

利用深度学习实现 *Dst* 指数短期业务预报*

牛 犇 黄 智

(江苏师范大学物理与电子工程学院 徐州 221116)

摘 要 由太阳活动引发的磁暴事件会导致地球磁场产生剧烈变化,进而影响通信、导航、电力等工程应用系统的服务性能.在空间物理领域通常利用 *Dst* 指数表征磁暴强度的变化,本文提出一种基于卷积神经网络 (CNN)、门控循环单元 (GRU) 和长短时记忆网络 (LSTM) 的磁暴预测模型 (C-G-LSTM),能够提前 1~6 h 预测 *Dst* 指数.进一步利用美国航空航天局 (National Aeronautics and Space Administration, NASA) 提供的 2010–2019 年 *Dst* 指数评估混合深度学习预测模型的性能.结果显示最大均方根误差不超过 7.29 nT;最大平均绝对误差不超过 5.03 nT,磁暴期间误差有所增大.与已有研究结果相比,本文所提出的模型具有较高精度,且无须提供太阳风温度、太阳风动压以及行星际磁场分量等输入参数,适用于业务预报.

关键词 *Dst* 指数, 卷积神经网络, 门控循环单元, 长短时记忆网络

中图分类号 P352

Using Deep Learning to Achieve Short Term Business Forecast of *Dst* Index

NIU Ben HUANG Zhi

(School of Physics and Electronic Engineering, Jiangsu Normal University, Xuzhou 221116)

Abstract Magnetic storm events triggered by solar activity can cause dramatic changes in the Earth's magnetic field, significantly impacting the performance of systems such as communications, navigation, and power supply. These disturbances can interfere with radio signal propagation, reduce navigation accuracy, and disrupt power transmission networks. Therefore, accurately predicting magnetic storms is crucial for mitigating their effects. In space physics, the *Dst* index is commonly used to characterize the intensity of magnetic storms. It serves as a vital global indicator of geomagnetic activity. To enhance the prediction of magnetic storms and reduce their adverse effects, an efficient and accurate predictive model is essential. This paper proposes a magnetic storm prediction model based on Convolutional Neural Networks (CNN), Gated Recurrent Units (GRU), and Long Short-Term Memory networks (LSTM), referred to as the C-G-LSTM model. This hybrid model leverages the strengths of CNN, GRU, and LSTM to predict the *Dst* index 1 to 6 h in advance, providing valuable lead time for responding to potential magnetic storm events. CNNs effectively extract spatial features from input data, while GRUs and

* 国家自然科学基金项目 (41104096) 和徐州科技计划项目 (KC21159) 共同资助

2024-03-08 收到原稿, 2024-05-30 收到修定稿

LSTMs excel at handling time series data and capturing temporal dependencies. The performance of the C-G-LSTM model was evaluated using *Dst* index data provided by NASA, covering the period from 2010 to 2019. The results demonstrate that this model performs exceptionally well in predicting the *Dst* index. Specifically, the maximum Root Mean Square Error (RMSE) does not exceed 7.29 nT, and the Maximum Mean Absolute Error (MAE) does not exceed 5.03 nT. Although errors increase during intense magnetic activity, the model maintains high accuracy. A significant advantage of the C-G-LSTM model is that it does not require additional input parameters such as solar wind temperature, solar wind dynamic pressure, and interplanetary magnetic field components, which are often needed in other models. This makes the C-G-LSTM model more straightforward and practical for operational forecasting. Its high accuracy and efficiency in predicting magnetic storms can provide timely warnings, helping to mitigate potential impacts on communication, navigation, and power systems. In conclusion, the C-G-LSTM model represents a significant advancement in predicting magnetic storm events, offering a reliable and accurate method for forecasting the *Dst* index and enhancing our ability to manage the effects of solar activity on critical engineering systems.

Key words *Dst* index, CNN, GRU, LSTM

0 引言

磁暴的发生可能导致电网故障、变压器损坏以及对卫星通信和导航等空间系统造成不利影响。因此,磁暴活动不仅引发空间物理学领域的广泛关注,同时磁暴监测与预测也成为工程应用领域研究的热点。

在地球赤道按均匀的经度间隔选取四个地磁台站,4个台站每小时地磁水平强度变化的平均值即为 *Dst* 指数^[1],其数值在磁暴期间通常为负值,绝对值的大小与地磁强度成正比。当 $-50 \text{ nT} < Dst \leq -30 \text{ nT}$ 时,表示发生小磁暴;当 $-100 \text{ nT} < Dst \leq -50 \text{ nT}$ 时,表示发生中等磁暴;当 $-200 \text{ nT} < Dst \leq -100 \text{ nT}$ 时,表示发生大磁暴;当 $Dst \leq -200 \text{ nT}$ 时,表示发生特大磁暴。因此,磁暴预测通常归结为 *Dst* 指数的预测研究。

早期研究大都从磁暴产生的物理机制出发,构建经验模型描述磁暴指数 *Dst* 的变化。其中最为著名的是 Burton 等^[2]提出了一种根据太阳风的速度和密度等参数获取 *Dst* 指数的算法。Temerin 等^[3]在 Burton 等研究的基础之上重新构建了 *Dst* 指数的数学描述方程,结果表明均方根误差为 6.4 nT,相关系数为 0.94。这些方法通常利用太阳风速度、太阳风动压、行星际磁场分量等参数,实时更新 *Dst* 指数,在预测能力上存在一定的局限性。

由于神经网络能够捕捉以及处理复杂的非线性输出关系,因此不断有研究将其应用于空间环境参数的预报。Nuraeni 等^[4]首次提出一种非线性自回归外

源的方法对 *Dst* 指数进行 24 h 预报,结果表明,平静日的均方根误差在 4.75~5.46 nT,但是磁暴日的预测效果较差。Li 等^[5]采用了 BP(Back Propagation)神经网络构建提前一天的预报电离层 TEC 参数的模型,实验结果表明训练好的神经网络模型可以反映出不同太阳活动水平的日变化特征以及地磁风暴时的 TEC 特征。Lethy 等^[6]利用人工神经网络分别提前 1~12 h 预测 *Dst* 指数及其对太阳风参数的依赖分析,经过其预测,均方根误差在 14.3 nT 左右。Xu 等^[7]利用 1998—2014 年发生的 80 个强磁暴事件,采用贝叶斯模型预测磁暴主相期间 *Dst* 指数,预测误差约为 35 nT。

近年来机器学习特别是深度学习的高速发展,在计算机视觉、自然语言处理等领域取得突破,很多研究尝试将其应用于空间物理的预报研究。长短期记忆网络(Long Short-Term Memory Network, LSTM)是循环神经网络(Recurrent Neural Network, RNN)的变体,其有效规避了 RNN 梯度爆炸、消失的问题^[8],利用门控机制捕捉时间序列的长期依赖关系,在时间序列上的预测能力表现卓越。Zhang 等^[9]利用 LSTM 和经验模态分解实现了短期 *Dst* 指数预测,预测效果较好,平静期和活动期的均方根误差分别为 8.87 nT 和 3.29 nT。Gruet 等^[10]利用 LSTM 神经网络和高斯过程提前 1~6 h 预报 *Dst* 指数,针对特大磁暴预报精度不高,给出了概率预测。Liu 等^[11]运用 LSTM 进行中国电离层总电子含量(Total Electron

Content, TEC) 预报, 结果表明, R^2 值在 7~9 月可达 0.99, 最差情况仍能达到 0.965. Şentürk 等^[12] 利用多网络的混合 LSTM 模型预测电离层 TEC 的高度不规则数据, 与经典方法比较的结果基本一致; 而且此模型对于电离层 TEC 的短期预报以及异常检测也有较好的效果.

卷积神经网络 (Convolutional Neural Network, CNN) 利用卷积技术提取局部特征, 在图像处理上具有一定的优势. 研究表明, 将其与 LSTM 结合对时间序列的参数进行预测具有较高的精度. Yang 等^[13] 利用 CNN-LSTM 神经网络处理北斗卫星数据缺失, 平均相对误差达到 0.008, 相关系数达到 0.855. Abdualah 等^[14] 结合 CNN 和 LSTM 神经网络对 *Dst* 指数进行 1~6 h 预测, 预测性能进一步提高. Li^[15] 利用 CNN 和 LSTM 以及 Transformer 对 *Dst* 指数进行 1~6 h 预测, 均方根误差为 3.735~9.176 nT, 与数据集相同的其他模型相比, 预测性能更优.

与电离层电子浓度总含量 TEC、太阳黑子数不同, *Dst* 指数的变化不具有明显的季节变化、年变化特点, 特别是磁暴的发生具有很大的随机性. 因此构建较高精度的磁暴预测模型仍然需要持续不断地进行尝试. *Dst* 指数通常受到太阳风速度、太阳风温度、太阳风压力以及南向行星际磁场等物理参数的影响, 目前 *Dst* 建模研究中大都将这些物理量作为输入层特征参数, 但这些参数往往需要实际测量获取, 其准确性和及时性直接影响模型的性能, 不利于模型的工程开发. Bej 等^[16] 提出了一种基于最优状态空间重构和模式识别来提前 1 h 预测 *Dst* 指数, 此模型只将 *Dst* 指数作为输入, 预测效果良好. 门控循环单元 (Gate Recurrent Unit, GRU) 在 LSTM 基础上进一步简化结构^[17], 所需训练数据较少, 收敛速度更快.

本文从磁暴预测的工程应用出发, 根据混合模型中神经网络的基本原理, 将门控循环单元与卷积神经网络、长短时记忆网络结合, 利用单变量参数 *Dst* 数据信息致力于开发混合深度学习磁暴预报模型.

1 实验原理

1.1 模型原理

Dst 指数是典型的时间序列, 因此本文结合 CNN, LSTM, GRU 构建 *Dst* 指数预测模型. 其中卷积神经网络利用卷积层能够有效地捕捉数据中的空

间信息并且进行局部特征提取. LSTM 和 GRU 在处理时间序列数据时能够有效地捕捉长期依赖关系^[18], 且具有较快的收敛速度, 进一步提高模型的鲁棒性.

1.2 卷积神经网络

卷积神经网络是一种具有卷积计算和深度结构的前馈神经网络, 是深度学习典型算法之一^[19]. 卷积操作是 CNN 的核心^[20], 其计算公式为

$$y_k = f(W_{ki} \cdot x_{k-1} + b_i). \quad (1)$$

式中, y_k 表示第 k 层输出的特征图数据, 是多维的数据结构, 包含了输入数据中提取到的有效特征; W_{ki} 表示第 k 层第 i 个卷积核, 是包含数值的权重矩阵, 用于从输入数据中提取特定的特征; $x_{(k-1)}$ 表示上一层的输出, 是经过前一层处理后的数据; b_i 表示第 i 个特征图的偏置矩阵. CNN 利用池化层减小特征图的空间尺寸从而降低模型的计算复杂度, 池化层可以选取均值或者最大值作为其输出^[21].

1.3 循环神经网络 — LSTM 和 GRU

长短时记忆网络和门控循环单元是两种用于处理序列数据的循环神经网络变体^[22]. 其中 LSTM 主要结构分别为遗忘门、输入门和输出门. 遗忘门决定了前一时间步的记忆状态中保留多大程度的信息, 遗忘门的输出在 (0, 1), 当输入的信息不重要时, 遗忘门的数值近似为 1. 利用

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

可以计算遗忘门保留多大程度的信息; 输入门决定了哪些新的信息会被添加到记忆状态中, 实现对时间上的记忆和遗忘功能^[23]. 其主要工作原理如下:

$$i_t = \sigma(w_i [h_{t-1}, x_t] + b_i), \quad (3)$$

$$\bar{C}_t = \tanh(W_c [h_{t-1}, x_t] + b_c), \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * \bar{C}_t, \quad (5)$$

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

$$h_t = o_t * \tanh(C_t). \quad (7)$$

其中, i_t , o_t , f_t 分别为 t 时刻输入门、输出门、遗忘门的输出值; $\bar{C}_t$ 为输入单元的状态, C_t 为神经元的激活状态, h_t 为存储器, $\tanh$ 为正切激活函数.

与 LSTM 相比, GRU 的结构进一步简化, 主要由重置门 r_t (Reset Gate) 和更新门 z_t (Update Gate) 组成. 假定当前时刻的信息状态为 x_t , 前一刻的信息

状态为 h_{t-1} , 当前时刻的候选状态为 $\bar{h}_t$, 则 GRU 的输出表达式为

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r), \quad (8)$$

$$z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + b_z), \quad (9)$$

$$\bar{h}_t = \tanh[W_{h\bar{h}}(r_t h_{t-1}) + W_{x\bar{h}}x_t + b_{\bar{h}}], \quad (10)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \bar{h}_t. \quad (11)$$

其中, σ 为 sigmoid 激活函数; W_{hz} , $W_{x\bar{h}}$, W_{xr} , W_{xz} , W_{hr} , $W_{h\bar{h}}$ 分别为当前状态与之前状态进行传播的权重矩阵, b_r , b_z , $b_{\bar{h}}$ 分别为重置门、更新门和当前时刻隐藏层的偏置项。

2 模型预报过程

2.1 实验数据

研究中所使用的 Dst 指数来源于 NASA 的太阳风与磁场实验室 OMNIWeb^{*}. OMNIWeb 由 NASA 高级太空物理数据中心 (CDAWeb) 管理和提供支持. 该实验室致力于收集、整理和分发来自多个空间探测器和地面观测站的宇宙环境数据, 包括太阳风、地球磁场以及其他与地球磁层活动相关的参数, 这些参数被广泛应用于空间物理学研究。

利用 2010—2019 年的 Dst 指数分析混合深度学习预测模型精度, 其中 2010 年 1 月至 2015 年 11 月、2017 年 1 月至 2017 年 12 月期间的数据为训练集, 2019 年 1 月至 2019 年 12 月为验证集. 2015 年 12 月至 2016 年 12 月和 2018 年 1 月至 2018 年 12 月的数据为测试集, 分别评估地磁活动平静和异常情况下模型的性能. 此外, 为方便与已有文献进行对比, 选取了 2014 年 2 月 15 日至 2014 年 2 月 24 日、2015 年 6 月 5 日至 2015 年 6 月 14 日两个磁暴事件为测试集. 为了减少模型中噪声的影响, 需将 Dst 指数进行归一化处理, 其表达式如下:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}. \quad (12)$$

式中, x_i 为 Dst 指数, x'_i 为 x_i 归一化的值, $x_{\max}$ 和 $x_{\min}$ 分别为最大值和最小值。

2.2 模型结构

实验采用基于卷积神经网络、门控循环单元和长

短时记忆网络的 Dst 指数预报模型, 模型结构如图 1 所示. 特征输入序列首先传送给 LSTM 神经网络和一维 CNN 网络 Conv1 D, 其 LSTM 的隐藏神经元设置为 15, Conv1 D 的卷积核数为 30, 大小为 1. 中间层为含有 15 个隐藏神经元的 GRU 网络层, 进一步经由相同结构的 LSTM 和 CNN 网络, 通过 Dense 层进行线性转换输出预测结果. 模型优化器为 Adam 算法, 目标函数为均方根误差。

模型完成训练后, 载入训练好的权重, 把训练好的模型记为 C-G-LSTM. 由于本文提前预测 1~6 h 的 Dst 数据, 标记为 C-G-LSTM-1~C-G-LSTM-6. 将输出结果进行反归一化, 则得到最终的预报结果。

为了评估模型的性能, 采用均方根误差 (Root Mean Square Error, RMSE) E_{RMS} 、平均绝对误差 (Mean Absolute Error, MAE) E_{MA} 和相关系数 R 来评估模型的有效性, 即

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (y'_i - y_i)^2}, \quad (13)$$

$$E_{\text{MA}} = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i|, \quad (14)$$

$$R = \frac{\text{cov}(y'_i, y_i)}{\sqrt{\text{var}(y'_i) \cdot \text{var}(y_i)}}. \quad (15)$$

其中, y'_i 为 Dst 指数预测值反归一化结果, y_i 为 Dst 同一时间的真实值, n 为样本个数, cov 为协方差, var 为方差。




图 1 基于卷积神经网络、GRU 和 LSTM 的 Dst 指数预报模型

Fig. 1 Dst index prediction model based on convolutional neural network, Gated Recurrent Unit (GRU) and LSTM

* <https://omniweb.gsfc.nasa.gov/>

3 实验分析

为了评估模型性能, 实验采用 2010—2019 年 *Dst* 指数作为输入特征参数, 进行 *Dst* 指数的预测. 首先利用历史数据将无监督的 *Dst* 时间序列转化成有监督的输入-输出序列, 预测未来 1~6 h 的 *Dst* 指数.

为了验证模型的预测效果, 将模型预测值减去真实观测值, 2015 年 12 月至 2016 年 12 月与 2018 年 1 月至 2018 年 12 月差值的统计分布结果如图 2 所示. 从图中可以看出, 整体的预测结果基本呈现正态分布. 2018 年提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 85%, 提前 2~6 h 占比为 81%~53%;

2015 年 12 月至 2016 年 12 月提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 81%, 提前 2~6 h 占比为 74%~46%. 2015 年 12 月至 2016 年 12 月地磁活动较为活跃, 其差值明显高于 2018 年.

根据式 (13) 和式 (14) 分别计算 2015 年 12 月至 2016 年 12 月和 2018 年提前 1~6 h *Dst* 指数预测的均方根误差和平均绝对误差, 结果如图 3 所示. 2015 年 12 月至 2016 年 12 月提前 1 h 预测均方根误差约为 3.66 nT, 提前 6 h 预测均方根误差达到 8.03 nT; 2018 年模型在提前 1 小时进行预测时为 2.94 nT, 而在提前 6 小时的误差为 6.40 nT. 平均绝对误差呈现相同变化的趋势. 2016 年由于发生了若干




图 2 2015 年 12 月至 2016 年 12 月与 2018 年 1~6 h 预测值与真实值差值的统计分布

Fig. 2 Statistical distribution of the difference between predicted and actual values of 1~6 h forecasts from December 2015 to December 2016 and in 2018




图 3 2015 年 12 月至 2016 年 12 月和 2018 年提前 1~6 h 预测的 RMSE 和 MAE 值

Fig. 3 RMSE and MAE values predicted of 1~6 h forecasts from December 2015 to December 2016 and in 2018

次中等磁暴, 计算的误差明显比 2018 年偏高, 且随着预测时间增长, 误差明显增大。

为进一步详细描述模型预测值与 Dst 指数真实测量值的差异, 根据式 (15) 计算并绘制了模型在测试集上的散点分布图与回归分析图, 如图 4 所示。 R 表示相关系数, 其值越靠近 1, 预测值与实际值之间的一致性越高, 说明预测效果越好。由图 4 可见, 提前 1 h 的预测相关性为 0.98, 提前 6 h 的预测相关性为 0.88, 模型的预测值与实际值之间显示出较强的正相关性。

为了分析磁暴发生时模型的性能表现, 选取了 2015 年 12 月 15 日至 2016 年 12 月 25 日以及 2018 年 8 月 25 日至 2018 年 8 月 31 日发生的磁暴事件分析模型输出结果。两次磁暴最小 Dst 指数分别是 -166 nT 和 -175 nT, 图 5 和图 6 给出了两次磁暴 Dst 指数预测值与真实值的对比结果。结果表明, 模型预测结果与 Dst 指数真实值的变化趋势基本一致, 但随着预测时间增大, 误差增大。2015 年 12 月 15 日至 2016 年 12 月 25 日期间, 提前 1 h 预测均方根误差为 6.20 nT, 提前 6 h 预测均方根误差为 13.56 nT; 2018 年 8 月 25 日至 2018 年 8 月 31 日期间, 提前 1 h 预测 RMSE 值为 6.34 nT, 提前 6 h 预测均方根误差为 16.52 nT。磁暴强度增大, 误差增大。

本文所提出的混合预测模型 C-G-LSTM 堆叠了

两层 CNN-LSTM 结构是为了更充分地提取 Dst 指数的内在特征。在模型超参数、训练集和测试集相同的条件下, 进一步对模型进行消融分析: 分别去除一层 CNN-LSTM 和 GRU, 标记为 G-LSTM 和 C-LSTM, 利用测试集计算相应的平方根误差和平均绝对误差结果列于表 1。表 1 中 G-LSTM 模型与 C-LSTM 模型的预测均方根误差和平均绝对误差都高于 C-G-LSTM 的误差结果, C-G-LSTM 模型相较于 G-LSTM 模型均方根误差平均降低了 22.5%, 平均绝对误差平均降低了 24.55%; C-G-LSTM 模型相较于 C-LSTM 模型均方根误差平均降低了 6.92%, 平均绝对误差降低了 10.65%。相关结果表明, 由于 CNN 网络中的卷积层能够提取局部变化特征, 进一步将其和 GRU/LSTM 结合, 有利于提升时间序列的预测精度。

均方根误差和平均绝对误差是评估预测模型性能的统计指标, 其大小和采用的测试数据密切相关。因此采用具有相同测试数据的预测模型, 进一步评估模型的性能。给出 Li^[15] 搭建的 Transformer 模型预测误差, 结果列于表 2。由表可见, 本文模型提前 1~6 h 预测的均方根误差较小。Transformer 模型采用 2001—2016 年数据, 测试集为 2014—2016 年, 其中 2016 年与本文所采用的测试集重合。此外, 该模型还输入了等离子体温度、密度、速度、太阳风动压、电






图 4 2015 年 12 月至 2016 年 12 月和 2018 年 1~6 h 预测值与真实值相关系数分析结果

Fig. 4 Analysis results of correlation coefficient between predicted value and true value of 1~6 h forecasts from December 2015 to December 2016 and in 2018

图 5 大磁暴 1~6 h Dst 指数预测值与真实值对比Fig. 5 Comparison of the predicted Dst index of 1~6 h forecasts for large magnetic storms图 6 大磁暴 1~6 h Dst 指数预测值与真实值对比Fig. 6 Comparison of the predicted Dst index of 1~6 h forecasts for large magnetic storms

场强度等 7 个物理参量作为辅助特征输入. 与本文模型类似, Bej 等^[16]建立的基于自适应 Delta 调制和最优状态空间概念的概率模型 (Delta 模型) 仅利用 *Dst* 指数为输入参数, 并且是提前 1 h 预测. Delta 模型预测 2016 年的均方根误差与平均绝对误差分别为 4.35 nT 和 3.17 nT, 2018 年的均方根误差和平均绝对误差分别为 3.79 nT 和 2.80 nT, 均高于本文提出模型的预测精度.

同时为了评估模型在磁暴期间的预测精度, 采用相同的测试数据集与 Lethy 等^[6]建立的人工神经网络 (ANN) 模型进行对比, 结果如表 3 所示. ANN 在提前 2 h 预测精度低于本文模型的预测精度, 但提前 6 h 预测精度较高. ANN 模型也考虑了磁场强度、温度、速度、太阳风动压、电场强度等参数为特征输入. 表 4 给出了与 Xu 等^[7]建立的贝叶斯机器学习模型比较结果, 结果如表 4 所示. Xu 等^[7]只选取主相期间的 *Dst* 数据评估模型性能, 因此本文选取了相同时间

段的数据进行比较.

4 分析与讨论

基于深度学习开发 *Dst* 指数预报, 其预测范围为 1~6 h. 考虑到预报的短期性, 引入持续预报模型, 采用相同数据集对比分析预测性能. 持续预报模型 (Persistence Forecasting model, PF model) 通常假设某一变量在短期内不会发生显著变化, 因而可以用当前时刻观测值作为下一时刻的预测值.

为了验证持续预报模型的预测效果, 使用模型的预测值减去真实观测值, 平静期和磁暴期的两个模型差值统计分布对比如图 7 和图 8 所示. 从图 7 可以看出, 平静期本文模型提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 75%, 提前 2~6 h 占比为 76%~66%; 持续预报模型提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 66%, 提前 2~6 h 占比为 46%~

表 1 混合神经网络模型与消融分析预测 RMSE 与 MAE 对比结果

Table 1 Comparison of the RMSE and MAE between the mixed neural network model and ablation analysis

Model	RMSE/MAE /nT					
	1 h	2 h	3 h	4 h	5 h	6 h
C-G-LSTM	3.40/2.32	4.64/3.08	5.61/3.79	6.34/4.30	6.75/4.48	7.44/5.09
G-LSTM	5.74/4.15	6.17/4.24	6.96/4.76	7.60/5.41	8.25/6.00	7.90/5.31
C-LSTM	3.80/2.82	4.95/3.62	5.81/3.96	6.24/4.28	7.35/5.21	7.71/5.46

表 2 混合神经网络模型与 Transformer 模型均方根误差 (单位 nT) 对比结果

Table 2 Comparison of RMSE (unit: nT) between the mixed neural network model and Transformer model

Model	Advance forecast time					
	1 h	2 h	3 h	4 h	5 h	6 h
C-G-LSTM	3.34	4.55	5.50	6.21	6.61	7.29
Transformer	3.74	5.47	6.88	7.88	8.58	9.18

表 3 ANN 模型与本文模型磁暴期间 RMSE 和 MAE 对比结果

Table 3 Comparison of RMSE and MAE between ANN model and our model during magnetic storms

Storm time	RMSE/MAE/nT		RMSE/MAE/nT	
	C-G-LSTM Model		ANN Model	
	2 h	6 h	2 h	6 h
20—23 Jan. 2016	8.06/5.82	14.32/9.33	9.86/8.05	11.16/9.26
6—10 Mar. 2016	8.10/4.86	16.20/9.21	13.91/11.45	13.60/11.69
7—13 May 2016	7.16/4.31	10.94/6.73	7.53/5.40	8.78/6.09
22—26 Aug. 2016	6.34/4.05	10.40/6.68	8.01/6.94	7.78/6.53
12—17 Oct. 2016	7.03/4.68	13.01/8.50	12.79/8.31	10.61/7.19

29%. 从图 8 可以看出, 磁暴期本文模型提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 67%, 提前 2~6 h 占比为 57%~37%; 持续预报模型提前 1 h 位于 ± 3 nT 范围的分布所占百分比约为 55%, 提前 2~6 h 占比为 40%~23%.

图 9 给出了两个模型平静期和磁暴期提前 1~6 h 的均方根误差. 本文模型在磁暴期提前 1 h 预测的均方根误差为 4.92 nT, 提前 6 h 预测的均方根误差达到了 11.61 nT; 持续预报模型在磁暴期提前 1 h 预测的均方根误差为 5.46 nT, 提前 6 h 预测的均方根误差为 17.8 nT. 平静期的均方根误差变化趋势和磁暴期一样.

同时, 进一步采用显著性水平检测, 比较本文模

型和持续预报模型在不同地磁环境的性能, 其结果如表 5 所示. 根据显著性水平的结果, P -value 值小于 0.05 为显著优于持续预报模型. 综合图 7~9 的结果, 证明本文提出的模型具有更好的性能.

5 结论

针对磁暴 *Dst* 指数变化特征提出了一种基于 CNN, GRU 和 LSTM 的混合深度学习预测模型, 并利用 2010—2019 年 *Dst* 指数数据对其进行提前 1~6 h 预测. 预测结果显示, 与 LSTM 网络模型以及已有方法相比, 混合模型无须外部特征输入参量, 在不同地磁条件下均具有较高的精度; 随着预测时间的递增, 预测效果逐渐变低.

Dst 指数数据预测一直是空间天气领域的热点和难点问题, 尤其是对通信、导航和卫星等工程应用系统, 相对准确的 *Dst* 指数预测能够减少磁暴所产生的不利影响. 磁暴预测研究中, 由于磁暴是小概率事件, 约占数据集的 11.6%, 且磁暴的强度、形态不尽相同, 其数据种类不平衡是磁暴期间误差较大的主要原因之一, 未来研究工作将收集更多的磁暴数据进行预测, 同时开展磁暴的异常监测, 构建空间天气异常预警系统.

表 4 混合神经网络模型与贝叶斯机器学习模型磁暴期间均方根误差 (单位 nT) 对比结果

Table 4 Comparison of RMSE (unit: nT) between the mixed neural network model and Bayesian machine learning model

Model	18–19 February 2014	8–10 June 2015
C-G-LSTM	4.23	10.86
Bayesian machine learning model	35.45	35.11




图 7 地磁平静期本文模型与持续预报模型 1~6 h 差值统计分布对比

Fig. 7 Comparison of the statistical distribution of 1~6 h forecasts differences between our model and the persistence forecasting model during geomagnetic quiet periods




图 8 磁暴期本文模型与持续预报模型 1~6 h 差值统计分布对比
Fig. 8 Comparison of the statistical distribution of 1~6 h differences between our model and the persistence forecasting model during storm periods




图 9 本文模型与持续预报模型平静期与磁暴期均方根误差值
Fig. 9 RMSE of our model and persistence forecasting model during quiet periods and storm periods

表 5 本文模型与持续预报模型在平静期与磁暴期显著性水平对比结果
Table 5 Comparison results of significance levels between our model and the persistence forecasting model during quiet periods and storm periods

Time	P-value					
	1 h	2 h	3 h	4 h	5 h	6 h
Quiet Period	1.15×10^{-17}	6.02×10^{-12}	2.00×10^{-54}	6.92×10^{-141}	8.31×10^{-50}	2.37×10^{-82}
Storm Period	5.98×10^{-7}	5.66×10^{-15}	2.07×10^{-8}	5.86×10^{-14}	2.33×10^{-4}	1.95×10^{-31}

参考文献

[1] ZHU Yuncong. Research on the Correlation between Ionospheric TEC and Solar Activity Parameters[D]. Zibo: Shandong University of Technology, 2022. DOI: 10.27276/
d.cnki.gsdgc.2022.000667

[2] BURTON R K, MCPHERRON R L, RUSSELL C T. An empirical relationship between interplanetary conditions and *Dst*[J]. *Journal of Geophysical Research*, 1975, **80**(31): 4204-4214

- [3] TEMERIN M, LI X L. A new model for the prediction of Dst on the basis of the solar wind[J]. *Journal of Geophysical Research: Space Physics*, 2002, **107**(A12): SMP 31-1-SMP 31-8. DOI: [10.1029/2001JA007532](https://doi.org/10.1029/2001JA007532)
- [4] NURAENI F, RUHIMAT M, ARIS M A, *et al.* Development of 24 hours Dst index prediction from solar wind data and IMF B_z using NARX[J]. *Journal of Physics: Conference Series*, 2022, **2214**(1): 012024
- [5] LI Shuhui, PENG JunHuan, XU Weichao, *et al.* Short-term ionospheric TEC change prediction by neural network[J]. *Science of Surveying and Mapping*, 2013, **38**(1): 8-9,12 (李淑慧, 彭军还, 徐伟超, 等. 利用神经网络预报短期电离层 TEC 变化 [J]. *测绘科学*, 2013, **38**(1): 8-9,12)
- [6] LETHY A, EL-ERAKI M A, SAMY A, *et al.* Prediction of the Dst index and analysis of its dependence on solar wind parameters using neural network[J]. *Space Weather*, 2018, **16**(9): 1277-1290
- [7] XU W W, ZHU Y M, ZHU L, *et al.* A class of Bayesian machine learning model for forecasting Dst during intense geomagnetic storms[J]. *Advances in Space Research*, 2023, **72**(9): 3882-3889
- [8] YANG Xu, ZHU Yaguang, YANG Shenggao, *et al.* Application of LSTM neural network in $F_{10.7}$ solar radio flux mid-term forecast[J]. *Chinese Journal of Space Science*, 2020, **40**(2): 176-185 (杨旭, 朱亚光, 杨升高, 等. LSTM 神经网络在太阳 $F_{10.7}$ 射电流量中期预报中的应用 [J]. *空间科学学报*, 2020, **40**(2): 176-185)
- [9] ZHANG J Y, FENG Y, ZHANG J X, *et al.* The short time prediction of the Dst index based on the long-short time memory and empirical mode decomposition-long-short time memory models[J]. *Applied Sciences*, 2023, **13**(21): 11824
- [10] GRUET M A, CHANDORKAR M, SICARD A, *et al.* Multiple-hour-ahead forecast of the Dst index using a combination of long short-term memory neural network and Gaussian process[J]. *Space Weather*, 2018, **16**(11): 1882-1896
- [11] LIU H J, LEI D X, YUAN J, *et al.* Ionospheric TEC prediction in China based on the multiple-attention LSTM model[J]. *Atmosphere*, 2022, **13**(11): 1939
- [12] ŞENTÜRK E, SAQIB M, ADIL M A. A Multi-Network based Hybrid LSTM model for ionospheric anomaly detection: A case study of the M_w 7.8 Nepal earthquake[J]. *Advances in Space Research*, 2022, **70**(2): 440-455
- [13] YANG Xu, CUI Ruifei, TIAN Chao, *et al.* Linear spline and CNN-LSTM for missing values imputation of Beidou satellite radiation dose data[J]. *Chinese Journal of Space Science*, 2022, **42**(1): 163-169 (杨旭, 崔瑞飞, 田超, 等. 基于线性样条和 CNN-LSTM 的北斗卫星缺失数据处理方法 [J]. *空间科学学报*, 2022, **42**(1): 163-169)
- [14] ABDUALLAH Y, WANG J T L, BOSE P, *et al.* Forecasting the disturbance storm time index with Bayesian deep learning[C]//The International FLAIRS Conference Proceedings. Florida, USA, 2022, 35
- [15] LI Leilei. Deep Learning Modeling Research on the Relationship between Solar Wind and Geomagnetic Storms and Earthquakes[D]. Dalian: Dalian University of Technology, 2022. DOI: [10.26991/d.cnki.gdllu.2022.001958](https://doi.org/10.26991/d.cnki.gdllu.2022.001958)
- [16] BEJ A, BANERJEE A, CHATTERJEE T N, *et al.* One-hour ahead prediction of the Dst index based on the optimum state space reconstruction and pattern recognition[J]. *The European Physical Journal Plus*, 2022, **137**(4): 479
- [17] WANG Zhiyuan. Time Series Forecasting with Depth Probabilistic Models[D]. Chengdu: University of Electronic Science and Technology of China, 2023. DOI: [10.27005/d.cnki.gdzku.2023.000727](https://doi.org/10.27005/d.cnki.gdzku.2023.000727)
- [18] TANG X G, FENG J H, ZHANG B Q, *et al.* Radio frequency fingerprint-based satellite TT&C ground station identification method[J]. *Journal of Beijing Institute of Technology*, 2023, **32**(1): 1-12
- [19] GU J X, WANG Z H, KUEN J, *et al.* Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, **77**: 354-377
- [20] MA H Y, WU Y, LIU F, *et al.* Design of Super-X Test Facility monitoring and early warning system based on improved CNN-BiLSTM model[C]//2023 International Conference on Image Processing, Computer Vision and Machine Learning (ICICML). Chengdu, China: IEEE, 2023: 1015-1021. DOI: [10.1109/ICICML60161.2023.10424770](https://doi.org/10.1109/ICICML60161.2023.10424770)
- [21] SONG Y, SEBE N, WANG W. On the eigenvalues of global covariance pooling for fine-grained visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, **45**(3): 3554-3566
- [22] DEY R, SALEM F M. Gate-variants of Gated Recurrent Unit (GRU) neural networks[C]//2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). Boston, MA, USA: IEEE, 2017: 1597-1600. DOI: [10.1109/MWSCAS.2017.8053243](https://doi.org/10.1109/MWSCAS.2017.8053243)
- [23] TANG Siyu, HUANG Zhi. Prediction of ionospheric total electron content based on causal convolutional and LSTM network[J]. *Chinese Journal of Space Science*, 2022, **42**(3): 357-365 (唐丝语, 黄智. 基于因果卷积与 LSTM 网络的电离层总电子含量预报 [J]. *空间科学学报*, 2022, **42**(3): 357-365)

作者简介



牛 犇 男, 1999 年 8 月出生于河南省漯河市, 现就读于江苏师范大学物理与电子工程学院电子信息专业, 主要研究方向为磁暴 Dst 指数的预测及异常检测。
E-mail: m15939543950@163.com



黄 智 (通信作者) 女, 1973 年 7 月出生于辽宁省抚顺市, 现为江苏师范大学物理与电子工程学院教授, 硕士生导师, 主要研究方向为电离层折射误差修正、空间环境现报与预报等。
E-mail: huangzhi@jsnu.edu.cn