

基于深度学习递归神经网络的电离层 总电子含量经验预报模型^{*}

袁天娇^{1,2} 陈艳红¹ 刘四清^{1,2} 龚建村¹

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

摘要 利用行星际太阳风参数与太阳活动指数、地磁活动指数、电离层总电子含量格点化地图数据,首次基于一种能处理时间序列的深度学习递归神经网络 (Recurrent Neural Network, RNN), 建立提前 24 h 的单站电离层 TEC 预报模型. 对北京站 (40°N, 115°E) 的预测结果显示, RNN 对扰动电离层的预测误差低于反向传播神经网络 (Back Propagation Neural Network, BPNN) 0.49~1.46 TECU, 将太阳风参数加入预报因子模型后对电离层正暴预测准确率的提升可达 16.8%. RNN 对 2001 和 2015 年 31 个强电离层暴预报的均方根误差比 BPNN 低 0.2 TECU, 将太阳风参数加入 RNN 模型可使 31 个事件的平均预报误差降低 0.36~0.47 TECU. 研究结果表明深度递归神经网络比 BPNN 更适用于电离层 TEC 的短期预报, 且在预报因子中加入太阳风数据对电离层正暴的预报效果有明显改善.

关键词 电离层暴, TEC, 预报, 递归神经网络, 太阳风参数

中图分类号 P 352

Prediction Model for Ionospheric Total Electron Content Based on Deep Learning Recurrent Neural Network

YUAN Tianjiao^{1,2} CHEN Yanhong¹ LIU Siqing^{1,2} GONG Jiancun¹

1(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2(University of Chinese Academy of Sciences, Beijing 100049)

Abstract A 24 h ahead forecasting model for ionospheric Total Electron Content (TEC) at Beijing station is established based on the deep learning Recurrent Neural Network (RNN) for the first time. The model implementation requires solar 10.7 cm flux index, geomagnetic index *ap*, grid map of TEC, solar wind speed and the southward components of interplanetary magnetic field. The predicting results for Beijing station (40°N, 115°E) show that the Root Mean Square Error (RMSE) of the

* 国家自然科学基金面上项目 (41574181) 和国家重点研发计划项目共同资助 (2016YFB0501503)

2017-03-18 收到原稿, 2017-09-01 收到修定稿

E-mail: yuantj19900407@163.com

disturbed ionosphere TEC predicted by RNN model is lower than that of BPNN (Back Propagation Neural Network) model by 0.49~1.46 TECU. The forecasting accuracy of ionospheric positive storm by RNN model is increased by 16.8% with solar wind parameters. Furthermore, the RMSE of RNN model of 31 strong TEC storms in 2001 and 2015 are less than those of BPNN model by 0.2 TECU, and the RMSE of RNN model is decreased by 0.36~0.47 TECU as solar wind parameters are added. The results indicate that RNN model is more reliable than BP model for short-term forecasting of TEC. Moreover, the addition of interplanetary solar wind parameters are helpful for predicting TEC positive storm.

Key words Ionospheric storm, TEC, Forecast, Recurrent neural network, Solar wind parameter

0 引言

电离层总电子含量 (Total Electron Content, TEC) 是单位面积上电离层的总电子含量, 表征电离层中自由电子的数量. TEC 扰动会引起通信、导航和卫星定位等系统的工作误差, TEC 监测预报对保障这些系统的稳定性具有重要意义. 随着地球自转周、太阳活动周及太阳爆发性活动, TEC 发生周期性或突发性的扰动变化. 宁静时期电离层参量的预报工作已经取得了较好的结果. Li 等^[1] 构建了时间序列 TEC 自回归短期预报模型. Chen 等^[2] 利用 BP 神经网络方法, 以电离层 5 天历史观测数据和太阳活动指数 $F_{10.7}$ 作为输入, 预报电离层临界频率. 但以上方法对电离层暴的预报结果不理想. 电离层暴的物理过程复杂, 磁层-电离层-热层耦合作用机制尚不清晰. Gao 等^[3] 修正了地磁 Kp 指数对电离层扰动的延迟作用, 建立了一个线性模型来预报地磁暴时电离层临界频率的扰动变化. Huang 等^[4] 以 $F_{10.7}$ 指数、 Dst 指数和 TEC 作为输入, 利用径向基网络预报电离层 TEC. BORRIES 等^[5] 利用太阳风速度和行星际磁场计算极盖电位 Φ_{PCC} , 并统计分析了其与电离层 TEC 扰动尤其是正相扰动的相关性. Nishioka 等^[7] 利用 BP 神经网络, 从日本地区 TEC 地图中提取 36 个面调和方程系数作为模型输入因子, 分别利用地磁指数 $K < 4$ 和 ≥ 4 的历史数据, 建立日本区域的宁静电离层经验模型和扰动电离层经验预报模型, 宁静电离层模型的平均预报均方根误差 (Root Mean Square Error, RMSE) 为 2.0 TECU, 扰动电离层模型的 RMSE 为 4.7 TECU.

神经网络法在电离层参数的预报工作中已得到广泛引用. 该方法能够较好地预测平静电离层参数,

但是其对电离层暴的预测准确率和精度很难进一步提升. 本文采用一种新的机器学习方法, 即深度学习递归神经网络 (Recurrent Neural Network, RNN), 根据历史 TEC、太阳活动指数、地磁活动指数和太阳风参数预测北京电离层 TEC. 与反向传播神经网络 (Back Propagation Neural Network, BPNN) 方法相比, RNN 网络法对宁静电离层和电离层暴的预测更准确.

1 RNN 基本原理

RNN 可以解决全连接的深度神经网络 (Deep Neural Network, DNN) 无法对时间序列变化进行建模的问题. 与传统 BP 神经网络相比, RNN 能够更好地捕捉序列数据的信息. RNN 和 BPNN 同样使用误差反向传播算法, 但传统 BPNN 的神经网络层间传递的参量不共享, 随着层之间的迭代, 梯度逐渐稀疏, 误差矫正越来越弱, 而 RNN 的神经网络层间的参数矩阵是一样的. 此外, BPNN 的训练参数仅在不同层的神经元之间传输, RNN 隐含层的神经元不仅输出传递给下一层, 还将作用在本层神经元的下一时刻, 即第 i 层 j 时刻的输入, 包括 $i-1$ 层的输出和第 i 层 $j-1$ 时刻的输出两部分^[6]. 图 1 为 RNN 结构, 图 2 为一组输入-隐含-输出结构在时间上的展开. 假设

$$x = [x_1, x_2, \dots, x_n]$$

为网络输入集, 每个输入量时间步长为 p , 即

$$x_i = [x_i^1, x_i^2, \dots, x_i^p],$$

隐含层迭代函数为

$$s_i^t = \sum_{i=1}^n w_{ih}x_i^t + \sum_{h'=1}^H w_{h'h}b_{h'}^{t-1}, \quad (1)$$

$$b_h^t = f_h(s_h^t). \quad (2)$$

式中, s_i^t 为隐含层第 i 个输出的第 t 步数据, x_i^t 为输入集中第 i 个输入量的第 t 步数据, w_{ih} 为输入层信息传递给隐含层的权值, H 为隐含层数, $w_{h'h}$ 为隐含层上一步 $t-1$ 传递的权值, b_h^t 为经过激活函数 f_h 计算的值, 将传递给输出层. 输出集 $y = [y_1, y_2, \dots, y_m]$, 每个输出量时间步长为 q , 即 $y_o = [y_o^1, y_o^2, \dots, y_o^q]$ 传递函数为

$$y_o^t = \sum_{h=1}^H w_{ho}b_h^t. \quad (3)$$

其中, y_o^t 为第 o 个输出量第 t 步数据, w_{ho} 为隐含层连接输出层的权值.

2 实验数据与模型构建

这里使用的数据包括电离层 TEC、太阳活动指数 $F_{10.7}$ 、地磁活动指数 ap 、太阳风速度 v_p 和行星际磁场南向分量 B_z , 数据时间范围为 1999—2016 年. 取 2001 和 2015 年的数据作为测试数据集, 测试年份




图 1 RNN 结构

Fig. 1 RNN construction

的太阳活动性和地磁扰动情况如图 3 所示, 其余样本作为网络训练数据列于表 1.

TEC 数据来自欧洲定轨中心 (CODE) 的全球电离层 MAP TEC 北京地区 (40°N , 115°E) 数据, 经纬格点的精度均为 $2.5^\circ \times 5^\circ$, 时间分辨率为 1h. $F_{10.7}$ 指数来自美国国家海洋和大气管理局 (NOAA) 地球物理数据中心, 时间分辨率为 1d. ap 指数来自日本京都地磁数据中心, 时间分辨率为 3h.

太阳风速度和行星际磁场南向分量来自 ACE 卫星观测数据, 时间分辨率为 1h. 这里采用五层 RNN 模型, 即输入层、三层隐含层和输出层, 激活函数为线性函数, 优化器为 RMSprop 算法, 目标函数为均方差. 网络输入为预报因子连续 5 天的历史数据, 输出第六天 24h 的 TEC 数据. 为提升电离层暴时预报

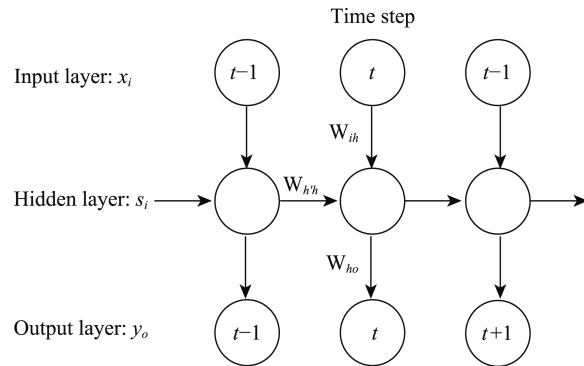


图 2 RNN 结构在时间上的展开

Fig. 2 Unfolding RNN construction on time steps

表 1 训练及测试数据分配


Table 1 Assignment of the training and testing data

Phase	Training data	Testing data
Year	1999—2000	2001
Year	2002—2014, 2016	2015

表 2 预报因子对照组

Table 2 Assignment of the input factors

	Set 1	Set 2	Set 3
Factor	TEC, $F_{10.7}$, ap	TEC, $F_{10.7}$, v_p , B_z	TEC, $F_{10.7}$, ap , v_p , B_z
Dimension	120, 5, 40	120, 5, 120, 120	120, 5, 40, 120, 120
Number of training samples	5603	5315	5315
Number of testing samples	730	696	696

图3 2001和2015年 $F_{10.7}$ 指数及 ap 指数的变化Fig. 3 Variation of $F_{10.7}$ index and ap index in 2001 and 2015

效果, 利用太阳风参数作为预报因子 (见表 2). 设计三种预报输入组合, 1 组只考虑太阳活动指数和地磁活动指数, 即为 TEC, $F_{10.7}$ 和 ap 指数; 2 组考虑太阳活动和太阳风参数的影响, 为 TEC, $F_{10.7}$, v_p , B_z ; 3 组既考虑太阳和地磁活动指数, 同时也考虑太阳风参数, 为 TEC, $F_{10.7}$, ap , v_p , B_z . 将每天数据缺损过半的样本去除, 其余的进行线性插值, 每组预报因子分别得到 5603, 5315, 5315 个训练样本和 730, 696, 696 个测试样本数.

另外, 为验证 RNN 的有效性, 采用了传统的三层 BPNN^[2], 即输入层、单隐含层和输出层. 激活函数为 tansig 函数, 训练函数为 trainlm 函数, 目标函数为均方差. 采用与 RNN 相同的数据集进行训练和测试.

3 模型测试结果

3.1 最优模型神经元数

实际预报工作中, 定义 Ap 指数低于 20 时为地磁平静. 考虑地磁扰动对电离层有持续性影响, 若地磁活动水平连续三天均平静, 则为电离层宁静期, 即当日和前两天 Ap 指数均低于 20, 否则为电离层扰动期. 分别计算模型预测扰动期和宁静期 TEC

的 RMSE, 计算公式为

$$\sigma_{\text{RMSE}} = \sqrt{\frac{\sum (\tau_{\text{TEC}_o} - \tau_{\text{TEC}_p})^2}{n}}. \quad (4)$$

为了直观评估模型对电离层暴的预测结果, 计算电离层 TEC 相对于其 27 天 (前后各 13 天) 滑动中值的相对偏差 $|\delta_{\text{TEC}}|$, 有

$$\delta_{\text{TEC}} = \frac{\tau_{\text{TEC}_o} - \tau_{\text{TEC}_m}}{\tau_{\text{TEC}_m}} \times 100\%. \quad (5)$$

KOURIS 等^[8] 基于西欧地区电离层 TEC 变化特征, 提出了 $|\delta_{\text{TEC}}| > 20\%$ 并持续 3h 以上为电离层扰动的标准. 参考此阈值, 将测试样本分为电离层正暴日、负暴日和平静日. 三组预报因子组合的测试集中, 正暴日样本分别有 73, 164, 164 个, 负暴日样本分别有 130, 119, 119 个. 采用混淆矩阵定量评价模型对电离层暴的预测结果. 混淆矩阵定义列于表 3 和表 4. 每个模型的预测结果可以得到一个混淆矩阵, 真实样本在行中显示, 预测样本在列中显示, 矩阵中每个元素为对应分类的样本数目. 从表 3 可计算报准率 (T_1^{rate}) 和虚警率 (F_1^{rate}):

$$T_1^{\text{rate}} = \frac{T_1}{T_1 + F_0} \times 100\%, \quad (6)$$

$$F_1^{\text{rate}} = \frac{F_1}{F_1 + T_0} \times 100\%. \quad (7)$$

从表 4 可计算出模型的正暴报准率 (T_p^{rate}) 和负暴报准率 (T_n^{rate}):

$$T_p^{rate} = \frac{T_p}{T_p + N_p + O_n} \times 100\%, \quad (8)$$

$$T_n^{rate} = \frac{T_n}{O_p + N_n + T_n} \times 100\%. \quad (9)$$

调整网络的神经元数, 反复训练三种输入样本的 RNN 和 BPNN, 计算测试结果的正负暴报准率和 RMSE, 结果如图 4 所示. 图 4 的纵轴和横轴分别为不同神经元数网络模型的正暴和负暴报准率, 每个点上竖向线段为该模型测试结果的 RMSE, R 值为

表 3 二分类混淆矩阵

Table 3 Definition of confusion matrix on binary classification

	预测的暴日	预测的静日
真实的暴日	正确的暴日 (T_1)	错误的静日 (F_0)
真实的静日	错误的暴日 (F_1)	正确的静日 (T_0)

三组预报因子模型正负暴报准率的相关系数. 由图 4 可以看出, 预报因子组 3 (绿色) 的正负暴报准率高于组 2 (蓝色), 组 2 高于组 1 (红色). 此外, 模型的正暴报准率和负暴报准率基本呈负相关分布, 并且正暴和负暴报准率差距越大, 模型的 RMSE 越大. 选取 RNN 三层隐含层的神经元数分别为 30, 20, 20, BPNN 隐含层神经元数为 14, 得到三组预报因子的 RNN 模型和 BP 模型.

3.2 暴时误差统计分析

图 5 给出了三种输入的 RNN 和 BPNN 扰动电离层预报误差和宁静电离层预报误差. RNN 模型对扰动电离层的预测误差分别为 4.42, 4.74, 4.44 TECU, 对宁静电离层的预测误差分别约为 2.87, 3.13, 2.98 TECU. BP 模型对扰动电离层的预测误差为 5.88, 5.25, 5.22 TECU, 对宁静电离层的预测误差为 3.10, 3.26, 3.13 TECU. RNN 模型的平静期 TEC 预测误差与 BP 模型相当, 其对扰动电离层的预测误差明显低于 BP 模型. 预报因子组 1 和组 3 的 RNN 模型预测精度优于预报因子组 2.

表 4 三分类混淆矩阵

Table 4 Definition of confusion matrix on three classification

	预测的正暴日	预测的静日	预测的负暴日
真实的正暴日	正确的正暴 (T_p)	漏报的静日 (N_p)	报反的负暴 (O_n)
真实的静日	误报的正暴 (W_p)	正确的静日 (T_0)	误报的负暴 (W_n)
真实的负暴日	报反的正暴 (O_n)	漏报的静日 (N_n)	正确的负暴 (T_n)




图 4 不同神经元数的模型正负暴报准率和均方根误差

Fig. 4 Hit rate of positive and negative storm and RMSE of models with different number of neurons




图 5 北京电离层 TEC 的预报 RMSE
Fig. 5 Forecasting RMSE of TEC in Beijing




图 6 RNN 和 BPNN 的报准率和虚警率
Fig. 6 Hit and false alarm rate of RNN and BPNN model

RNN 和 BPNN 的报准率和虚警率如图 6 所示。(0, 1) 点意味着所有的样本都正确分类, 各模型的点距离 (0, 1) 点越近, 表示样本分类的准确性越高。从图 6(a) 可以看出, RNN 模型性能与 BPNN 模型相差不大。将图 6(b) 中黑框区域放大, 可以看出三组预报因子组的 RNN 模型均比 BPNN 模型更靠近 (0, 1) 点, 说明使用太阳风参数作为预报因子能提升模型对电离层暴的预报能力。

图 7 为各模型对正暴和负暴的平均误差及报准率。RNN 模型对 TEC 负暴的预测误差与 BPNN 模型相当, 约为 4.0~4.5 TECU; 对正暴的预测误差显著低于 BP 模型, 约为 3.8 TECU。RNN 模型对 TEC

正暴的报准率分别为 52.4%, 69.2%, 54.7%, 对负暴的报准率分别为 36.1%, 30.9%, 38.6%。BPNN 模型对 TEC 正暴的报准率分别为 52.0%, 61.7%, 52.3%, 对负暴的报准率分别为 45.6%, 48.1%, 48.7%。预报因子组 2 的 RNN 模型负暴误差高于 BPNN 模型, 其他 RNN 模型对 TEC 正暴和负暴的预测误差低于 BPNN 模型。

3.3 电离层暴个例分析

为了检验模型对强电离层扰动的预测误差, 定义 $|\delta_{TEC}| \geq 50\%$ 为强电离层暴, 统计得到 2001 年和 2015 年共发生强暴 31 次。表 5 列出了 RNN 模型和 BPNN 模型对 31 次事件 5 日平均预报误差和暴

表 5 对 31 次电离层暴事件的预报 RMSE
Table 5 Forecasting RMSE of 31 TEC storms

年-月-日	Sample set 1				Sample set 2				Sample set 3			
	RNN		BPNN		RNN		BPNN		RNN		BPNN	
	暴日 误差	五日 误差	暴日 误差	五日 误差	暴日 误差	五日 误差	暴日 误差	五日 误差	暴日 误差	五日 误差	暴日 误差	五日 误差
正相 2001-01-21	2.74	2.41	3.06	2.01	3.24	2.69	2.22	2.96	3.03	2.44	2.57	2.34
2001-01-29	1.56	3.32	1.41	2.43	1.04	3.63	2.03	3.35	1.39	3.71	2.69	3.07
2001-02-05	3.28	2.45	2.76	2.19	1.84	2.13	3.69	3.16	2.51	2.45	2.70	2.60
2001-02-12	4.94	3.33	4.82	4.11	4.86	3.50	3.63	3.26	3.80	2.92	4.67	3.95
2001-02-22	3.10	2.49	3.28	2.30	2.54	2.93	2.90	2.93	2.89	2.70	3.16	2.39
2001-03-12	3.60	3.09	2.95	3.03	1.75	3.21	3.61	3.49	2.98	3.46	2.69	3.07
2001-03-27	6.43	8.73	5.96	8.30	8.36	7.82	6.76	7.74	7.98	7.78	6.17	7.77
2001-09-25	5.07	4.34	13.92	8.07	4.26	4.46	5.41	5.29	6.12	5.00	6.89	5.39
2001-11-24	5.36	3.84	4.41	4.83	3.92	3.92	3.55	3.55	4.44	4.44	5.67	5.67
2001-12-04	5.26	4.76	3.77	3.39	3.66	3.62	2.71	3.75	4.04	3.37	3.89	3.48
2015-01-19	2.14	1.89	2.09	1.56	2.22	2.42	2.31	2.15	2.40	2.35	2.46	2.04
2015-01-28	2.64	2.28	3.25	2.59	2.40	2.20	2.90	2.29	2.26	2.09	2.63	2.06
2015-03-01	5.26	4.50	3.77	4.29	3.91	4.41	4.99	3.56	3.93	4.12	4.36	4.48
2015-03-26	2.48	2.98	2.51	3.53	1.81	2.69	2.47	2.97	1.93	2.99	1.26	2.98
2015-04-19	5.57	3.16	4.31	3.10	3.94	2.95	6.58	4.10	5.09	3.18	6.10	3.96
2015-06-08	5.48	3.53	6.17	4.87	4.14	2.74	5.60	4.13	4.75	3.16	3.65	3.45
2015-07-04	3.80	3.21	2.97	2.29	2.76	2.83	3.25	2.53	3.07	2.99	3.34	3.21
2015-07-11	3.81	3.30	4.10	3.50	2.93	3.38	3.51	4.02	3.32	3.29	3.06	3.75
2015-09-15	2.43	1.80	2.16	1.99	2.26	1.89	2.61	2.21	2.43	1.78	2.67	1.99
2015-10-14	2.38	2.39	2.60	2.44	2.20	1.84	2.11	2.66	2.31	1.90	2.24	2.41
2015-10-19	1.91	1.90	1.44	1.53	2.00	2.05	1.73	2.15	1.47	1.50	1.99	1.83
2015-12-20	7.81	4.12	5.09	2.60	6.63	3.98	3.50	2.39	7.00	4.09	3.89	2.60
负相 2001-01-12	3.57	2.06	3.70	2.19	3.75	2.67	4.05	2.32	3.36	2.61	3.76	2.06
2001-04-12	2.41	4.44	6.03	7.29	3.77	5.36	2.96	5.96	3.58	4.67	1.84	10.04
2001-05-10	3.22	3.13	3.21	3.59	5.42	4.21	5.29	4.21	4.28	3.70	4.67	4.35
2001-12-27	9.16	6.72	7.99	6.40	6.54	6.28	9.80	6.36	5.99	5.82	6.71	5.39
2015-06-23	7.61	4.78	6.88	7.01	7.16	4.66	7.89	5.58	7.79	4.96	8.52	6.32
2015-10-07	1.60	2.19	3.68	2.34	5.00	2.92	1.99	2.54	3.68	2.56	4.22	3.30
双相 2001-11-05	18.18	9.44	16.95	9.78	16.01	11.58	15.24	10.86	15.55	11.14	16.03	11.52
2001-03-20	11.03	9.61	12.44	9.33	9.00	9.95	9.56	8.61	9.03	8.74	8.36	6.96
2015-03-17	5.58	4.93	5.82	5.31	5.59	4.93	5.45	4.22	5.82	4.80	5.09	4.12
平均	4.82	3.91	4.95	4.14	4.35	4.00	4.53	4.04	4.46	3.89	4.45	4.15

日预报误差, 其中暴日定义为发生扰动五日内 $|\delta_{TEC}|$ 最大日. 由表 5 可见, 22 次 TEC 正暴中, 组 2 和组 3 的误差结果有 16 次事件最低, 各组预报因子的 RNN 模型暴日误差分别有 8, 14, 14 次低于 BPNN 模型, 平均误差分别有 9, 13, 13 次低于 BPNN 模型. 6 个负暴事件中, 有 4 次组 1 的暴日误差最低, RNN 模型的暴日误差分别有 3, 3, 5 次低于 BPNN 模型, 平均误差分别有 6, 2, 4 次低于 BPNN 模型. 3 次正负双相暴中, 三组预报因子的 RNN 模型各有一次暴日误差最低, 组 1 的 RNN 模型暴日误差和平均误差均有两次低于 BPNN 模型, 而组 2 和组 3 的 RNN 模型暴日误差仅有一次低于 BPNN 模型. 因此, 预报因子组 1 对负暴的预报精度比其他两组更好, 组 2 和组 3 对正暴预报精度更好. 此外, RNN 模型对 60% 电离层暴事件的预测精度高于 BPNN 模型, 其 31 次事件平均误差比 BPNN 模型低约 0.2 TECU.

图 8(a) (b) 给出了 2015 年 3 月 17 日和 2015 年 6 月 7 日两次电离层暴事件的预测结果. 两种模型都预测出了事件 1 第二天的电离层负向扰动. 预报因子组 2, 3 的模型预测值与观测值更加接近, 误差比组 1 的更小. 组 2, 3 的 BPNN 模型预测 3 月 18 日的 TEC 更加准确, 但对随后恢复相的 TEC 预测值误差大于 RNN 模型的预测误差. 在事件 2 中, 组 1 的 BP 模型将第三天误报为负向扰动, 组 2, 3

的 BPNN 模型预测误差均有改善. RNN 和 BPNN 模型均未能预测出 3 月 17 日和 6 月 8 日的正暴.

4 讨论

对于平静时期电离层的预测, RNN 和 BPNN 模型都能给出较好的预测结果, RNN 对 TEC 的预测结果略优于 BPNN. 对于电离层暴的预测, RNN 和 BPNN 模型都能更好地预测电离层正暴, RNN 模型对电离层正暴的报准率略高于 BPNN 模型, 而 BPNN 模型对负暴的报准率高于 RNN 模型. Nakamura 等^[10] 利用 BPNN 模型构建了电离层单站经验预报模型, 其模型测试数据中含有 690 个电离层正暴和 514 个电离层负暴, 准确预报出 216 个正暴和 165 个负暴, 正暴、负暴报准率分别为 31.3% 和 32.1%. 与之相比, RNN 模型对电离层 TEC 正、负暴的报准率均更高, 分别可达 69.2%, 38.6% 以上. 这说明递归神经网络方法应用于电离层 TEC 预报是可行的. 神经网络模型难以兼顾电离层 TEC 正暴和负暴报准率, 测试结果的正、负暴报准率为明显负相关分布. 这证明电离层正暴和负暴的物理机制存在很大差异, 而现阶段的网络结构较难分辨和模拟这种差异. 本文 RNN 模型对电离层负暴的预测误差比正暴误差低, 与 BPNN 模型相比, 其预测准确度提升

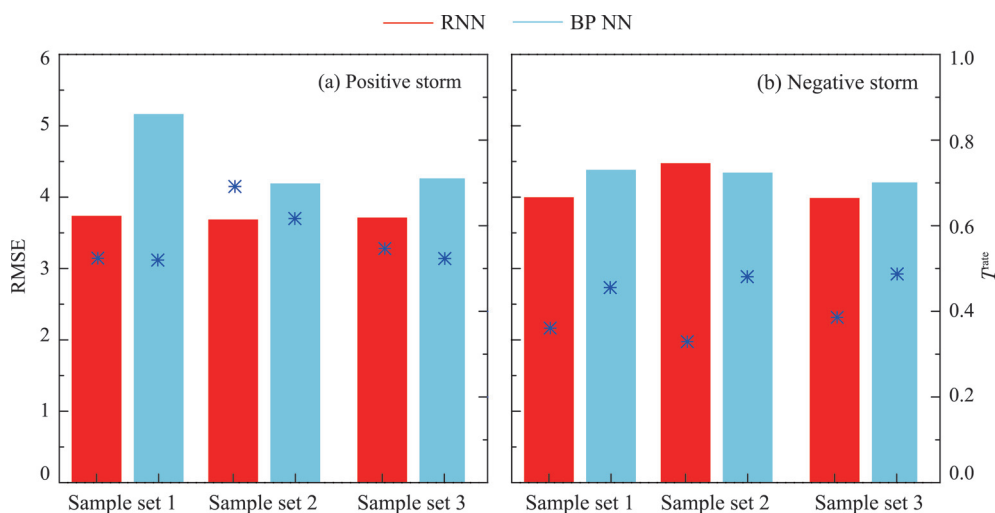


图 7 RNN 及 BPNN 模型正暴报准率 (a) 和负暴报准率 (b) 及其平均误差. 左纵轴为 RMSE, 对应直方图, 右纵轴为报准率 T^{rate} , 对应符号 *

Fig. 7 Hit rate and RMSE of RNN and BPNN model for positive (a) and negative (b) storm. The left vertical axis is root-mean-square error, which corresponds to the histogram. The right vertical axis is the success rate of prediction, which corresponds to the signal *




图 8 利用 RNN 和 BPNN 模型预测 TEC 的结果与观测结果的比较

Fig. 8 Comparison of predicted TEC by RNN and BPNN model with the observations

并不显著. 这可能是由于负暴主要是由中性成分变化引起的, 形成原因相对单一, 而这一机制和太阳风参数与地磁指数的扰动相比, 存在时间上的延迟, 一般作用在磁暴恢复相. 因此, 传统 BPNN 神经网络等经验预报方法已经能够较好地模拟和预测电离层负暴的发生. 但 RNN 和 BPNN 模型不能预报全部

的电离层负暴. 这可能是由于电离层暴的物理机制过于复杂, 穿透电场、中性风和大气成分的变化都是电离层暴形成的原因, 单纯依靠机器学习的方法很难将这些机制进行区分, 有时会虚报电离层负暴, 产生较大的电离层负暴预测误差. 电离层负暴的预测仍需进一步优化模型输入和结构.

这里将太阳风参数加入模型的输入因子中, 改善了模型对 TEC 正、负暴的预测能力. 这是因为太阳风参数弥补了 A_p 指数不能够完全表征地磁暴时极区扰动这一缺陷, 同时其也是地磁扰动的上游影响因子, 作为模型的输入因子后, 能够同时提升模型对正暴和负暴的预测能力. 但是, 加入太阳风参数并不能完全解决模型预测正暴能力欠缺的问题. 这里建模时使用的是前几天的太阳风参数, 这对于穿透电场引起的电离层正暴没有意义. 当行星际-磁层发生扰动时, 电场的影响几乎是瞬时产生并穿透到电离层, 因此在实际应用中随时间窗口滑动进行预报, 可能有更好的结果.

本文预报因子组 3 的 RNN 模型对宁静电离层的平均预测误差为 3.0 TECU, 对扰动电离层的预测误差约为 4.4 TECU, 而 Nishioka 等^[7]的宁静 TEC 模型精度为 2.0 TECU, 扰动模型误差为 4.7 TECU. Nishioka 等对宁静电离层的预测精度优于本文, 可能是因为其取宁静电离层历史数据来独立训练模型, 而本文为了能够同时适用于宁静和扰动电离层的预报并未分割训练数据, 网络学习宁静电离层演化时受扰动数据的干扰, 影响了预测精度. 但是, 宁静电离层具有十分规律的日变化, 本文模型仍能较好地预测 TEC 的静日变化. 此外, 独立的扰动电离层模型难以运用到业务预报中, 本文模型更具有实际应用价值.

5 结论

利用深度递归神经网络 (RNN) 对电离层总电子含量 TEC 进行预测. 该模型利用前 5 天的 TEC, $F_{10.7}$ 指数、 a_p 指数和太阳风参数观测数据作为输入, 第 6 天 24h 的 TEC 数据作为输出, 使用 1999—2016 年的数据进行训练, 并提出其中 2001 年和 2015 年的数据进行测试. 测试结果表明: 本文建立的 RNN 和 BPNN 模型均能有效预测电离层 TEC, RNN 模型结果比传统 BPNN 模型更加准确, 在保证平静电离层预报精度的同时, 提高了预测电离层暴的准确度; 增加太阳风参数作为预报因子提升了模型对电离层暴的报准率, 但预测误差有所增加; RNN 模型对正暴的预测误差相比 BPNN 模型降低了 0.6~1.5 TECU, 预测电离层正暴的报准率可达 69.2%, 即 RNN 模型

对电离层正暴的预测更具有优势.

首次将深度递归神经网络应用于电离层参量的预报, 结果表明深度学习神经网络是一种较好的预测电离层 TEC 的方法, 其对电离层暴的预测能力优于 BPNN 模型. 但是由于电离层扰动机制的复杂性, 模型对电离层暴的预测精度还有待进一步改进提高.

参考文献

- [1] LI Zhigang, CHENG Zongyi, FENG Chugang, *et al.* A study of prediction models for ionosphere[J]. *Chin. J. Geophys.*, 2007, **50**(2): 327-337 (李志刚, 程宗颐, 冯初刚, 等. 电离层预报模型研究[J]. *地球物理学报*, 2007, **50**(2): 327-337)
- [2] CHEN Yanhong, XUE Bingsen, LI Libin. Forecasting of ionospheric critical frequency using neural networks[J]. *Chin. J. Space Sci.*, 2005, **25**(2): 99-103 (陈艳红, 薛炳森, 李利斌. 利用神经网络预报电离层 $f_0F_2^*$ [J]. *空间科学学报*, 2005, **25**(2): 99-103)
- [3] GAO Qing, LIU Libo, ZHAO Biqiang, *et al.* A prediction method for midlatitude ionospheric storms at a single station based on modified K_p [J]. *Progr. Geophys.*, 2009, **24**(6): 1943-1950 (高琴, 刘立波, 赵必强, 等. 基于修正 K_p 指数的中纬区单站电离层暴预报方法研究[J]. *地球物理学进展*, 2009, **24**(6): 1943-1950)
- [4] HUANG Z, YUAN H. Ionospheric single-station TEC short-term forecast using RBF neural network [J]. *Radio Sci.*, 2014, **49**(4): 283-292
- [5] BORRIES C, BERDERMANN J, JAKOWSKI N, *et al.* Ionospheric storms—a challenge for empirical forecast of the total electron content [J]. *J. Geophys. Res.*, 2015, **120**(4): 3175-3186
- [6] SARMA K K, MITRA A. A class of recurrent neural network (RNN) architectures with SOM for estimating MIMO channels [C]//Advances in Computing and Communications. Berlin: Springer, 2011: 512-521
- [7] NISHIOKA M, MARUYAMA T, TSUGAWA T, *et al.* Forecast model of ionospheric total electron content over Japan using a machine learning technique [C]//Japan Geoscience Union Meeting, 2016
- [8] KOURIS S S, POLIMERIS K V, CANDLER L R. Specifications of TEC variability [J]. *Adv. Space Res.*, 2006, **37**(5): 983-1004
- [9] KOURIS S. Thresholds of TEC variability describing the plasmaspheric disturbed state [J]. *Acta Geophys.*, 2008, **56**(2): 408-416
- [10] NAKAMURA M I, MARUYAMA T, SHIDAMA Y. Using a neural network to make operational forecasts of ionospheric variations and storms at Kokubunji, Japan [J]. *Earth, Planets Space*, 2007, **59**(12): 1231-1239