已迭代升级至 NRLMSIS 2.0 版本. 此版本在保持原有优势的基础上, 进一步提升了模型的计算精度和适用范围. NRLMSIS 2.0 是一个全高度的中性大气温度和大气成分经验模型, 其范围从地面延伸至外大气层, 并通过参数化解析式描述了温度、8 种大气成分密度和质量密度. 该模型的输入包括经纬度、年积日、平太阳时、地磁指数 A_p 、太阳活动通量 $F_{10.7}$ 及其 81 d 平均值 $F_{10.7a}$, 输出包括大气密度和温度. NRLMSIS 2.0 是先前版本 NRLMSISE-00 的重大改进升级. 该模型通过将热层中各种气体的密度与整个大气的温度分布进行耦合, 实现了每种气体从 70 km 以下完全混合区域到 200 km 以上扩散分离区域之间的平滑过渡, 提高了模型对各种大气成分密度的估算能力^[26].

NRLMSIS 2.0 模型对原子氧的处理也进行了优化. 将原子氧扩展到 50 km, 使模型能够更全面地覆盖低层大气中的原子氧分布. 同时, 模型采用地势高度作为内部垂直坐标, 进一步增强了模型对大气密度在不同地理位置上变化的描述能力, 使模型输出更加贴近实际大气状况^[26]. 因此选择 NRLMSIS 2.0 模型作为本文的研究对象.

1.2 星载加速度计反演密度

星载加速度计反演密度数据被广泛用于验证大气密度模型的精度, 加速度计可以测量出卫星受到的非保守力摄动加速度, 去除太阳光压加速度值和地球反照辐射压加速度值, 可以得到卫星受到大气阻力加速度值, 依据大气阻力与大气密度之间的关系可以计

算出卫星轨道处的大气密度^[2,3], 即

$$a_d = -\frac{1}{2}C_d \frac{A}{m} \rho v^2. \quad (1)$$

其中, C_d 为大气阻尼系数, A 为卫星面板的迎风面积, m 为卫星质量, ρ 为热层大气密度, v 为卫星相对热层大气分子的移动速度.

选择 GRACE-A 卫星作为实验对象. GRACE 是由美国宇航局和德国航空航天中心联合提出的空间重力探测任务, 该任务采用 GRACE-A/B 双星编队, 用于高精度地球重力场变化测量, 两颗卫星相距约 220 km, 初始轨道平均为 490 km 的近极轨道, 轨道倾角约为 89.5° , 周期约为 90 min, 从 2002 年发射以来持续运行至 2018 年^[27]. GRACE 卫星搭载了高精度加速度计, 由其反演来的大气密度数据被广泛用于改进各种大气密度模型.

图 1 分别给出了 2007 年 1 月 1 日与误差统计时段 2006 年 7 月 1 日至 2007 年 1 月 1 日的 GRACE-A 星载加速度计反演密度数据与 NRLMSIS 2.0 计算

的密度数据情况. 从图 1 可以看出, GRACE-A 星载加速度计反演密度数据比 NRLMSIS 2.0 密度数据有更多的细节, NRLMSIS 2.0 计算的密度数据较为平滑, GRACE-A 星加速度计反演密度整体小于 NRLMSIS 2.0 模型计算的密度数据.

1.3 外部环境参数

太阳和地磁活动影响热层的温度, 进而对热层大气密度产生显著影响. 太阳辐射通量 $F_{10.7}$ 和地磁活动指数 A_p 是表征太阳和地磁活动的重要指标, 也是大气密度预测中常用的外部环境参数. $F_{10.7}$ 代表了太阳在 10.7 cm 波长的辐射强度, 通常以 sfu 为单位^[28]. A_p 是描述地球磁场扰动的参数, 由全球多个地磁观测站的数据综合计算得出, 通常以 nT 为单位^[29]. 在地磁风暴期间, A_p 对大气密度的影响可能会超过 $F_{10.7}$ ^[30].

图 2 分别给出了模型误差统计时段 2006 年 7 月 1 日至 2007 年 1 月 1 日的太阳和地磁指数, 从图 2 可以看出, 这一时期太阳辐射通量最大值不超过 120 sfu, 分布在 70~100 nT 之间, 2006 年 12 月太阳活动频繁, 整体处于太阳中等活动时期. 地磁活动指数大部分时间最大值不超过 60 nT, 分布在 0~60 nT 之间, 处于地磁中等活动时期. 2006 年 12 月 15 日地磁活动突然加剧, A_p 指数高达 93 nT, 地磁活动剧烈. 总体来说, 2006 年下半年太阳和地磁活动整体比较平稳, 2006 年 12 月太阳和地磁活动相对频繁.

2 SegRNN 神经网络

2.1 SegRNN with Residual Block 模型

SegRNN with Residual Block 模型将预报时段的外部环境参数 A_p , $F_{10.7}$ 和 $F_{10.7a}$ 作为动态协变量输入到 RB (Residual Block) 进行学习编码, 提取出未来时刻的密度相关信息并与 SegRNN 计算的结果相运算, 从而将未来时刻密度信息注入到神经网络模型中, 其模型结构如图 3 所示.

SegRNN with Residual Block 模型对输入数据的处理过程可以描述为

$$\mathbf{y} = \text{SegRNN}(\mathbf{X}^{(i)}) \cdot \mathbf{w} \cdot \text{ResidualBlock}(\mathbf{X}_c^{(i)}). \quad (2)$$

其中, $\mathbf{X}^{(i)}$ 是历史数据值构成的矩阵, 包括 NRLMSIS 2.0 密度数据、GRACE-A 星载加速度计反演密度数据、外部环境参数 A_p 和 $F_{10.7}$ 及其 81 d 平均值




图 1 NRLMSIS 2.0 和 GRACE-A 加速度计反演的大气密度

Fig. 1 Atmospheric density data obtained by NRLMSIS 2.0 and inversion from GRACE-A accelerometer




图2 测试时段的外部环境参数

Fig. 2 External environmental parameters during testing periods




图3 SegRNN with Residual Block 模型结构

Fig. 3 Model architecture of SegRNN with Residual Block

$F_{10.7a}$; w 为两个模型的转换矩阵; $X_c^{(i)}$ 为动态协变量参数值构成的矩阵.

2.2 SegRNN 模型

SegRNN 是针对长时间序列预报优化的 RNN 模型, 通过采用数据段而非单个数据点作为基础时间单元, 并且用并行多步预报方法替代传统的迭代多步预报方式, 实现了模型的改进, 模型结构如图 4 所示. 这两项改进不仅大幅减少了模型在训练和预报阶段的迭代次数, 还有效地减少了误差累积, 进而显著提升了模型在处理长序列数据时的预报精度和效率^[25].

SegRNN 模型框架主要分为编码器 (Encoder) 和解码器 (Decoder) 两个部分. 在编码部分, 模型将时间序列输入 $X_L^{(i)}$ 分割成 n 个长度为 w 的数据段 $X_w^{(i)}$, 再将 $X_w^{(i)}$ 通过 Linear 编码为 $X_d^{(i)}$, 以适应 GRU (Gated Recurrent Unit) 隐藏层的维度 d , 进而将 $X_d^{(i)}$ 输入到 GRU 单元中循环迭代, 以捕获时间特征, 对于 $X_d^{(i)}$ 中第 i 个特征的 x_t 在 GRU 中的计算过程可以描述为

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]), \quad (3)$$

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]), \quad (4)$$

$$\tilde{h}_t = \tanh(\mathbf{W} \cdot [r_t \times h_{t-1}, x_t]), \quad (5)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t. \quad (6)$$

其中, z_t 为更新门; $\mathbf{W}_z$ 为权重矩阵, 决定前一时刻隐藏状态 h_{t-1} 中有多少信息需要被保留到当前时刻 h_t ; σ 为 Sigmoid 激活函数, 用于将输入映射到 $(0, 1)$ 区间, 从而控制信息的通过比例; r_t 为重置门, 决定前一时刻的隐藏状态 h_{t-1} 中有多少信息需要被遗忘, 以便计算新的候选隐藏状态 $\tilde{h}_t$. 式 (3)~(6) 描述了数据在网络中的处理过程.

在解码阶段, RNN 隐藏层根据位置编码和通道编码的输入生成预报段, 每个预报段通过 Linear 编码, 最后将所有编码段拼接在一起, 得到最终的预报数据 $Y^{(i)}$.

2.3 Residual Block 模型

Residual Block 主要用来提取动态协变量中的有效信息, 并将其映射到新的特征空间, 用来与 SegRNN 的中间输出值进行交互, 由 Linear 层、ReLU 激活函数、Dropout 层和跳跃连接组成, 模型结构如图 5 所示.

在图 5 中 Linear 层用来编码动态协变量信息; ReLU 激活函数增加模型的非线性能力^[31]; Dropout 层随机丢弃部分神经元的输出, 以防止过拟合^[32]; 跳跃连接在增加网络深度的同时避免了性能的损失, 也减少了信息在传播过程中的损失^[33]. Residual Block 对动态协变量的处理过程可以描述为

$$\widehat{X}_c = \text{ResidualBlock}(X_c^{(i)}). \quad (7)$$

其中, $X_c^{(i)}$ 为大气密度数据的第 i 个动态协变量, $\widehat{X}_c$ 为所有动态协变量的编码值.

3 实验结果分析

通过统计模型预报误差值验证 SegRNN 模型的有效性; 通过消融实验, 分析加入动态协变量对 SegRNN 模型预报精度的影响, 从而验证 SegRNN with Residual Block 模型的效果; 利用 LSTM 模型在相同数据集上进行校准实验, 并与 SegRNN 结果进行对比分析. 实验基于 Pytorch 深度学习框架^[34], 在显存为




图 4 SegRNN 模型结构
Fig. 4 Model architecture of SegRNN




图 5 Residual Block 模型结构
Fig. 5 Model architecture of Residual Block

10 GB 的 NVIDIA RTX3080 显卡上完成。

3.1 实验设计

针对历史时间为 64 h, 预报时间为{1, 3, 6, 12, 24 h}的密度数据预报任务, 分别训练了各自的神经网络模型, 包括 LSTM 和 SegRNN 以及加入了动态协变量的 SegRNN with Residual Block 模型。

3.1.1 数据集

选取 NRLMSIS 2.0 经验模型为待校准模型, 以 GRACE-A 星载加速度计反演的密度数据作为标准密度值。同时, 将地磁指数 A_p 、太阳辐射通量 $F_{10.7}$ 及其 81 d 平均值 $F_{10.7a}$ 作为外部环境参数, 并将预报时段的外部环境参数当作动态协变量。神经网络模型基于大气密度数据进行学习, 模型的输入数据包括 NRLMSIS 2.0 密度, GRACE-A 星载加速度计反演的密度及外部环境参数; 模型的输出数据为校准后的大气密度。

在模型的训练阶段, 使用 2006 年 4 月 1 日至 2006 年 6 月 30 日的数据作为神经网络的训练数据,

其中 70% 的数据作为训练集, 30% 作为验证集。在测试阶段, 选取 2006 年 7 月 1 日至 2007 年 1 月 1 日的数据作为测试数据, 统计模型的预报性能。

3.1.2 数据处理

由于大气密度值较小 ($10^{-12} \sim 10^{-14}$), 而外部环境参数值较大 (1~100), 因此在输入到神经网络之前, 需要对数据进行标准化处理, 以消除不同数据量纲的影响。进行标准化处理的表达式为

$$x^{(n)} = \frac{x_i^{(n)} - \mu^{(n)}}{\sigma^{(n)}}. \quad (8)$$

其中, μ 和 σ 分别为不同数据的均值和方差, n 为不同数据序列。

由于星载加速度计会受到卫星环境变化以及仪器老化等影响, 其测量数据也存在一些较大的偏差, 导致反演的大气密度数据出现异常值, 因此需要将这些异常值剔除。本文使用 MAD (Median Absolute Deviation) 中位数偏差法检测并剔除密度数据中的异常值, 大气密度数据异常值的判定条件为

$$\delta_{\text{MAD}} = \text{Median} \{|y_i - m| / 0.6745\}, \quad (9)$$

$$|y_i| > (m + n \cdot \delta_{\text{MAD}}). \quad (10)$$

其中, y_i 为密度数据, m 为密度数据 y_i 的中间数, Median 表示取中位数. 当数据值满足上式时, 判定该值为异常值, 并将其替换为数据平均值. 其中 n 的值需要根据实际情况进行调整, 直到剔除全部异常值. 最后对于时间分辨率不同的数据, 采用拉格朗日插值使其一致, 这里采用的时间分辨率统一为 5 min.

3.1.3 性能指标

为了评估模型的性能, 采用均方根误差 (RMSE, E_{RMS}) 和平均相对误差 (RE, E_{RE}) 作为性能指标, 其表达式如下:

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\rho}_i - \rho_i)^2}, \quad (11)$$

$$E_{\text{RE}} = \sum_{i=1}^N \frac{R_i}{N}. \quad (12)$$

其中, $\hat{\rho}_i$ 为经验模型密度值, ρ_i 为 GRACE-A 星加速度计反演密度值. 为了评估经验模型密度的精度, 引入相对误差 R_i 作为评价指标, 其表达式为

$$R_i = \frac{\hat{\rho}_i - \rho_i}{\rho_i} \times 100\%. \quad (13)$$

RMSE 用于衡量两个变量之间的差异, 因为 RMSE 误差值和原始数据的单位是一致的, 因此在本文中被当作绝对误差使用. 平均相对误差 RE 是以百分比的形式表示误差, 通常用于表示计算的精确程度, 尤其是在科学测量和工程领域, 更能反映测量的可信度.

3.1.4 模型配置

SegRNN 和 SegRNN with Residual Block 模型的配置统一设定为: 以单层 GRU^[35] 作为 SegRNN 的基础 RNN 类型, 使用基于自适应学习率和动量梯度下降算法的 Adam (Adaptive Moment Estimation) 优化器 (optimizer)^[36]. 采用通道独立策略进行训练, 减少了模型对通道间复杂关系的依赖, 增强了模型的鲁棒性, 同时也有效缓解了分布漂移对模型性能的影响^[37]. 模型训练和验证时使用的损失函数选定为均方误差 (mse). 历史数据长度 (seq len) 为 768, 训练轮数 (epoch) 为 30, 并在此过程中实施早停策略以避免过拟合, 同时缩短模型的训练时间. 学习率在初始三

轮训练中保持恒定, 随后则按 0.8 的比例逐步衰减. 早停策略的耐心值 (patience) 设置为 6, 以确保训练过程的稳定性和效率, 同时确保模型具有良好的泛化能力. 根据具体预报时间 {1, 3, 6, 12, 24 h} 确定模型大小 (d model)、暂退率 (dropout)、批次大小 (batch size)、分块大小 (seg len) 和学习率 (learning rate) 的参数选择. 其中, 分块大小需要是历史数据长度和预报长度 (pred len) 的公因数, 最优选择是小于二者的最大公因数^[25]. batch size 越大, 模型一次获取的信息越多, 模型收敛速度越快, 但是容易使模型产生过拟合的倾向. 当预报时间越短时, d model 应该越小, 同时 learning rate 也越小. 当模型出现过拟合倾向时, 应适当增大 dropout, 以关闭更多神经元, 抑制模型过拟合的程度. 另外, 实验结果验证, d model 和 batch size 的参数值选取越大, 模型预报数据与真实数据的偏移程度越小, 但是会导致模型预报结果离散程度和波动程度增加, 相应的 RMSE 误差会增加. 经多次实验, 本文采用的参数列于表 1. 其中 LSTM 模型的参数配置和训练策略与 SegRNN 模型保持一致. 由于 LSTM 网络架构本身并不包含分块大小 (seq len) 参数, 故在 LSTM 模型的配置过程中, 该参数被相应省略.

3.2 结果与分析

以 GRACE-A 星载加速度计反演密度数据为基准, 对比 NRLMSIS 2.0 模型与神经网络校准后模型的预报结果, 以此评估神经网络校准的效果; 列举经过神经网络校准后的模型在不同预报时间长度下的误差; 对 NRLMSIS 2.0 模型与神经网络模型的每日误差均值进行对比和分析.

3.2.1 SegRNN 校准效果

图 6 给出了经过 SegRNN 及其改进版本 SegRNN with Residual Block 神经网络校准后, 对 2007 年 1 月 1 日大气密度数据的预报结果. 从图 1 (a) 和图 6 (a) 的对比中可以看出, 经过 SegRNN 校准后的模型预报密度数据 (以蓝线表示) 相比 NRLMSIS 2.0 模型 (以蓝线表示) 有了显著提升. 另外, 从图 6 (b) 中 SegRNN with Residual Block 预报的密度数据可以发现, 通过将动态协变量注入到 SegRNN 模型中, 使原有模型获得了未来的太阳和地磁活动信息, 其预报结果与 GRACE-A 密度数据 (以红线表示) 吻合度更好, 使 SegRNN 的预报效果得到了

表 1 神经网络模型参数选择
Table 1 Neural network model parameter selection

Parameter	Time/h				
	1	3	6	12	24
seq len	768	768	768	768	768
pred len	12	36	72	144	288
seg len	6	12	12	48	96
num layer	1	1	1	1	1
d model	256	256	512	512	1024
dropout	0.5	0.5	0	0.5	0
batch size	8	16	64	128	256
epoch	30	30	30	30	30
patience	6	6	6	6	6
learning rate	0.0001	0.0001	0.0002	0.0002	0.0004
loss function	mse	mse	mse	mse	mse
optimizer	Adam	Adam	Adam	Adam	Adam




图 6 SegRNN 和 SegRNN with Residual Block 模型预报结果

Fig. 6 Prediction results of SegRNN and SegRNN with Residual Block model

进一步提升.

另外, 由于使用神经网络校准 NRLMSIS 2.0 经验模型, 实际上就是通过神经网络学习经验模型与 GRACE-A 密度数据之间差值的规律. 因此为了更加直观地考察经过 SegRNN 校准后模型的预报效果, 绘制了 NRLMSIS 2.0 (N20) 密度数据和 SegRNN 预报

的密度数据与 GRACE-A 密度数据之间的差值结果, 如图 7 所示.

图 7 中绿框显示的是历史时段, 蓝框显示的是预报时段. 其中红线代表神经网络需要学习并校准的部分, 即 NRLMSIS 2.0 模型预报密度与 GRACE-A 加速度计反演密度的差值; 蓝线代表 SegRNN 模型预报结果与 GRACE-A 加速度计反演密度的差值. 从图 7 可以看出, SegRNN 预报差值与 NRLMSIS 2.0 差值部分基本符合, 表明预报效果显著.

3.2.2 神经网络校准结果

表 2 列出了神经网络校准后模型预报的结果误差. 从表 2 可以看出, 经过 SegRNN 校准后的模型误差大幅下降, 24 h 预报的相对误差从原来的 31.3% 下降到 8.0%, 同时均方根误差也从原来的 9.4×10^{-14} 下降到了 4.8×10^{-14} , 校准后的模型相对误差下降了 23.3%, 精度改善效果显著. 与传统神经网络 LSTM 相比, SegRNN 的预报性能提升显著, 且时间和空间复杂度更小^[25], 因此训练和预报花费的显存和时间更少, 在 24 h 大气密度预报任务中 SegRNN 相对误差比 LSTM 降低了 9.4%. SegRNN with Residual Block 模型由于使用了预报时间段的外部环境参数作为动态协变量输入到网络, 得到预报时间段的密度相关信息, 从而提升了其预报的精度. 从中可以看出, SegRNN with Residual Block 在原有 SegRNN 框架基础上进行了优化措施, 使 SegRNN 模型的预报精度得到

了额外提升, 其中 24 h 预报误差进一步降低至 7.2%.

3.2.3 误差分析

图 8 中给出了 NRLMSIS 2.0 模型和 SegRNN 校准模型的相对误差日均值和均方根误差日均值. 可以发现, NRLMSIS 2.0 模型的误差呈现出较为显著的波动趋势, 其中相对误差的最大值甚至超过了 60%. 此外, NRLMSIS 2.0 经验模型的整体预报结果偏高, 大部分时间的相对误差均保持在 0 以上. 值得注意的是, 2006 年 12 月也就是太阳活动异常频繁的时期, NRLMSIS 2.0 模型的误差达到一个高峰, 反映了 NRLMSIS 2.0 模型在捕捉和反映太阳与地磁活动变化方面具有一定程度的局限性, 从而影响了其整体的准确性和可靠性. 经过神经网络校准后的模型, 其误差波动比较平稳, 未再出现明显的误差, 且相对误差

在 0 附近波动, 表明校准后的模型预报结果与加速度计反演密度数据更加吻合, 不再普遍偏高, 即使在太阳活动频繁时期, 模型性能也能得到明显改善, 表明校准后模型能够精准捕捉太阳和地磁辐射的变化, 从而更加准确地预报大气密度.

4 结论

提出了一种基于 SegRNN 的热层大气密度经验模型校准方法, 通过观察和分析大气密度和外部环境参数的变化关系, 提出了一种改进的网络架构 SegRNN with Residual Block. 研究以 NRLMSIS 2.0 经验模型为校准对象, 但该方法同样适用于校准 DTM2020, JB2008 等其他经验模型. 通过对实验结果分析, 得到如下结论.

(1) 相比传统 LSTM 模型, 使用 SegRNN 神经网络校准 NRLMSIS 2.0 模型的预报精度显著提高, 24 h 预报误差为 8.0%, 相比 LSTM 提升了 9.4%, 并且得益于 SegRNN 的并行模式, 模型训练和推理所需时间和显存显著下降.

(2) SegRNN with Residual Block 模型将预报时间段的地磁指数 A_p 、太阳辐射通量 $F_{10.7}$ 及其 81 d 平均值 $F_{10.7a}$ 作为动态协变量, 经过 Residual Block 编码后输入网络, 使模型获得未来时刻密度数据的相关信息. 结果表明, 改进后的模型在全部 5 个




图 7 SegRNN 模型预报效果
Fig. 7 Prediction effect of SegRNN model

表 2 神经网络模型预报误差
Table 2 Prediction error of neural network models

Horizon	Metric	Model		
		LSTM	SegRNN without RB	SegRNN with RB
1 h	RMSE/(kg·m ⁻³)	4.6×10 ⁻¹⁴	2.6×10⁻¹⁴	2.7×10 ⁻¹⁴
	RE/(%)	7.8	4.7	2.5
3 h	RMSE/(kg·m ⁻³)	4.9×10 ⁻¹⁴	3.0×10 ⁻¹⁴	2.9×10⁻¹⁴
	RE/(%)	8.2	4.7	4.3
6 h	RMSE/(kg·m ⁻³)	7.7×10 ⁻¹⁴	3.3×10 ⁻¹⁴	3.1×10⁻¹⁴
	RE/(%)	14.8	7.4	4.2
12 h	RMSE/(kg·m ⁻³)	8.7×10 ⁻¹⁴	4.1×10 ⁻¹⁴	3.8×10⁻¹⁴
	RE/(%)	17.2	7.8	4.4
24 h	RMSE/(kg·m ⁻³)	9.4×10 ⁻¹⁴	4.8×10 ⁻¹⁴	4.7×10⁻¹⁴
	RE/(%)	17.4	8.0	7.2

注 RB为Residual Block model. RE为Relative Error. 黑体表示最小误差值.




图 8 NRLMSIS 2.0 经验模型与 SegRNN 校准模型相对于 GRCAE-A 星载加速度密度数据的误差日均值

Fig. 8 Daily average error of NRLMSIS 2.0 empirical model and SegRNN calibration model relative to GRCAE-A onboard acceleration density data

预报时段所涉及的 10 个指标中, 9 个指标的表现均优于 SegRNN, 其中 24 h 预报误差为 7.2%, 说明这种设计能有效提升模型预报精度. 校准后的 NRLMSIS 2.0 经验模型误差下降了 24.1%.

研究中使用太阳辐射通量 $F_{10.7}$ 和 A_p 作为太阳和地磁活动的指标, 为了更精确地刻画太阳辐射和地磁强度的特征, 将在后续研究中考虑使用太阳极紫外辐射指数^[38]以及 Dst 地磁指数^[39], 更精准地描述太阳辐射和地磁强度, 这些指数的加入预计将提供更准确的外部环境信息, 从而有助于提升校准模型的精确度. 此外, 以往采用的传统校准方法已经具有显著成效. 因此, 将传统方法与神经网络相结合校准热层大气密度经验模型, 将是未来研究的重点.

参考文献

- [1] LI Min. Research on Muti-GNSS Precise Orbit Determination Theory and Application[D]. Wuhan: Wuhan University, 2011: 63
- [2] LIU Lin. Orbit Theory of Spacecraft[M]. Beijing: National Defense Industry Press, 2000
- [3] MONTENBRUCK O, GILL E, LUTZE F. Satellite orbits: models, methods, and applications[J]. *Applied Mechanics Reviews*, 2002, **55**(2): B27-B28
- [4] LIU Shushi, GONG J C, LIU S Q, *et al*. Thermospheric density during geomagnetic storm based on EOF analysis[J]. *Chinese Journal of Geophysics*, 2013, **56**(10): 3236-3245
- [5] JACCHIA L G. Revised static models of the thermosphere and exosphere with empirical temperature profiles[J]. *Sao Special Report*, 1971, **313**(20): 3138-3144
- [6] 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
- [7] BRUINSMA S. The DTM-2013 thermosphere model[J]. *Journal of Space Weather and Space Climate*, 2015, **5**: A1
- [8] BRUINSMA S, THUILLIER G, BARLIER F. The DTM-2000 empirical thermosphere model with new data assimilation and constraints at lower boundary: accuracy and properties[J]. *Journal of Atmospheric and Solar Terrestrial Physics*, 2003, **65**(9): 1053-1070
- [9] BOWMAN B R, TOBISKA W K, MARCOS F A. A new empirical thermospheric density model JB2006 using new solar indices[C]//AIAA/AAS Astrodynamics Specialist Conference and Exhibit. Keystone: AIAA, 2006: 6166
- [10] BOWMAN B R, TOBISKA W K, MARCOS F A, *et al*. A new empirical thermospheric density model JB2008 using new solar and geomagnetic indices[C]//AIAA/AAS Astrodynamics Specialist Conference and Exhibit. Honolulu: AIAA, 2008: 6438
- [11] EMMERT J T. Thermospheric mass density: a review[J]. *Advances in Space Research*, 2015, **56**(5): 773-824
- [12] STORZ M F, BOWMAN B R, BRANSON M J I, *et al*. High accuracy satellite drag model(HASDM)[J]. *Advances in Space Research*, 2005, **36**(12): 2497-2505
- [13] CASALI S J, BARKER W N. Dynamic Calibration Atmosphere (DCA) for the high accuracy satellite drag model (HASDM)[C]//AIAA/AAS Astrodynamics Specialist Conference and Exhibit. Monterey: AIAA, 2013. DOI:10.2514/6.2002-4888
- [14] LI Wenwen, LI Min, SHI Chuang, *et al*. Thermosphere mass density derivation using on-board accelerometer observations from GRACE satellites[J]. *Chinese Journal of Geophysics*, 2016, **59**(9): 3159-3174
- [15] DOORNBOS E, KLINKRAD H, VISSER P. Atmospheric density calibration using satellite drag observations[J]. *Advances in Space Research*, 2005, **36**(3): 515-521
- [16] CEFOLA P J, PROULX R J, NAZARENKO A I, *et al*. Atmospheric density correction using two line element sets as the observation data[J]. *Advances in the Astronautical Sciences*, 2004, **116**: 1953-1978
- [17] BERGSTROM S E, PROULX R J, CEFOLA P J. Atmospheric density correction using observational data[C]//AIAA/AAS Astrodynamics Specialist Conference and Exhibit.

- it. Monterey: AIAA, 2002: 4738
- [18] CHEN Xuxing, HU Xiong, XIAO Chunying, *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
- [19] PÉREZ D, BEVILACQUA R. Neural Network based calibration of atmospheric density models[J]. *Acta Astronautica*, 2015, **110**: 58-76
- [20] PÉREZ D, WOHLBERG B, LOVELL T A, *et al.* Orbit-centered atmospheric density prediction using artificial neural networks[J]. *Acta Astronautica*, 2014, **98**: 9-23
- [21] CHEN H R, LIU H X, HANADA T. Storm-time atmospheric density modeling using neural networks and its application in orbit propagation[J]. *Advances in Space Research*, 2014, **53**(3): 558-567
- [22] ZHANG Y, YU J J, CHEN J Y, *et al.* An empirical atmospheric density calibration model based on long short-term memory neural network[J]. *Atmosphere*, 2021, **12**(7): 925
- [23] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, **9**(8): 1735-1780
- [24] ZHOU H Y, ZHANG S H, PENG J Q, *et al.* Informer: Beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. Palo Alto: AAAI, 2021: 11106-11115
- [25] LIN S S, LIN W W, WU W T, *et al.* SegRNN: Segment recurrent neural network for long-term time series forecasting[OL]. (2023-08-22) [2024.12.30]. <https://arxiv.org/abs/2308.11200>
- [26] EMMERT J T, DROB D P, PICONE J M, *et al.* NRLMSIS 2.0: a whole-atmosphere empirical model of temperature and neutral species densities[J]. *Earth and Space Science*, 2021, **8**(3): e2020EA001321
- [27] VAN DEN IJSSEL J, VISSER P. Performance of GPS-based accelerometry: CHAMP and GRACE[J]. *Advances in Space Research*, 2007, **39**(10): 1597-1603
- [28] TAPPING K F. The 10.7 cm solar radio flux ($F_{10.7}$)[J]. *Space Weather-the International Journal of Research & Applications*, 2013, **11**(7): 394-406
- [29] BARTELS J. The geomagnetic measures for the time-variations of solar corpuscular radiation, described for use in correlation studies in other geophysical fields[J]. *Geomagnetism*, 2013: 227-236
- [30] KNIPP D J, TOBISKA W K, EMERY B A. Direct and indirect thermospheric heating sources for solar cycles 21-23[J]. *Solar Physics*, 2004, **224**(1/2): 495-505
- [31] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[J]. *Journal of Machine Learning Research*, 2011, **15**: 315-323
- [32] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, *et al.* Dropout: a simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, **15**(1): 1929-1958
- [33] WU D X, WANG Y S, XIA S T, *et al.* Skip connections matter: On the transferability of adversarial examples generated with resnets[OL]. (2020-02-14) [2024.12.30]. <https://arxiv.org/abs/2002.05990>
- [34] PASZKE A, GROSS S, MASSA F, *et al.* Pytorch: an imperative style, high-performance deep learning library[J]. *Neural Information Processing Systems*, 2019, **32**: 8026-8037
- [35] CHUNG J Y, GULCEHRE C, CHO K, *et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. *Eprint Arxiv*, 2014. DOI:10.48550/arXiv.1412.3555
- [36] KINGMA D P, BA J. Adam: A method for stochastic optimization[OL]. (2017-01-30) [2024-12-25]. <https://arxiv.org/abs/1412.6980>
- [37] HAN L, YE H J, ZHAN D C. The capacity and robustness trade-off: Revisiting the channel independent strategy for multivariate time series forecasting[J]. *IEEE Transactions on Automatic Control*, 2024, **36**(11): 7129-7142
- [38] WANG Hongbo, ZHANG Mingjiang, XIONG Jianning. Effects of solar extreme ultraviolet radiation on thermospheric neutral density[J]. *Chinese Journal of Space Science*, 2023, **43**(1): 87-100 (汪宏波, 张明江, 熊建宁. 太阳极紫外辐射对热层大气密度的影响[J]. *空间科学学报*, 2023, **43**(1): 87-100)
- [39] WANG Xin, MIAO Juan, LIU Siqing, *et al.* Characteristics analysis of thermospheric density response during the different intensity of geomagnetic storms[J]. *Chinese Journal of Space Science*, 2020, **40**(1): 28-41 (王昕, 苗娟, 刘四清, 等. 不同强度磁暴期间热层大气密度响应特征分析[J]. *空间科学学报*, 2020, **40**(1): 28-41)

作者简介



曹庆鹏 男, 1998年6月出生于黑龙江省牡丹江市, 现就读于中山大学人工智能学院计算机技术专业, 主要研究方向为热层大气密度经验模型校准。
E-mail: caoqingpeng11@126.com



谷德峰 (通信作者) 男, 1980年8月出生, 现为中山大学教授、博导, 人工智能学院副院长, 主要研究方向为低/中/高轨多类卫星及其编队轨道确定, 系统误差建模抑制, 时空序列智能预测。
E-mail: gudefeng@mail.sysu.edu.cn