

基于 LSTM-NN 混合模型的 $F_{10.7}$ 指数中期预报研究

刘开静¹ 董亮² 黄文耿³ 王晶³ 李牧迪^{2,4}

1 (成都东软学院 成都 611844)

2 (中国科学院云南天文台 云南昆明 650216)

3 (中国科学院国家空间科学中心, 北京 100089)

4. (中国科学院大学, 北京 100000)

摘要 针对现有基于统计分析与机器学习的时间序列预测方法在处理太阳 $F_{10.7}$ 指数序列时, 难以同步兼顾其时序依赖性与非线性特征的关键问题, 特别是太阳活动峰年期间射电爆发事件导致的指数异常波动及相应预测误差显著高于谷年的现象, 本文提出了一种太阳 $F_{10.7}$ 指数中期预测方法。该方法创新性地融合长短期记忆网络 (Long Short-Term Memory network) 与全连接神经网络 (FCNN), 并引入太阳黑子数 (SSN) 相关影响因子, 搭建了基于 LSTM-NN 的多输入变量驱动的混合预测模型。利用第 24-25 太阳活动周期期间的 $F_{10.7}$ 指数实测数据, 开展提前 7 天的预测实验。结果表明, 该模型预测相关系数达 $R=0.95$, 均方根误差 (RMSE) 为 11.11 sfu, 较 SWPC 下降约 14.87%。此外, 通过分析引入太阳黑子数作为外源输入对预测结果的改善程度发现, SSN 对太阳活动谷年预测结果的年平均修正贡献率约为 7.24%, 而对峰年预测的年平均修正贡献率提升至 15.14%。基于系统的分析与实验验证, 本研究证实了所提出的混合模型在表征复杂太阳活动特征方面的有效性, 充分挖掘 SSN 序列蕴含的信息价值, 能显著提升 $F_{10.7}$ 指数序列预测的准确性与可靠性。

关键词 太阳 $F_{10.7}$ 指数, 太阳黑子数, 长短期记忆神经网络, 多输入变量混合模型, 中期预报

中图分类号 P353

基金项目: 国家自然科学基金天文联合基金 (U2031133); 国家自然科学基金重点专项 (11941003); 云南省应用基础研究计划面上项目 (2019FB009); 云南省基础研究计划项目 (202301AT070325); 科技部平方公里阵列射电望远镜 (SKA) 专项 (2020SKA0110202); 中国科学院国际伙伴计划 (114A11KYSB20200001) 和昆明市对外 (国际) 合作基地项目 (GHJD-2021022) 资助。

Mid-term Forecasting Study of Solar $F_{10.7}$ Index

Using LSTM-NN Hybrid Model

1st LIU Kai-Jing¹ 2nd DONG Liang² 3rd HUANG Wen-Geng³ 4th WANG Jing³ 5th LI Mu-Di^{2,4}

1 (Chengdu Neusoft University, Chengdu 611844, China)

2 (Yunnan Observatories, Chinese Academy of Sciences, Kunming 650216, China)

3 (National Space Science Center, Chinese Academy of Sciences, Beijing 100089, China)

Abstract Existing methods for forecasting the solar $F_{10.7}$ index, which are primarily based on statistical analysis and machine learning, often struggle to simultaneously capture its temporal dependencies and nonlinear characteristics. This limitation is particularly evident during solar maximum periods, when radio burst events cause anomalous fluctuations in the index, leading to prediction errors significantly higher than those during solar minimum. To address this critical challenge, this paper proposes a mid-term forecasting method for the solar $F_{10.7}$ index. The approach innovatively integrates a Long Short-Term Memory (LSTM) network with a Fully Connected Neural Network (FCNN) and incorporates the sunspot number (SSN) as a key influencing factor, establishing a hybrid prediction model driven by multiple input variables. Prediction experiments for a 7-day horizon were conducted using measured $F_{10.7}$ index data from Solar Cycles 24 and 25. The results demonstrate that the model achieves a correlation coefficient of $R=0.95$ with the observed values and a Root Mean Square Error (RMSE) of 11.11 sfu, representing an approximate 14.87% reduction in RMSE compared to the SWPC baseline. Furthermore, analysis of the improvement attributable to introducing SSN as an exogenous input variable revealed that the average annual correction contribution of SSN was about 7.24% for predictions during solar minimum years, increasing to 15.14% for predictions during solar maximum years. Systematic analysis and experimental validation confirm the effectiveness of the proposed hybrid model in characterizing complex solar activity features. By fully leveraging the informational value embedded in the SSN series, the model significantly enhances the accuracy and reliability of $F_{10.7}$ index forecasts.

Keywords Solar $F_{10.7}$ index, Sunspot number, Long short-term memory neural network, Multi-input hybrid model, midrange forecasting

*****以下是正文部分相关要求 (单栏、双栏不作要求, 对于已接收发表的稿件, 编辑部会自行排版)

0 引言

作为地球生命赖以生存的能量来源, 太阳活动通过电磁辐射与带电粒子流持续作用于地球空间环境^[1-3]。其中, 太阳 $F_{10.7}$ 指数 (10.7 cm 射电流量) 作为表征太阳活动强度的关键参数, 因其与太阳黑子数 (SSN) 保持高度相关性 (相关系数达 0.96^[4]) 且具备客观的观测特性, 已成为当前空间环境建模中不可或缺的核心指标^[5-7]。然而, 该指数序列呈现显著的非平稳特性与复杂的非线性动力学行为, 尤其在太阳活动峰年期间, 频繁发生的射电爆发事件常导致传统预测方法失效^[8]。

在预测方法研究领域, 早期研究主要基于经验公式与"相似周"方法^[8-9]。此类方法虽能

有效反映太阳活动的基本周期特征，但对短期突变行为的捕捉能力存在局限。随着研究的深入，自回归模型^[10]等统计方法在太阳活动宁静期展现出良好的预测性能，但其线性假设难以适配活动峰年的动态演化特征。机器学习方法（如支持向量机 SVM^[11]、人工神经网络 ANN^[12]）通过引入非线性建模机制，将预测精度提升了约 15%^[13]，但在特征自动提取维度仍存在优化空间。近年来，以长短期记忆网络 LSTM^[14]为代表的深度学习方法凭借其卓越的时序建模能力，在太阳活动预测领域取得突破性进展——Wang 等^[15]构建的 LSTM 模型将预测误差降至 13.7 sfu。值得注意的是，Bruevich 等^[4]与高等^[16]的研究证实，通过融合 SSN 等多源观测数据构建混合模型可进一步提升预测效能，其改进的长短期记忆混合模型（M-LSTM）将预测误差降至 11.62 sfu。美国空间天气预报中心（Space Weather Prediction Center, SWPC）结合经验模型、线性回归、人工修正等方法，实现了对太阳黑子数和太阳耀斑的常态化业务化预测，其发布的世界数据中心（WDC）指数被广泛用于空间天气预警与卫星轨道预报，其相关系数 R 在 0.8-0.9 左右。

本文创新性地提出一种混合预测框架，该方法的核心创新体现在：

- （1）采用信号分解技术将原始序列解耦为多个具有明确物理意义的子成分；
- （2）构建 LSTM 与深度神经网络的混合架构，分别对各子成分的动态特性进行精准建模；
- （3）引入 SSN 等辅助特征以增强模型的物理可解释性。基于 2011-2021 期间的 $F_{10.7}$ 指数实测数据，利用多输入变量驱动的 LSTM-NN 混合模型，开展提前 7 天的预测实验。

经过对比检验，本研究提出的混合模型在测试周期内预测性能明显优于基准模型（单输入 LSTM 模型），其预测结果与真实值之间的相关系数高达 0.95，均方根误差（RMSE）为 11.11 sfu。该混合模型能够有效捕捉太阳活动中的复杂特征，充分提取太阳黑子数序列中的物理信息，显著提高了 $F_{10.7}$ 指数短期预测的精确度与稳健性。

1 $F_{10.7}$ 和 SSN 时间序列处理分析

1.1 数据来源

本研究选取太阳 $F_{10.7}$ 指数与太阳黑子数作为关键参数，用以分析太阳活动的周期性及趋势特征并进行模型训练。相关数据从两个可靠来源获取，其详细获取过程与来源信息如

下所述。

1) 太阳 $F_{10.7}$ 指数的数据是通过访问基于欧洲空间天气数据中心 Radio Solar and Space Physics Laboratory (RSPL) 发布的太阳射电观测数据 (网站: https://chain-new.chain-project.net/echaim_downloads/apf107.dat) 而获得的, 该数据库提供了自 1958 年 1 月 1 日至今无间断的长期太阳活动观测数据^[17]。

2) 太阳黑子数据取自 SILSO 网站 (<https://wwwbis.sidc.be/silso/datafiles>) 获取。其数据库收录了太阳黑子数的不同时间分辨率指标, 具体包括日均值、月均值与平滑月均值^[17]。每日总太阳黑子数通过公式 1 计算得出:

$$R = N_s + 10 \times N_g \quad (1)$$

其中 N_s 为斑点数, N_g 为整个太阳盘上计数的斑点群数。

为满足研究需求, 对数据进行了如下预处理: (1) 选用 1958 年 1 月 1 日至 2023 年 9 月 17 日期间的 $F_{10.7}$ 指数数据与 SSN 数据作为研究样本, 共计 24001 个样本数据。该时间范围覆盖了多个完整的太阳活动周期 (如图 1 与图 2 所示), 有助于全面捕捉太阳活动的周期性特征与长期趋势。(2) 对上述时间段内的数据进行了异常值与缺失值的排查与处理。(3) 划分训练集与测试集, 如图 1 与图 2 所示, 训练集由蓝色实线表示 (占全部样本 80.0%), 测试集由橙色实线表示 (占全部样本 20.0%)。样本中, 太阳 $F_{10.7}$ 射电流量的变化区间为 63.4 至 367.0 sfu, 太阳黑子数的变化区间为 0 至 484, 相比之下, 太阳黑子数的相对离散程度更高。




图 1 1958 到 2023 年的 $F_{10.7}$ 的数据

Figure 1. F_{10.7} data from 1958 to 2023




图 1 1958 到 2023 年的 SSN 的数据

Figure 2. SSN data from 1958 to 2023

1.2 数据标准化

不同来源的样本数据往往存在显著的尺度差异，这对机器学习模型的性能产生重要影响。数据标准化不仅能优化训练过程，使梯度方向更加明确、加速模型收敛，还能提高模型鲁棒性，减少异常值干扰和过拟合风险。最值归一化（Min-Max Normalization）可将数值型数据缩放到特定范围内，若原始数据 x 中最小值为 $x_{\min}$ ，最大值为 $x_{\max}$ ，其归一化表达式为：

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

为便于后续分析与建模，对太阳 F_{10.7} 指数和太阳黑子数的原始时间序列进行了最值归一化处理，将其无量纲化至[0, 1]区间，如图 3 所示，F_{10.7} 指数和 SSN 序列存在内在关联与有序性，其相关系数高达 0.96，为揭示太阳活动的演化规律及其对地球空间环境的影响提供了基础。其中，黑子数从极小值到极大值的相对变化幅度更大，对其物理机制的差异具有指示意义。




图 3 $F_{10.7}$ 和 SSN 序列归一化

Figure 3. Normalization of $F_{10.7}$ and SSN series

本研究所用数据横跨 5-6 个完整的太阳活动周期，分析显示，作为不同物理量的太阳 $F_{10.7}$ 指数与 SSN，其长期波动趋势具有一致性，共同验证了太阳活动约 11 年的准周期循环特征。然而在局部区间内，SSN 序列的波动幅度较太阳 $F_{10.7}$ 指数更为剧烈，其周期性特征也更为显著。

1.3 序列分解

STL (Seasonal and Trend decomposition using Loess) 是基于局部加权回归的季节趋势分解方法。它将时间序列 Y_v 分解为季节项 S_v 、趋势项 T_v 和残差项 R_v 三个组成部分，如公式 3 所示。

$$Y_v = T_v + S_v + R_v, v = 1, \dots, N \quad (3)$$

STL 分解包含内、外两个循环。内循环首先通过局部加权回归技术，依次计算趋势分量与季节分量。随后，外循环根据拟合残差计算鲁棒权重，并在下一轮内循环中赋予观测值，以抑制异常值的影响。

内循环的 6 个步骤如下：

(1) 令初始情况下趋势分量 $T_v^{(0)} = 0$ ，将原始数据 Y_v 减去上一次（第 k 次）迭代得到的趋势分量 $T_v^{(k)}$ ，得到序列 $Y_v - T_v^{(k)}$ ，该序列包含了当前的季节性信息和残差，；

(2) 对去除季节性的序列进行 LOESS 回归平滑以估计趋势项，将序列首尾各延长一

个周期以处理边界效应，并设定平滑参数为 $n_{(s)}$ ，将平滑结果记为 $C_v^{(k+1)}$ ；

(3) 采用低通滤波对平滑结果 $C_v^{(k+1)}$ 依次进行窗口长度为 $n_{(p)}$ 、 $n_{(p)}$ 、3 的滑动平均，继而做参数为 $n_{(l)}$ 的 LOESS 回归，生成最终长度为 N 的趋势序列 $L_v^{(k+1)}$ ；

(4) 去除 $C_v^{(k+1)}$ 的趋势， $S_v^{(k+1)} = C_v^{(k+1)} - L_v^{(k+1)}$ ；

(5) 去除季节分量， $Y_v - S_v^{(k+1)}$ ；

(6) 对趋势分量做平滑处理，对步骤 (5) 得到的序列 $Y_v - S_v^{(k+1)}$ 进行 LOESS 平滑，得到本轮最终的趋势分量 $T_v^{(k+1)}$ 。据此判断模型是否收敛：若收敛，循环结束并输出全部分解项；若不收敛，则选取当前分量返回步骤 (1)，并基于新的残差权重开始下一轮迭代。

STL 分解的外循环通过调节鲁棒权重以抑制异常值影响。当某数据点为异常值时，其残差较大，于是定义 $h = 6 * \text{median}(|R_v|)$ ，在 v 位置上数据点的鲁棒权重更新为 $\delta_v = B(\frac{|R_v|}{h})$ ，做鲁棒局部加权回归时乘上 δ_v ，从而在内循环 LOESS 回归中降低该点的权重，减弱其对拟合结果的影响。

通过对太阳 $F_{10.7}$ 指数的时间序列进行 STL 分解，太阳活动的主要模态（长期趋势、准周期波动和随机扰动）得以量化。图 4 展示了 1958-2023 年国际太阳 $F_{10.7}$ 指数数据的 STL 分解结果。其中，(a)原始数据；(b)趋势分量揭示了太阳活动的长期演变规律，是预测未来活动水平的关键；(c)季节性分量以相似的强度和频率重复出现，对于理解太阳活动的内在规律至关重要，该分量以 365 天为周期重复出现，其强度和频率在不同周期中表现一致，图中展示了 8 个年份的数据，值得注意的是，因闰年影响，分量的具体走势存在轻微偏移；(d)残差分量则反映了剔除趋势和周期后剩余的随机波动，具有高度不确定性。

通过对趋势、季节性与残差三个分量分别进行建模预测，能有效降低它们之间的耦合效应，从而更精确地预测 $F_{10.7}$ 指数的未来走势与周期变化，更好地理解太阳活动的变化。




图 4(a) STL 算法分解时间序列-原始数据

Figure 4(a). Time series decomposition using STL algorithm - Original data




图 4(b) STL 算法分解时间序列-趋势分量

Figure 4(b). Time series decomposition using STL algorithm - Trend component




图 4(c) STL 算法分解时间序列-季节性分量

Figure 4(c). Time series decomposition using STL algorithm - Seasonal component




图 4(d) STL 算法分解时间序列-残差分量

Figure 4(d). Time series decomposition using STL algorithm - Residual component

2 LSTM-NN 混合模型

2.1 LSTM 神经网络

长短期记忆网络通过创新的门控机制（输入门、遗忘门和输出门）为时序预测提供了有效的解决方案，其核心在于选择性记忆机制能够动态调节信息流，既能保留长期关键特征又可过滤噪声干扰。这种结构不仅解决了梯度不稳定问题，更展现出对太阳活动等非平稳时序数据的卓越建模能力。在太阳 $F_{10.7}$ 指数预测应用中，LSTM 的遗忘门可智能识别太阳活动周期特征，而输入门能精准捕捉耀斑爆发等突变事件，显著提升了预测精度。

LSTM 结构如图 5 所示，LSTM 网络由输入层、隐含层和输出层组成，通过内部的门控机制和细胞状态，LSTM 克服了传统 RNN 的梯度问题，实现了更稳定、高效的训练。




图 5 长短时记忆神经网络单元结构

Figure 5. Structure of the Long Short-Term Memory neural network unit

假定长短期记忆网络模型结构中输入变量为 $x_t \in R^{n \times d}$ ， n 为输入数据批量大小， d 为输入数据长度，隐藏单元个数为 h ， $t-1$ 时刻的隐藏状态为 $h_{t-1} \in R^{n \times h}$ ， t 时刻的输入门、遗忘门、输出门分别为 $i_t \in R^{n \times h}$ 、 $f_t \in R^{n \times h}$ 、 $o_t \in R^{n \times h}$ ，其表达式如式 4、5、6 所示。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) = \sigma(x_t W_{xi} + h_{t-1} W_{hi} + b_i) \quad (4)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) = \sigma(x_t W_{xf} + h_{t-1} W_{hf} + b_f) \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) = \sigma(x_t W_{xo} + h_{t-1} W_{ho} + b_o) \quad (6)$$

其中 $W_{xi}, W_{xf}, W_{xo} \in R^{d \times h}$ 和 $W_{hi}, W_{hf}, W_{ho} \in R^{h \times h}$ 为权重矩阵， $b_i, b_f, b_o \in R^{1 \times h}$ 为偏置项。

可由式 7、8 计算出当前的细胞单元状态 c_t 。

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \quad (8)$$

其中 W_c 为权重矩阵， b_c 为偏置项。

基于当前细胞状态和输出门，计算当前隐藏状态，即最终输出，如公式 9 所示：

$$h_t = o_t \cdot \tanh(c_t) \quad (9)$$

其中 $\tanh$ 是激活函数。

2.2 改进 LSTM 神经网络

由于太阳 $F_{10.7}$ 指数具有显著的非线性、非平稳性及复杂的周期性特征，为有效捕捉其

演化规律，需要构建具有较多隐藏单元的 LSTM 模型，这直接导致模型权重矩阵的维度随网络复杂度的增加而显著增大，参数数量激增，进而使得模型在训练过程中收敛速度缓慢，有限的训练时间成为模型性能提升的瓶颈，迭代不足使其难以完成充分的参数寻优，这限制了模型达到最佳性能的可能性，并直接影响预报准确率。

如图 6 所示，将 LSTM 的遗忘门与当前信息状态耦合形成复合遗忘门，改进型 LSTM 结构不仅继承了 LSTM 固有的记忆与遗忘机制，还能依据当前输入更动态地决定对历史信息的保留程度，缩短了太阳 F_{10.7} 指数预报模型训练时长，更有效地提取数据的特征。




图 6 改进的 LSTM 结构示意图

Figure 6. Schematic Diagram of the Improved LSTM Structure

改进后的 LSTM 模型的关键变量计算公式(10-15)如下：

$$m_t = \sigma(W_m \cdot [h_{t-1}, x_t] + b_m) = \sigma(W_{mh} h_{t-1} + W_{mx} x_t + b_m) \quad (10)$$

$$i_t = \tanh(W_i \cdot [h_{t-1}, x_t] + b_i) = \tanh(W_{ih} h_{t-1} + W_{ix} x_t + b_i) \quad (11)$$

$$c_t = (1 - m_t) \times i_t + m_t \times c_{t-1} \quad (12)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) = \sigma(W_{oh} h_{t-1} + W_{ox} x_t + b_o) \quad (13)$$

$$h_t = o_t \times \tanh(c_t) \quad (14)$$

$$y_t = \sigma(W_y \cdot h_t + b_y) \quad (15)$$

其中， m_t 是 t 时刻的新遗忘门的输出， σ 是激活函数， W_m 、 W_i 、 W_o 、 W_y 为权重， b_m 、 b_i 、 b_o 、 b_y 为偏置， y_t 是输出层输出预测值。

本实验采用 LSTM 网络和改进型复合遗忘门 LSTM 网络分别进行模型搭建，使用相同的 F_{10.7} 指数数据集进行训练分析。两种模型的参数配置如表 1 所示。

在模型结构方面，改进型 LSTM 在标准 LSTM 基础上引入了复合遗忘门机制，将当前输入信息动态耦合到遗忘决策中，形成了更智能的记忆管理机制，主要的结构参数如输入

维度(1)、隐藏层维度(64)、层数(2)等保持一致。

通过对比两种模型在测试集上的表现，其提前 7 天预测结果误差分析结果如表 2 所示。改进型 LSTM 在保持主要参数不变的前提下，通过结构优化实现了训练效率和预测精度的全面提升，改进型 LSTM 的训练时长缩短了 39%，收敛所需 epoch 数减少了 23%，各项误差指标（包括 MSE、RMSE、MAE 和 MAPE）均有不同程度下降，其中 MAPE 降低了 1.38%。

表 1 LSTM 网络和改进型复合遗忘门 LSTM 网络模型的参数配置

Table 1. Parameter configuration of LSTM network and improved composite forget gate LSTM network model

参数类别	参数名称	LSTM 设置值	改进型 LSTM 设置值
核心结构	遗忘门机制	标准遗忘门	复合遗忘门
	LSTM 实现	nn.LSTM	自定义 LSTMCell
数据参数	序列长度 (seq_length)	54	54
	训练集比例	0.8	0.8
	批处理大小 (batch_size)	32	32
模型结构	输入维度 (input_size)	1	1
	隐藏层维度 (hidden_size)	64	64
	LSTM 层数 (num_layers)	2	2
	Dropout 率	0.2	0.2
训练参数	优化器	Adam	Adam
	学习率 (lr)	0.001	0.001
	权重衰减	1e-5	1e-5
	损失函数	MSELoss	MSELoss
	训练轮数 (epochs)	200	200
	梯度裁剪	1.0	1.0
学习率调度	调度器	ReduceLROnPlateau	ReduceLROnPlateau
	耐心值 (patience)	10	10
	衰减因子 (factor)	0.5	0.5

表 2 LSTM 网络和改进型复合遗忘门 LSTM 网络模型提前 7 天预测结果误差

Table 2. Prediction error of LSTM network and improved compound forget-gate LSTM network model 7 days in advance

	训练时长 (秒/epoch)	收敛所需 epoch 数	训练损失	MSE (均方误差)	RMSE (均方根误差)	MAE (平均绝对误差)	MAPE (平均绝对百分比误差)
LSTM	18.5	78	4.38×10^{-3}	231.24	15.21	9.97	8.72%
改进型 LSTM	11.2	60	4.01×10^{-3}	231.02	15.20	9.86	8.60%
提升幅度	39%	23%	8.45%	0.09%	0.05%	1.07%	1.38%

2.3 基于 LSTM-NN 混合模型预报方法

本研究构建了一个由改进 LSTM 结构与全连接神经网络组成的预测模型。该模型利用改进的 LSTM 结构自动学习太阳 F_{10.7} 指数历史数据中的深层特征，在保证高预测精度的同时，凭借其更快的收敛速度显著提升了训练与预测效率。为精准预测太阳 F_{10.7} 指数，需同

时利用其自身的时间序列规律及其与太阳黑子数等因子的关联。鉴于 LSTM 网络擅长捕捉时序依赖，而全连接神经网络作为深度神经网络（DNN）一个分支，通过多层非线性变换实现对复杂数据特征的高效提取，能更简洁地处理静态特征间的复杂非线性映射，将历史 F_{10.7} 指数子序列输入 LSTM 以提取时序模式，同时将 LSTM 的输出特征与太阳黑子数相关因子一并输入全连接神经网络，从而融合时序与关联特征进行最终预测，该结构在提升特征提取能力的同时，简化了模型设计。

LSTM-NN 混合模型结构如图 7 所示，第 1 层为（F_{10.7} 指数）输入层，将数据分解为三个子序列，第 2 层为应用于趋势和残差分量的改进型长短期记忆网络层、应用于季节分量的季节性预测器，第 3 层为（联合 SSN 数据）输入层，在第 1 层对原始 F_{10.7} 指数数据进行预处理，即 STL 分解得到趋势、季节和残差三个子序列 X_1, X_2, X_3 后，进行标准化处理，并分别划分为固定长度为 M 的时序片段，每个样本 $x_{1train} \in R^{M \times 1}, x_{2train} \in R^{M \times 1}, x_{3train} \in R^{M \times 1}$ ， $x = [x_1, x_2, \dots, x_M]^T$ ， $v \in R^{M \times 1}$ ，第 2 层在 t 步输出表示为：LSTM 模型输出 $h_t = LSTM(h_{t-1}, x_{train})$ ， $t \in [1, M]$ 、季节性预测器输出 $h_t = h_{t-4 \times 365}$ ；第 3 层将每个子序列逆分解（重构）为 H ，再与 SSN 序列 F_{train} ， $F_{train} = R^{M \times D}$ 拼接为新矩阵 $x' = \text{concat}(h_t, F_{train}) = [h_t, F_{train}]$ 。

第 4、5 层均为全连接神经网络层，将 x' 传输入第 4 层，输出记为 $H_1' \in R^{M \times H_1}$ ，再将 H_1' 输入到第 5 层，输出记为 $H_2' \in R^{M \times H_2}$ 。

第 6 层为输出层，输出结果为 $y_p = FCNN(H_2')$ ， $y_p \in R^{N \times 1}$ ，即太阳 F_{10.7} 指数预报值。




图 7 LSTM-NN 混合模型的结构

Figure 7. Structure of the LSTM-NN hybrid model

LSTM-NN 混合模型用于太阳 $F_{10.7}$ 指数中期预报的完整工作流程如图 8 所示。模型首先对原始 $F_{10.7}$ 时间序列进行趋势-季节-残差分解（周期设置为 365）。趋势分量、残差分量预测采用改进的 LSTM 网络，网络包含三层 LSTM 结构，每层隐藏单元数为 50，输入序列长度设置为 54 个时间步，并引入自注意力机制以增强对关键时间特征的捕捉能力。季节性分量预测基于太阳活动的四年周期性规律，采用历史同期参考法，直接引用四年前同日的季节性分量值作为预测输出。经反 STL 分解，得到阶段性的太阳 $F_{10.7}$ 指数预测值。随后引入太阳黑子数作为外部修正因子，SSN 修正模块采用四层全连接神经网络架构，隐藏层节点数依次为 64、32、16，输出维度为 1，以前一阶段的集成预测结果、同期太阳黑子数观测值作为输入特征，通过学习预测误差与太阳活动水平之间的非线性关系，生成动态修正量。




图 8 基于 LSTM-NN 混合模型太阳 $F_{10.7}$ 指数中期预报算法流程

Figure 8. Mid-term forecasting algorithm for solar $F_{10.7}$ index based on the LSTM-NN hybrid model

3 混合模型预报实验分析

本研究基于 PyTorch 框架构建了 LSTM-NN 混合预报模型，将太阳 $F_{10.7}$ 指数经 STL 分解得到的趋势、残差子序列分别输入 LSTM 网络进行训练，输入尺度设定为两个太阳自转周期（54 天），优化器采用 Adam 算法（Adaptive Moment Estimation）以自适应调整学习率，学习率设置为 0.001，配合 Dropout 正则化（比率为 0.2）和权重衰减（ $1e-5$ ）防止过拟合，训练周期为 100 轮次，批量大小为 32。随后，将 LSTM 网络的输出以及季节性预测器输出重构为初步预测值，并输入全连接网络进行修正，最终得到 $F_{10.7}$ 指数的预报结果。图 9（a）展示了应用于趋势分量的改进型 LSTM 模型在 Adam 优化器下的训练损失收敛过程，反映了损失函数值随训练轮次增加而下降的趋势，图 9（b）则对应的是残差分量模型的损失函数。




图 9(a) 趋势分量模型损失值变化详情

Figure 9(a). Details of Trend Component Model Loss Value Changes




图 9(b) 残差分量模型损失值变化详情

Figure 9(b). Detailed Changes in Residual Component Model Loss Values

训练过程中，趋势分量模型损失值达到 4.8×10^{-5} 后缓慢波动并趋于平稳，表明模型已充分收敛。基于此收敛态势，选取第 57 次迭代的模型参数作为最终结果，以在保证性能的同时避免过拟合。残差分量模型损失值达到 4.1×10^{-3} 后缓慢波动并趋于平稳，则选取第 86 次迭代的模型参数作为最终结果。

将 STL 分解后的子序列分别输入改进的 LSTM 网络、季节性预测器进行预测，各分量及预测结果的误差评估如表 3 所示。从表中数据可以清晰地看出，不同分量在预测模型中的贡献与挑战截然不同。首先，趋势分量与季节性分量的拟合精度极高，其各项误差指标（MSE, RMSE, MAE, MAPE）均趋近于零。这一结果强有力地证明，模型能够出色地捕捉并复现太阳活动中存在的长期趋势性与规律性周期变化，这构成了实现高精度预测的坚实基础。

然而，与上述高度确定性的分量形成鲜明对比的是，残差分量表现出极大的不确定性，成为预测误差的主导来源。其 MAPE 值高达 272.53%，MAE 也达到 9.6052，远超其他分量。这表明，残差分量中蕴含了太阳活动内在的、难以通过确定性模型捕捉的随机波动与复杂非线性相互作用。这部分噪声或随机性，是制约预测模型精度进一步提升的关键瓶颈。

在此背景下，本文所提出 LSTM-NN 混合预报模型修正方法的有效性得到了充分验证。经 SNN 相关影响因子修正后，测试集（2010-2023 年间样本数据）最终预测结果相较于未修正结果实现了全面的性能优化。具体而言，均方根误差（RMSE）从 12.05 显著降低

至 11.27，降幅约 6.50%；同时，平均绝对百分比误差（MAPE）从 7.06%降低至 6.49%。这两个关键指标的同步下降，不仅从数值上证实了修正策略的成功，更从机理上说明该方法有效地抑制了残差波动对最终预测结果的部分负面影响，成功地从原始信号中提取出了更具规律性和可预测性的信息，从而将模型的整体预测精度提升到了一个新的水平。此外，通过分析引入太阳黑子数作为外源输入对预测结果的改善程度发现，SSN 对太阳活动谷年预测结果的修正贡献率为 7.24%，而对峰年预测的修正贡献率提升至 15.14%。该结果印证了 SSN 在提升模型预报能力，尤其是在刻画活动高年复杂动态过程中的物理价值。

表 3 模型输出各分量及预测结果的误差

Table 3. Errors of each component of the model output and the prediction results

分量	MSE(均方误差)	RMSE(均方根误差)	MAE(平均绝对误差)	MAPE(平均绝对百分比误差)
趋势分量	0.5547	0.7448	0.5645	0.54%
季节分量	0	0	0	0%
残差分量	201.8276	14.2066	9.6052	272.53%
未修正的预测值	145.2692	12.0528	7.7457	7.06%
修正的预测值	129.6769	11.27	7.1234	6.49%

为全面评估模型的预测性能，本文选取了最佳与最差预测时段，分别对 F_{10.7} 太阳辐射通量的原始预测结果、修正后结果及其趋势、季节性与残差分量进行了对比分析。在最佳预测时段（2019-07-29 至 2019-12-25）中，模型表现出较高的预测精度，详情如图 10-14（a）所示。未经修正的 F_{10.7} 预测值的 MAE 与 RMSE 分别为 2.92 sfu 与 3.47 sfu；经 SSN 相关影像因子修正后，两项误差指标进一步下降至 2.32 sfu 与 2.94 sfu，表明引入 SSN 策略有效提升了预测准确性。进一步分析其构成分量可见，趋势、季节性分量的拟合近乎完美，说明模型能完整捕捉该时段趋势性、周期性变化；而残差分量的预测也较为理想（MAE: 2.82, RMSE: 3.36），反映出模型对随机波动成分仍具备一定的拟合能力。

相比之下，在最差预测时段（2014-06-08 至 2014-11-04）中，模型整体误差显著增大，详情如图 10-14（b）所示。未修正 F_{10.7} 预测的 MAE 与 RMSE 分别上升至 21.09 sfu 与 25.59 sfu，修正后预测误差仍处于高位（MAE: 17.87 sfu, RMSE: 22.26 sfu），说明该时段内太阳活动噪声强度大、非线性特征突出，是影响整体预测精度的关键瓶颈。图 11 残差分量项子序列输出存在比较明显的相位差异，对于时间序列预测模型通常隐含着数据平稳性的假设，但太阳活动，尤其是在活动周上升期和高年，具有强烈的非平稳特性。新的爆发性活动区的出现会突然改变 F_{10.7} 的变化趋势，模型难以准确预测这些突变事件的精确发生时间，从而表现为相位的整体偏差。

综合两个时段的对比可知，本文提出的模型能稳定且精确地捕捉 F_{10.7} 序列中的趋势与

季节性规律；而预测性能的波动主要受残差分量影响，其在平静期拟合良好，在活跃期则成为误差主因，修正方法在困难时段能一定程度上抑制误差。




图 10(a) 趋势分量项子序列的改进的 LSTM 网络最佳预测时段输出结果
Figure 10(a) . Output results of the improved LSTM network for the trend component sub-sequence during the best prediction period




图 10(b) 趋势分量项子序列的改进的 LSTM 网络最差预测时段输出结果
Figure 10(b) . Output results of the improved LSTM network for the trend component sub-sequence during the worst prediction period




图 11(a) 残差分量项子序列的改进的 LSTM 网络最好预测时段输出结果
Figure 11(a). Output results of the improved LSTM network for the residual component sub-series during the best prediction period




图 11(b) 残差分量项子序列的改进的 LSTM 网络最差预测时段输出结果
Figure 11(b). Output results of the improved LSTM network for the residual component sub-series during the worst prediction period




图 12(a) 季节分量项子序列的季节性预测器最好预测时段输出结果
Figure 12(a). Output results of the seasonal predictor for the seasonal component subseries during the best prediction periods




图 12(b) 季节分量项子序列的季节性预测器最差预测时段输出结果
Figure 12(b). Output results of the seasonal predictor for the seasonal component subseries during the worst prediction periods




图 13(a) 重构序列最好预测时段输出结果
Figure 13(a). Output results of Reconstruct sequence during the best prediction periods




图 13(b) 重构序列最差预测时段输出结果
Figure 13(b). Output results of Reconstruct sequence during the worst prediction periods




图 14(a) 引入 SSN 到 FCNN 网络修正预测序列的最好预测时段输出结果

Figure 14(a). Output results of Incorporating SSN into the FCNN Network to Refine Predicted Sequences during the best prediction periods




图 14(b) 引入 SSN 到 FCNN 网络修正预测序列的最差预测时段输出结果

Figure 14(b). DOutput results of Incorporating SSN into the FCNN Network to Refine Predicted Sequences during the worst prediction periods

本研究通过 LSTM-NN 混合模型对太阳 $F_{10.7}$ 指数开展了提前 7 天的预报实验。图 15 展示了 2011 年至 2021 年期间各个年份预测误差与相关系数的变化趋势，表 4 详细列出了各项评估指标的具体数值。实验结果表明，该模型的预报性能与太阳活动水平密切相关：在太阳活动高年， $F_{10.7}$ 波动剧烈，模型预报误差相对较大，RMSE 为 20.04 sfu，MAPE 为 10.45%，NMSE 为 0.21，相关系数 R 为 0.89；而在太阳活动低年， $F_{10.7}$ 变化平缓，模型预报精度显著提升，RMSE 约为 4 sfu，MAPE 低于 4.6%，NMSE 为 0.05 左右，相关系数 R 达到 0.98。整体而言，所有年份的相关系数均保持在 0.89 以上，NMSE 普遍低于 0.21，表明模型能够有效捕捉 $F_{10.7}$ 的变化规律，其预报效果显著优于基准方法，展现出良好的稳定

性和预报能力，具备应用于实时空间天气预警与服务的潜力。




图 15 采用 LSTM-NN 混合模型预报 2011 年至 2021 年期间 $F_{10.7}$ 提前 7 天预报实验结果

Figure 15. Experimental results of 7-day-ahead $F_{10.7}$ forecast from 2011 to 2021 using an LSTM-NN hybrid model

表 4 采用 LSTM-NN 混合模型预报 2011 年至 2021 年期间 $F_{10.7}$ 提前 7 天预报实验结果误差和平均相关系数

Table 4. Experimental results of forecasting $F_{10.7}$ seven days in advance using an LSTM-NN hybrid model for the period 2011 to 2022 , including errors and average correlation coefficients

Year	RMSE(sfu)	MAPE(%)	NMSE	R
2011	13.86	9.11	0.15	0.92
2012	12.79	7.95	0.13	0.93
2013	10.81	6.89	0.10	0.95
2014	20.04	10.45	0.21	0.89
2015	15.67	9.24	0.18	0.91
2016	8.70	7.31	0.09	0.96
2017	8.36	6.14	0.08	0.96
2018	3.95	4.52	0.05	0.98
2019	4.10	4.59	0.05	0.98
2020	4.58	4.61	0.07	0.97
2021	6.26	5.68	0.07	0.96

本章构建的联合太阳黑子数的 LSTM-NN 混合模型，其预报性能显著优于单变量输入

的 LSTM 模型。对 2011 年至 2021 年期间样本进行提前七天的预报结果显示，相关系数 R 达 0.95，RMSE 为 11.11，与本文的基准 LSTM 模型（RMSE=15.21）相比，误差整体降低 27%，与 LSTM 模型^[15]相比降低 19%，与 M-LSTM^[16]相比降低 3%，相较于 SWPC 下降约 14.87%。

与传统单一模型相比，该集成框架展现出更强的鲁棒性和泛化能力。分量分解策略有效隔离了噪声干扰，多时间尺度融合机制兼顾了短期动态与长期规律，端到端的训练方式确保了各模块的协同优化。实验结果表明，该模型在长期预测任务中能够保持稳定的性能表现，为空间天气业务化预报提供了可靠的技术支撑，同时也为类似具有复杂周期性和外部影响的时间序列预测问题提供了可借鉴的解决方案框架。

4 总结

本文构建了 LSTM-NN 混合神经网络模型，开展了太阳活动 $F_{10.7}$ 指数的高精度预测研究。针对 2011 年至 2021 年期间提前 7 天的预测精度评估结果为：相关系数 R 达到 0.95，整体均方根误差为 11.11 sfu，预报结果的均方根误差相较于 SWPC 下降约 14.87%。在太阳活动低年，模型能实现极高精度的预报（RMSE 约 4 sfu， $R>0.97$ ）；即便在波动剧烈的活动高年，模型仍能保持稳健的趋势捕捉能力（ R 为 0.89）。研究结果表明，本文所构建的预测模型通过深入挖掘历史数据中的潜在模式与发展趋势，能精准捕捉太阳活动的非线性特征，从而实现对太阳活动水平的可靠预测。通过将 LSTM-NN 混合模型与太阳黑子数量相结合，能够有效提高 $F_{10.7}$ 指数的预测精度，预测结果展现出高度的相关性及较低的误差水平。研究成果可为基于我国自主的精密流量太阳射电望远镜的 $F_{10.7}$ 指数观测数据预测分析提供重要技术支撑。

参考文献

- [1] ZHANG Hanke, SHEN Fang. Application of data assimilation in space weather[J]. *Chinese Journal of Space Science*, 2022, 42(3): 422-436 (张晗可, 沈芳. 数据同化在空间天气学中的应用[J]. 空间科学学报, 2022, 42(3): 422-436)
- [2] XIAO Ziniu. Impact of solar activity on Earth's climate[J]. *Chinese Journal of Nature*, 2021, 43(6): 408-419 (肖子牛. 太阳活动对地球气候的影响[J]. 自然杂志, 2021, 43(6): 408-419)
- [3] MANGLA S, CHAKRABORTY S, DATTA A, *et al.* Exploring Earth's ionosphere and its effect on low radio frequency observation with the uGMRT and the SKA[J]. *Journal of Astrophysics and Astronomy*, 2023, 44(1): 2

- [4] BRUEVICH E A, BRUEVICH V V, YAKUNINA G V. Changed relation between solar 10.7-cm radio flux and some activity indices which describe the radiation at different altitudes of atmosphere during cycles 21-23[J]. *Journal of Astrophysics and Astronomy*, 2014, **35**(1): 1-15
- [5] SCAFETTA N, BIANCHINI A. Overview of the spectral coherence between planetary resonances and solar and climate oscillations[J]. *Climate*, 2023, **11**(4): 77
- [6] KORSCHINEK G, FAESTERMANN T. Recent nucleosynthesis in the solar neighbourhood, detected with live radionuclides[J]. *The European Physical Journal A*, 2023, **59**(3): 52
- [7] TANG Cheng, LI Jiawei, ZHANG Xiaoxin, *et al.* TIEGCM numerical study on the thermospheric density response to solar $F_{10.7}$ radio flux variations during the 23rd solar cycle[J]. *Chinese Journal of Space Science*, 2021, **41**(5): 704-714 (唐成, 李嘉巍, 张效信, 等. 第 23 太阳活动周热层大气密度对太阳辐射指数 $F_{10.7}$ 响应的模拟研究[J]. 空间科学学报, 2021, **41**(5): 704-714)
- [8] WANG Hongbo, XIONG Jianning, ZHAO Changyin. The mid-term forecast method of solar radiation index $F_{10.7}$ [J]. *Acta Astronomica Sinica*, 2014, **55**(4): 302-312 (汪宏波, 熊建宁, 赵长印. 太阳辐射指数 $F_{10.7}$ 的中期预报方法[J]. 天文学报, 2014, **55**(4): 302-312)
- [9] WANG Jialong, HAN Yanben. “similar cycle” method and a discussion of predicted monthly sunspot numbers for solar cycle 23[J]. *Chinese Journal of Space Science*, 2000, **20**(3): 278-281 (王家龙, 韩延本. “相似周”方法及对第 23 周太阳黑子数逐月值预测的讨论[J]. 空间科学学报, 2000, **20**(3): 278-281)
- [10] LIU Siqing, ZHONG Qiuzhen, WEN Jing, *et al.* Modeling research of 10.7 cm solar radio flux 27-day forecast (I) [J]. *Chinese Journal of Space Science*, 2010, **30**(1): 1-8 (刘四清, 钟秋珍, 温靖, 等. 太阳 10.7 cm 射电流量中期预报模型研究(I) [J]. 空间科学学报, 2010, **30**(1): 1-8)
- [11] VALERO-CARRERAS D, ALCARAZ J, LANDETE M. Comparing two SVM models through different metrics based on the confusion matrix[J]. *Computers & Operations Research*, 2023, **152**: 106131
- [12] KURANI A, DOSHI P, VAKHARIA A, *et al.* A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting[J]. *Annals of Data Science*, 2023, **10**(1): 183-208
- [13] XIAO C, CHENG G S, ZHANG H, *et al.* Using back propagation neural network method to forecast daily indices of solar activity $F_{10.7}$ [J]. *Chinese Journal of Space Science*, 2017, **37**(1): 1-7
- [14] JOSEPH L P, DEO R C, PRASAD R, *et al.* Near real-time wind speed forecast model with bidirectional LSTM networks[J]. *Renewable Energy*, 2023, **204**: 39-58
- [15] WANG Z, HU Q H, ZHONG Q Z, *et al.* Linear multistep $F_{10.7}$ forecasting based on task correlation and heteroscedasticity[J]. *Earth and Space Science*, 2018, **5**(12): 863-874
- [16] GAO Yang, LV Jianyong, WANG Ming, *et al.* Short-term prediction of solar $F_{10.7}$ radiation flux based on deep learning[J]. *Acta Astronomica Sinica*, 2022, **63**(1): 104-114 (高扬, 吕建永, 王明, 等. 基于深度学习的太阳 $F_{10.7}$ 辐射通量的短期预报研究[J]. 天文学报, 2022, **63**(1): 104-114)
- [17] LIU Kaijing. Mid-Term Forecasting Study of Solar $F_{10.7}$ Index Using LSTM-NN Hybrid Model[D]. Mianyang: Southwest University of Science and Technology, 2024 (刘开静. 在 LSTM-NN 混合模型下的太阳 $F_{10.7}$ 指数中期预报研究[D]. 绵阳: 西南科技大学, 2024)

*****以上是正文

第一作者：刘开静,女,助教,主要研究数据处理技术. Email: liukaijing202212@163.com.



*通信作者：董亮,男,高级工程师,主要研究射电天文技术及空间天气. Email: dongliang@ynao.ac.cn.



最新录用