

基于 QPSO-LSTM 模型的电离层 TEC 预测*

郭文韬^{1,2,4} 孙希延^{1,2,3,4} 纪元法^{1,2,3} 贾茜子^{1,2}

1(桂林电子科技大学 广西精密导航技术与应用重点实验室 桂林 541004)

2(桂林电子科技大学信息与通信学院 桂林 541004)

3(卫星导航定位与位置服务国家地方联合工程研究中心 桂林 541004)

4(南宁桂电电子科技有限公司 南宁 530031)

摘要 针对单一 LSTM 模型的电离层 TEC 短期预报存在参数调整 and 性能优化困难导致预测精度低的问题, 结合量子粒子群算法 (Quantum Particle Swarm Optimization, QPSO) 和 LSTM 模型, 通过量子粒子群算法自适应确定最优解, 优化 LSTM 模型的参数配置, 并利用该模型预测 2014 年和 2018 年共三个时段的低、中、高纬度提前 5 d 的电离层 TEC, 对地磁活动的平静期和扰动期的电离层 TEC 预测精度进行实验分析. 结果表明, 经过 QPSO 优化的 LSTM 模型对 TEC 进行连续 5 d 预测时, 相对于单一 LSTM 模型, QPSO-LSTM 模型在太阳活动低年均方根误差最多降低了 0.34 TECU, 而相对精度最多提高了 2.68%, 而在太阳活动高年, 低纬度地区均方根误差最多下降了 0.68 TECU, 而相对精度在高纬度地区最多提高了 2.36%. 从不同的角度对比分析发现, QPSO-LSTM 模型的预测精度均优于单一 LSTM 模型.

关键词 LSTM, 量子粒子群算法, 地磁活动, 预测精度

中图分类号 P352

Ionospheric TEC Prediction Based on QPSO-LSTM Model

GUO Wentao^{1,2,4} SUN Xiyan^{1,2,3,4} JI Yuanfa^{1,2,3} JIA Qianzi^{1,2}

1(Guangxi Key Laboratory of Precision Navigation Technology and Application,
Guilin University of Electronic Technology, Guilin 541004)

2(School of Information and Communication, Guilin University of Electronic Technology, Guilin 541004)

3(Satellite Navigation Positioning and Location Service, National & Local Joint Engineering Research Center, Guilin 541004)

4(GUET-Nanning E-Tech Research Institute Co., Ltd., Nanning 530031)

Abstract For the ionospheric TEC short-term prediction of a single LSTM model, there are difficulties in parameter adjustment and performance Optimization, resulting in low prediction accuracy. Quan-

* 广西壮族自治区科学技术厅项目 (桂科 AB21196041, 桂科 AB22035074, 桂科 AD22080061), 国家自然科学基金项目 (U23A20280, 62161007, 62061010) 和广西高校中青年教师科研基础能力提升项目 (2022KY0181) 共同资助

2023-12-06 收到原稿, 2024-03-06 收到修定稿

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

tum Particle Swarm Optimization (QPSO) and LSTM model are combined. The quantum particle swarm optimization algorithm was used to determine the optimal solution, optimize the parameter configuration of the LSTM model, and use the model to predict the ionospheric TEC of low, middle and high latitudes 5 d in advance for three periods in 2014 and 2018, and analyze the prediction accuracy of the ionospheric TEC during the quiet period and disturbance period of geomagnetic activity. The experimental results show that when the LSTM model optimized by QPSO is used to predict TEC for 5 consecutive days, compared with the single LSTM model, the root-mean-square error of the QPSO-LSTM model is reduced by 0.34 TECU at most in low solar activity years, and the relative accuracy is increased by 2.68% at most in high solar activity years. The RMS error decreases by up to 0.68 TECU at low latitudes, while the relative accuracy increases by up to 2.36% at high latitudes. From different analysis angles, it is found that the prediction accuracy of QPSO-LSTM model is better than that of single LSTM model.

Key words LSTM, Quantum particle swarm optimization, Geomagnetic activity, Prediction accuracy

0 引言

电离层是地球大气层中的电离气体层,在现代通信和定位系统中扮演着关键角色^[1]. 电离层总电子含量 (Total Electron Content, TEC) 的变化对信号的传播和接收产生严重影响. 这一影响在无线通信、卫星导航、遥感等领域尤为显著. 在全球导航卫星系统 (Global Navigation Satellite System, GNSS) 中, 电离层的延迟和多路径效应是导致定位误差的主要因素之一^[2]. 提高电离层 TEC 预测精度对于提高定位精度和通信质量具有重要意义.

随着全球观测数据的不断增加, 深度学习等现代方法已经应用于电离层预测. Reddybattula 等^[3]采用长短期记忆 (Long Short-Term Memory, LSTM) 深度学习网络模型, 利用全球定位系统 (Global Positioning System, GPS) 观测值预测印度班加罗尔的电离层总电子含量, 使用 2018 年的数据进行验证, 印度低纬度地区的预报效果优于 IRI 和 GPS 模型. Ruwali 等^[4]使用 LSTM-CNN 模型, 对班加罗尔、冈特尔和勒克瑙 GPS 站的 GPS 测量数据中的垂直 TEC 时间序列进行了预测, 其混合模型表现出了很好的预测性能, 适合估计印度低纬度地区 GPS 信号的电离层延迟. Wang 等^[5]采用小波分解, 结合埃尔曼神经网络模型与差分自回归移动平均模型进行电离层 TEC 预测, 通过 ARIMA 模型进行高频信息预测, 采用 Elman 模型进行低频信息预测, 最终实现了

TEC 预测值的重构, 残差值小于 1 TECU 比例达到 80.23%. LSTM 模型作为一种特殊的循环神经网络, 在时序数据建模和预测方面表现出优秀的能力. 然而, 传统的 LSTM 模型在电离层 TEC 预测中仍然面临着参数调整 and 性能优化的挑战.

为了解决这些问题, 提出一种基于深度学习和优化算法的新型电离层 TEC 预测模型——QPSO-LSTM 模型. 使用由国际 GNSS 服务 (International GNSS Service, IGS) 中心发布的电离层 TEC 格网数据, 选取 2018 年的不同纬度的 TEC 数据, 通过 QPSO 算法自适应确定最优解^[6-8], 并优化 LSTM 模型的参数配置, 使用 LSTM 模型进行 TEC 预测分析.

1 算法原理

1.1 量子粒子群算法

量子粒子群算法是一种在粒子群算法的基础上, 加入量子计算原理的优化算法. 该算法通过对经典粒子群算法和量子位的概念进行融合, 具有较强的全局搜索能力, 可以帮助找到参数空间中的全局最优解; 由于量子粒子群算法采用群体协同的方式进行搜索, 有助于避免陷入局部最优解. QPSO 相较于传统的粒子群算法, 在处理非连续、非光滑空间的优化问题上具有更好的适应性, 可以自适应地调整搜索策略, 适应不同问题和不同阶段的搜索需求.

2004 年,为了解决粒子群算法 (Particle Swarm Optimization, PSO) 收敛速度较快但容易陷入局部最优的问题, Sun 等^[9] 结合量子力学, 提出了量子粒子群算法. 该算法通过设置种群中的个体数量、最大迭代次数和寻优的参数为度, 在每个参数的搜索范围内计算每个个体的适应度值, 找到个体最优解和全局最优解, 最终得到全局最优解. QPSO 的基本原理是模拟粒子在搜索空间中的移动和信息交流过程, 通过当前位置和速度对作为候选解的粒子进行更新. 与传统 PSO 不同的是, QPSO 引入了量子位的概念, 用于描述粒子的量子态和相位信息.

量子粒子群算法的粒子更新过程如下.

(1) 计算平均最优位置:

$$M_{\text{best}} = \frac{1}{M} \sum_{i=1}^M P_{\text{best}_i} \quad (1)$$

其中, M 为粒子群个数, P_{best_i} 表示第 i 个局部最优位置矢量.

(2) 更新粒子的位置:

$$P_i = \varphi \cdot P_{\text{best}_i} + (1 - \varphi) g_{\text{best}} \quad (2)$$

其中, g_{best} 表示全局最优粒子数值, P_i 表示经过迭代的第 i 个粒子的最优位置矢量, φ 为 $(0, 1)$ 内均匀分布的数值.

QPSO 的更新公式如下:

$$x_i = P_i \pm \alpha |M_{\text{best}} - x_i| \ln\left(\frac{1}{\varphi}\right) \quad (3)$$

其中, x_i 表示最终得到的粒子最优位置矢量, α 为收缩膨胀系数.

1.2 LSTM

长短期记忆神经网络广泛应用于时序数据建模和预测任务. 相对于传统的循环神经网络 (Recurrent Neural Network, RNN), LSTM 通过引入记忆单元和门控机制, 克服了传统 RNN 在长时序数据建模中的梯度消失和梯度爆炸问题, 使其能够更好地处理长期依赖关系^[10,11].

LSTM 模型神经网络结构如图 1 所示, LSTM 中的核心组件是 LSTM 单元, 每个 LSTM 单元由三个关键部分组成: 遗忘门、输入门和输出门. 这些门通过激活函数的输出来控制信息流动和记忆的保留,

实现对输入序列的建模和记忆^[12,13].

1.3 QPSO-LSTM 电离层 TEC 组合预报模型

利用 QPSO 强大的全局搜索能力和自适应性的优点, 对 LSTM 模型的参数配置进行自适应, 确定最优解, 降低参数选择对模型精度和稳定性的影响. 通过引入 QPSO 算法, QPSO-LSTM 模型可以更好地适应电离层 TEC 数据的变化和复杂性. QPSO-LSTM 模型流程如图 2 所示, 预测 TEC 的具体步骤如下.

(1) 数据获取及预处理: 获取 IGS 格网文件, 选择低中高纬度的 TEC 数据, 并划分为训练集和测




图 1 LSTM 模型神经网络结构

Fig. 1 LSTM model neuron network structure




图 2 QPSO-LSTM 模型流程

Fig. 2 QPSO-LSTM model flow

试集.

(2) QPSO 算法优化: 利用 QPSO 算法对 LSTM 的隐藏层大小、迭代次数和学习率进行寻优, 以得到的参数作为 LSTM 模型的配置参数.

(3) 模型训练和预测: 输入训练集到 QPSO 优化后的 LSTM 模型进行训练, 利用训练后的 QPSO-LSTM 模型对测试集数据进行预测.

(4) 预测结果对比分析: 将 QPSO-LSTM 模型和 LSTM 模型的预测结果对比, 并使用绝对误差 E_a 、相对误差 E_r 、均方根误差 E_{RMS} 、平均相对精度 P_{mr} 分析模型预测效果.

2 实验分析

2.1 实验数据

使用由 IGS 提供的全球电离层 TEC 数据, 为了研究不同纬度下的预测性能, 选择北半球 100°E 线上的位置作为研究对象. 选取的训练集数据为测试集前 3 个月的数据, 测试集数据的时间为 2018 年年积日 (Day of Year, DOY) 41—70 (时段 1)、DOY 211—240 (时段 2) 和 2014 年 DOY 22—51 (时段 3), 数据的时间分辨率为 15 min. 输入训练集数据进行模型训练, 得到 QPSO-LSTM 预测模型, 利用数据前 25 d TEC 数据作为预测模型的输入数据集, 选择 QPSO-LSTM 模型和 LSTM 对后 5 d 的 TEC 值进行单输入预测, 通过对比验证模型效果^[14]. 从低纬、中纬和高纬地区分别选取 1 个区域, 所选位置的描述如表 1 所示.

根据地磁活动水平, 其中太阳活动低年 2018 年 DOY 41—70 的电离层 TEC 数据为地磁平静期数据, 太阳活动高年 2014 年 DOY 22—51 和太阳活动低年 2018 年 DOY 211—240 的电离层 TEC 数据为地磁扰动期数据.

将模型预测值与真实值进行对比分析, 采用绝对误差 E_a 、相对误差 E_r 、均方根误差 E_{RMS} 、平均相对精度 P_{mr} 作为评价指标对电离层电子含量预报模型精度进行综合评价, 具体形式如下:

$$E_a = |\delta_i - \delta_{\text{pred},i}|, \quad (4)$$

$$E_r = \frac{E_a}{\delta_i} \times 100\%, \quad (5)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (\delta_i - \delta_{\text{pred},i})^2}, \quad (6)$$

$$P_{\text{mr}} = 1 - \sum_{i=1}^m \frac{|\delta_{\text{pred},i} - \delta_i|}{\delta_{\text{pred},i}}. \quad (7)$$

其中, $\delta_{\text{pred},i}$ 表示电离层电子含量预报模型第 i 个预测值; δ_i 表示电离层电子含量预报值对应的电离层电子含量^[15].

2.2 QPSO-LSTM 模型超参数优化

选取 2018 年 DOY 41—70 的 A1 区域 TEC 数据确定 QPSO 算法优化 LSTM 模型的寻优参数, 由于使用双层 LSTM 模型, 所以需要优化两个 LSTM 的隐藏层大小、迭代次数和学习率, 故寻优维度 $d = 4$. 利用 QPSO-LSTM 模型对 TEC 进行建模, 有两个参数对预测性能有显著影响, 分别是种群规模 PopNum 和最大寻优迭代数 Maxstep. 为了使寻优结果更具准确性, 对该数据集使用不同的参数组合, 种群规模 PopNum 设置为 10, 20 和 40, 最大寻优迭代数 Maxstep 设置为 10, 20 和 40^[16].

表 2 给出不同优化参数组合的 QPSO-LSTM 模

表 1 所选位置的描述

Table 1 Description of all locations

区域编号	经纬度坐标	描述
A1	(15°N , 100°E)	低纬度
A2	(45°N , 100°E)	中纬度
A3	(75°N , 100°E)	高纬度

表 2 不同参数组合的 QPSO-LSTM 模型预测结果

Table 2 Prediction results of QPSO-LSTM model with different parameter combinations

PopNum	10			20			40		
Maxstep	10	20	40	10	20	40	10	20	40
$E_{\text{RMS}}/\text{TECU}$	1.097	1.042	1.044	1.066	1.039	0.998	1.052	1.040	0.998
P_{mr}	95.048	95.298	95.287	95.191	95.311	95.495	95.252	95.304	95.494

型预测结果对比. 通过表中数据可以清晰看出, 在寻优维度固定为 4 的情况下, 种群规模为 20 和 40, 最大寻优迭代数为 40 的模型预测效果最佳, 但是随着种群规模由 20 增加到 40, QPSO 算法的优化时间成倍增加, 且效果并未明显提升, 表明在实验中, 种群规模到 20 次即可得到最后优化结果, 因此将 $d = 4$, $\text{PopNum} = 20$, $\text{Maxstep} = 40$ 设定为优化参数.

2.3 不同地磁活动电离层 TEC 预测

为了分析 QPSO-LSTM 模型在不同地磁活动预测电离层 TEC 的效果, 选择使用 2018 年地磁活动平静期时段 1 和扰动期时段 2 在 A1, A2 和 A3 区域的电离层数据, 分别采用 LSTM 模型和 QPSO-LSTM 模型进行 TEC 建模和预测. 图 3 和图 4 分别给出时




图 3 平静期地磁活动指数

Fig. 3 Geomagnetic activity index in quiet period




图 4 扰动期地磁活动指数

Fig. 4 Geomagnetic activity index in disturbance period

段 1 和时段 2 对应的地磁活动指数, 时段 1 的 Dst 指数在 $-25 \sim 20$ nT 范围内, 均大于 -30 nT, 未发生地磁磁暴; 时段 2 的 Dst 指数在 DOY 238–239 均超过 -50 nT, 且 DOY 238 的 Dst 参数达到了 -104 nT, 已经属于中等磁暴范围.

图 5 和图 6 分别为平静期和扰动期两种模型预报不同纬度 TEC 与真实值的对比图. 在地磁平静期




图 5 平静期两种模型 TEC 预测值与真实值对比

Fig. 5 Comparison of TEC predicted values and real values of the two models in the quiet period




图 6 扰动期两种模型 TEC 预测值与真实值的对比
Fig. 6 Comparison of TEC predicted values and real values of the two models during the disturbance period

两种模型均能较好地预测电离层 TEC 的变化, 不过在峰值和谷值处仍存在较大的误差, 这是由于预测模型在训练过程中能够基本捕捉到 TEC 变化的规律, 但是 TEC 的变化受到太阳活动和地磁活动的影响, 本文的输入数据集中未包含该类因素参数, 对于峰值和谷值的突变未能呈现出对应的变化趋势, 而在地磁活动扰动期, 受地磁活动的影响更大, 在磁暴期

TEC 发生的突变更加明显, 相对于单一 LSTM 模型的预测结果, QPSO-LSTM 模型对于峰值和谷值突变的预测有一定改善, 可以明显看出单一 LSTM 模型预测值与真实值相差较大, 而 QPSO-LSTM 模型的预测值比 LSTM 模型更加接近真实值, 能够更好地呈现与真实值相近的变化趋势。

图 7 和图 8 为不同地磁活动两种模型预测结果的绝对误差和相对误差直方图。从图中绝对误差和相对误差的直方图分布可以看出, 在平静期, 中纬度的 QPSO-LSTM 模型的预测结果明显优于单一 LSTM 模型, 而低纬度和高纬度的绝对误差直方图不能明显看出 QPSO-LSTM 模型和单一 LSTM 模型预测结果的好坏, 但是结合相对误差直方图可以看出, QPSO-LSTM 模型的预测结果在 0 附近均相对于单一 LSTM 模型占比更大, 说明 QPSO-LSTM 模型的预测结果更接近真实值。在扰动期, 通过绝对误差和相对误差直方图能够更加直观地看出, QPSO-LSTM 模型的绝对误差更向 0 集中, 而 QPSO-LSTM 模型相对误差直方图分布相对于单一 LSTM 模型均有提升。

2.4 不同太阳活动电离层 TEC 预测

电离层受到太阳活动的强烈影响。太阳活动高年电离层电子密度变化大于太阳活动低年电离层电子密度变化。为了进一步分析该模型的性能, 将时段 2 研究数据作为低太阳活动期, 时段 3 研究数据作为高太阳活动期, 并进行了对比实验^[17]。

图 9 为太阳活动高年扰动期两种模型在不同纬度的预测结果对比图。从图 9 可以明显地看出, QPSO-LSTM 模型和单一 LSTM 的预测结果均与真实值接近, 但是在峰值和谷值处, QPSO-LSTM 模型能够更好地捕捉 TEC 的变化, 得到的预测结果与真实值更接近。

图 10 为太阳活动高年扰动期两种模型的 TEC 预测结果绝对误差和相对误差直方图。通过该图能够更直观地发现, QPSO-LSTM 模型的预测结果优于单一 LSTM 模型, 能够更好地对 TEC 值进行预测, 但是在低纬度地区的 TEC 预测误差最大仍超过 10 TECU, 而在太阳活动低年, 低纬度地区的 TEC 误差基本不超过 6 TECU, 说明在低纬度地区, QPSO-LSTM 模




图 7 平静期两种模型的 TEC 预测结果绝对误差和相对误差直方图

Fig. 7 Histogram of absolute error and relative error of TEC prediction results of two models in quiet period




图 8 扰动期两种模型的 TEC 预测结果绝对误差和相对误差直方图

Fig. 8 Histogram of absolute error and relative error of TEC prediction results of two models in disturbance period




图 9 太阳活动高年两种模型 TEC 预测值与真实值对比
Fig. 9 Comparison of TEC predicted values and real values of two models in high solar activity years

型对于 TEC 变化特性的捕捉能力仍存在较大的提升空间。

为了进一步分析 QPSO 优化 LSTM 的效果, 表 3 和表 4 分别给出了低太阳活动期和高太阳活动期两种模型的均方根误差和平均相对精度。从表中可以看出, QPSO-LSTM 模型的均方根误差相对于单一 LSTM 模型的均方根误差均有所降低, 而相对精度均

有提高, 相同经度下, 太阳活动低年低纬度地区均方根误差下降最多, 降低了 0.34 TECU, 而相对精度在中纬度地区提高最多, 提高了 2.68%; 而在太阳活动高年, 低纬度地区均方根误差下降最多, 降低了 0.68 TECU, 而相对精度在高纬度地区提高最多, 提高了 2.36%。从上述分析可知, 在太阳活动高年和低年, QPSO-LSTM 模型的预测评估指数在地磁扰动期均优于 LSTM 模型, QPSO 对 LSTM 模型的优化效果明显。

3 结语

为了解决传统的 LSTM 模型在电离层 TEC 预测中参数调整 and 性能优化困难的问题, 提出了一种新的电离层 TEC 预测模型 QPSO-LSTM 对电离层 TEC 数据进行预测分析, 并与 LSTM 模型预测结果进行对比, 从不同地磁活动和不同太阳活动角度, 对电离层 TEC 进行 5 d 的短期预报进行实验分析, 结果如下。

(1) 在地磁平静期、扰动期, 从预测值与真实值的对比、预测结果的绝对误差和相对误差直图的分析表明, QPSO-LSTM 模型相比于单一 LSTM 模型的预测结果在不同纬度地区均有提升。总体说明, 经过 QPSO 进行超参数优化的 LSTM 模型的预测效果有所提升。

(2) 在太阳活动高年和太阳活动低年, QPSO-LSTM 模型的均方根误差相对于单一 LSTM 模型的均方根误差均有所降低, 而相对精度均有提高, 相同经度下, 均方根误差最多降低了 0.68 TECU, 而相对精度在中纬度地区最多提高了 2.68%。从均方根误差角度和平均相对精度角度而言, 相对于单一的 LSTM 模型, QPSO-LSTM 模型预测精度更高。在不同纬度, QPSO 优化的 LSTM 模型预测结果均优于单一的 LSTM 模型。

由于本次研究只使用了 TEC 值作为输入数据集, 而 TEC 值的变化受到地磁活动和太阳活动等因素影响, 导致本文研究的预测模型在对 TEC 峰值谷值变化的捕捉能力不足, 将通过更多的太阳活动参数作为输入数据加入模型中提高预测精度。另外, IGS 中心提供的数据相受其他因素影响, 存在一定




图 10 太阳活动高年两种模型的 TEC 预测结果绝对误差和相对误差直方图

Fig. 10 Histogram of absolute error and relative error of TEC prediction results for two models of high solar activity year

表 3 太阳活动低年不同模型 TEC 预测结果的评估系数对比
Table 3 Comparison of evaluation coefficients of TEC prediction results of different models in low solar activity years

模型	评估系数	A1	A2	A3
LSTM	均方根误差/TECU	1.74	1.03	0.53
	相对精度/(%)	91.43	89.40	91.50
QPSO-LSTM	均方根误差/TECU	1.40	0.80	0.46
	相对精度/(%)	93.12	92.08	92.61

表 4 太阳活动高年不同模型 TEC 预测结果的评估系数对比
Table 4 Comparison of evaluation coefficients of TEC prediction results of different models in high solar activity years

模型	评估系数	A1	A2	A3
LSTM	均方根误差/TECU	4.33	2.66	2.19
	相对精度/(%)	92.27	90.80	85.85
QPSO-LSTM	均方根误差/TECU	3.65	2.43	1.83
	相对精度/(%)	93.47	91.43	88.21

误差, 可以使用当地观测站获得的电离层数据对今后电离层 TEC 进行预测分析, 以进一步提高预测精度.

致谢 地磁指数由地磁指数国际服务合作机构提供, VTEC 数据由 IGS 中心提供.

参考文献

[1] SUN W J, WU B Y, WU Z, *et al.* IONISE: an ionospheric observational network for irregularity and scintillation in East and Southeast Asia[J]. *Journal of Geophysical Research: Space Physics*, 2020, **125**(8): e2020JA028055

[2] LIU L B, YANG Y Y, LE H J, *et al.* Unexpected regional

- zonal structures in low latitude ionosphere call for a high longitudinal resolution of the global ionospheric maps[J]. *Remote Sensing*, 2022, **14**(10): 2315
- [3] REDDYBATTULA K D, NELAPUDI L S, MOSES M, *et al.* Ionospheric TEC forecasting over an Indian low latitude location using long short-term memory (LSTM) deep learning network[J]. *Universe*, 2022, **8**(11): 562
- [4] RUWALI A, KUMAR A J S, PRAKASH K B, *et al.* Implementation of hybrid deep learning model (LSTM-CNN) for ionospheric TEC forecasting using GPS data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, **18**(6): 1004-1008
- [5] WANG Jianmin, TANG Yan, LYU Nan, *et al.* Research on combined model in short term ionospheric total electron prediction[J]. *Science of Surveying and Mapping*, 2022, **47**(4): 34-43, 67 (王建敏, 唐彦, 吕楠, 等. 组合模型的电离层总电子短期预报研究 [J]. 测绘科学, 2022, **47**(4): 34-43, 67)
- [6] RUGVETH V S, KHATTER K. Sensitivity analysis on Gaussian quantum-behaved particle swarm optimization control parameters[J]. *Soft Computing*, 2023, **27**(13): 8759-8774
- [7] SUN J, XU W B, LIU J. Parameter selection of quantum-behaved particle swarm optimization[C]//Proceedings of the 1st International Conference on Natural Computation. Changsha: Springer, 2005: 543-552
- [8] SUN J, FANG W, WU X J, *et al.* Quantum-behaved particle swarm optimization: analysis of individual particle behavior and parameter selection[J]. *Evolutionary Computation*, 2012, **20**(3): 349-393
- [9] SUN J, WU W B, FENG B. A global search strategy of quantum-behaved particle swarm optimization[C]//Proceedings of the IEEE Conference on Cybernetics and Intelligent Systems, 2004. Singapore: IEEE, 2004
- [10] LU Tieding, HUANG Jiawei, LU Chunyang, *et al.* Short-term ionospheric TEC prediction model based on EWT-ARMA[J]. *Journal of Geodesy and Geodynamics*, 2021, **41**(4): 331-335, 341 (鲁铁定, 黄佳伟, 鲁春阳, 等. 基于 EWT-ARMA 的短期电离层 TEC 预测模型 [J]. 大地测量与地球动力学, 2021, **41**(4): 331-335, 341)
- [11] LIU Ang, WANG Ningbo, LI Zishen, *et al.* Prediction of global ionospheric map using the theory of maximum posterior estimation[J]. *Chinese Journal of Space Science*, 2022, **42**(6): 1089-1099 (刘昂, 王宁波, 李子申, 等. 基于极大验后推估理论的全球电离层地图预报 [J]. 空间科学学报, 2022, **42**(6): 1089-1099)
- [12] WU Han, HUANG Ling, LIU Lilong, *et al.* Short term prediction model of ionospheric TEC based on SSA-LSTM[J]. *Journal of Geodesy and Geodynamics*, 2022, **42**(6): 626-630, 654 (吴晗, 黄玲, 刘立龙, 等. 基于 SSA-LSTM 的短期电离层 TEC 组合预报模型 [J]. 大地测量与地球动力学, 2022, **42**(6): 626-630, 654)
- [13] 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)
- [14] LI Lei, LI Jing, YANG Chen. Short-term ionospheric TEC prediction based on KF-LSTM combination model[J]. *Journal of Geodesy and Geodynamics*, 2023, **43**(10): 1020-1025 (李磊, 黎竞, 杨晨. 基于 KF-LSTM 组合模型的短期电离层 TEC 预测 [J]. 大地测量与地球动力学, 2023, **43**(10): 1020-1025)
- [15] NAVA B, COÏSSON P, RADICELLA S M. A new version of the NeQuick ionosphere electron density model[J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2008, **70**(15): 1856-1862
- [16] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, **8**(1): 22-34
- [17] TANG Jun, ZHONG Zhengyu, LI Yinjian, *et al.* Short-term prediction model of ionospheric TEC based on SSA-Elman neural network[J]. *Journal of Geodesy and Geodynamics*, 2022, **42**(4): 378-383 (汤俊, 钟正宇, 李垠健, 等. 基于 SSA-Elman 神经网络的电离层 TEC 短期预报模型 [J]. 大地测量与地球动力学, 2022, **42**(4): 378-383)

作者简介



郭文韬 男, 1996 年 6 月出生于河北省承德市, 现为桂林电子科技大学信息与通信学院硕士研究生, 主要研究方向为卫星导航电离层 TEC 时空演变规律及预测。
E-mail: gwt2024@126.com



孙希延 (通信作者) 女, 山东省安丘人, 现为桂林电子科技大学研究员, 博士生导师, 广西“八桂学者”, 主要研究方向为卫星导航、卫星通信和遥感。
E-mail: sunxiyan1@163.com