

基于 OARO-GRU 网络的高频地波雷达电离层杂波短期预测

乔铁柱, 尚 尚, 石依山, 刘 强
(江苏科技大学 海洋学院 镇江 212003)

摘要: 电离层杂波的精确预测对提升高频地波雷达的目标探测性能具有重要推动作用。为此, 提出了一种基于改进人工兔子算法优化门控循环单元 (Opposite Artificial Rabbits Optimization optimized Gated Recurrent Unit, OARO-GRU) 网络的电离层杂波短期预测模型。首先, 依据高频地波雷达接收到的电离层杂波具有混沌特性这一先验知识, 通过相空间重构技术构造 GRU 网络的输入和输出样本集; 然后, 融入反向学习和柯西变异两种改进策略用于改善标准 ARO 的寻优能力, 并将其用于执行 GRU 网络的包含隐层节点个数、初始学习速率和最大迭代次数在内的三个超参数值的优选; 最后, 重新训练优化后的 GRU 网络, 输入测试样本集进行测试, 并依据给定的评价指标评估模型。实测结果表明: 相较于其他 7 种对照模型, 所提出的 OARO-GRU 网络预测模型在预测精度和可靠性上均具有明显的优越性, 为有效改善高频地波雷达的目标探测性能提供了一种新的思路与方法。

关键词: 高频地波雷达; 电离层杂波预测; 改进人工兔子算法; 门控循环单元网络; 短期预测

中图分类号: TN957.51; TP183 **文献标志码:** A **文章编号:** 2095-1000(2024)01-0126-07

DOI: 10.12347/j.ycyk.20231116002

引用格式: 乔铁柱, 尚尚, 石依山, 等. 基于 OARO-GRU 网络的高频地波雷达电离层杂波短期预测[J]. 遥测遥控, 2024, 45(1): 126-132.

Short-term Prediction of Ionospheric Clutter from High Frequency Surface Wave Radar Using OARO-GRU

QIAO Tiezhu, SHANG Shang, SHI Yishan, LIU Qiang

(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212003, China)

Abstract: Accurate prediction of ionospheric clutter is of great significance in improving the target detection performance of high-frequency surface wave radar. This paper proposes a short-term prediction model of ionospheric clutter using the Opposite Artificial Rabbits Optimization optimized Gated Recurrent Unit (OARO-GRU) network. Firstly, based on the a priori knowledge that ionospheric clutter received by high-frequency surface wave radar has chaotic characteristics, the input and output sample sets of the GRU network are constructed using the phase space reconstruction technique. Then, two improvement strategies, namely, the opposition-based learning and the Cauchy-based mutation, are incorporated to enhance the optimization capability of the original ARO, which is used to optimize the GRU network with the values of three hyperparameters including the number of hidden layer nodes, the initial learning rate, and the maximum number of iterations. Finally, the optimized GRU network is retrained and fed into the test sample set for testing. The model is evaluated based on the given evaluation metrics. The experimental results show that compared with the other seven comparison forecast models, the proposed OARO-GRU network model has obvious superiority in prediction accuracy and reliability, and provides a new idea and method for effectively improving the target detection performance of high-frequency surface wave radar.

Keywords: High frequency surface wave radar; Ionospheric clutter prediction; Opposite artificial rabbits optimization algorithm; Gated recurrent unit network; Short-term prediction

Citation: QIAO Tiezhu, SHANG Shang, SHI Yishan, et al. Short-term Prediction of Ionospheric Clutter from High Frequency Surface Wave Radar Using OARO-GRU[J]. Journal of Telemetry, Tracking and Command, 2024, 45(1): 126-132.

0 引言

作为一种新体制雷达,高频地波雷达(High Frequency Surface Wave Radar, HFSWR)利用高频段垂直极化电磁波沿海水传播损耗小的特点,实现对海上舰船目标及低空飞行目标远距离全天候探测^[1]。然而,在雷达接收到的回波数据中,除了期望目标信号外,还包含有电离层杂波、海杂波等其他干扰信号。同其他干扰信号相比,电离层杂波的覆盖范围较广且特性也更为复杂,对HFSWR探测性能的影响也最为严重^[2]。因此,若能有效地抑制电离层杂波,将有助于提升HFSWR的探测性能。为更好对电离杂波进行抑制,对其实现精确预测是不可或缺的一步。文献[3]中利用实测数据首次证明了HFSWR接收到的电离杂波具有混沌特性,而这一研究成果为电离层杂波的短期预测提供了理论基础。

随着深度学习技术的发展,诸多时间序列预测模型相继被开发出来。GRU网络作为其中备受欢迎的一种,是由Cho等人在LSTM(Long Short-Term Memory,长短期记忆)网络的基础上提出的一种变体^[4]。相较于LSTM网络,GRU网络虽然可调参数少、结构简单,但两者的预测性能十分接近^[5]。马丽文等人基于GRU网络建立了海杂波幅度预测模型,并与ANN(Artificial Neural Network,人工神经网络)、SVM(Support Vector Machine,支持向量机)模型进行了对比,其结果表明GRU网络的预测精度最高^[6]。文献[7]使用GRU网络结合注意力机制建立了航空客流量预测模型,并获得了较好的预测结果。文献[8]使用GRU网络来学习电动汽车内部电池电压的演变规律。文献[9]基于GRU网络建立了原油价格预测模型。文献[10]将GRU网络用于预测未来一段时间内风力发电输出功率,并与统计模型ARIMA(Autoregressive Integrated Moving Average,自回归移动平均模型)进行了对比,其结果表明GRU网络的预测精度明显优于ARIMA模型。虽然GRU网络具有相对较高的预测精度,但同其他时间序列预测模型一样,其本身预测性能受到包含初始学习速率、最大迭代次数等超参数取值的制约,倘若取值选取不当,将严重影响模型的预测性能。目前,已有不少文献借助元启发式优化算法来辅助时间序列预测模型执行超参数值优选,显著提升了模型的预测精度

和可靠性^[11-13]。人工兔优化(Artificial Rabbits Optimization, ARO)算法,一种基于群体行为开发的元启发式优化算法,通过模仿兔子在自然界中的生存策略而执行寻优任务,具有复杂度低、灵活性强、原理简单等优点^[14],但仍存在收敛速度慢、易陷入局部最优等问题。为此,本文提出了融合反向学习和柯西变异两种策略用来改善标准ARO的寻优精度,随后将其用于执行GRU网络包括隐层节点个数、初始学习速率和最大迭代次数在内的3个超参数值的优选。

综上,本文根据HFSWR接收到的电离层杂波具有混沌特性这一先验知识,选用GRU网络用来学习其演化规律,为进一步提升GRU网络的预测精度和可靠性,借助OARO来优选GRU网络的超参数取值。对比文中设置的其他7种对照预测模型,测试结果表明:本文建立的OARO-GRU网络电离层杂波短期预测模型具有较高的预测精度及可靠性。

1 研究方法

1.1 GRU网络

GRU网络相较于LSTM网络,仅采用重置门和更新门两个控制门来执行信息的保留与丢弃操作,具有运算速度快、待调参数少等优势^[4]。具体的,重置门用于控制前一时刻隐层状态信息被丢弃的程度;更新门则用来控制前一时刻隐层状态信息被保留到当前时刻隐层状态中的程度。GRU网络内部结构如图1所示。




图1 GRU网络内部结构

Fig.1 Internal structure of GRU network

给定GRU网络隐层单元个数为 k ,当前时刻输入为 x_t ,则当前时刻隐层状态的具体计算过程如下:

$$r_t = \sigma(W_r x_t + R_r h_{t-1} + b_r) \quad (1)$$

$$z_t = \sigma(W_z x_t + R_z h_{t-1} + b_z) \quad (2)$$

$$c_t = \tanh(W_c x_t + R_c(r_t \odot h_{t-1}) + b_c) \quad (3)$$

$$h_t = z_t \odot h_{t-1} + (I_{k \times 1} - z_t) \odot c_t \quad (4)$$

式中, r_t 、 z_t 、 c_t 、 h_t 分别表示重置门输出、更新门输出、当前时刻候选集状态、当前时刻隐层状态; W_r 、 W_z 、 W_c 表示与输入向量连接的权重矩阵, R_r 、 R_z 、 R_c 表示与前一时刻隐层状态连接的权重矩阵; b_r 、 b_z 、 b_c 表示对应的偏差向量; \odot 表示哈达码乘积符号; $\sigma(\cdot)$ 和 $\tanh(\cdot)$ 分别表示 Sigmoid 激活函数、双曲正切激活函数。

1.2 PSR 技术

对混沌时间序列执行相空间重构(Phase Space Reconstruction, PSR)是建立预测模型的第一步, 其基本思想为: 利用获取的单一分量在不同延时点上的观测值, 将其重构为一个维数为 m 的相空间矢量。此外, 由 Takens 嵌入定理可知, 只要选择合适的嵌入维数, 则据此重构出的相空间矢量与原动力系统相空间近似等价^[15]。文中利用 PSR 技术构造 GRU 网络的输入、输出样本集, 来尽可能充分地学习电离层杂波的演化规律。具体重构过程如下:

给定电离层杂波序列 $\{x(i)\}_{i=1}^L$, 则维数为 m 的相空间矢量 R^m 可表示为

$$R^m = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_{L-(m-1)\tau} \end{bmatrix} = \begin{bmatrix} x(1) & \cdots & x(1+(m-1)\tau) \\ \vdots & & \vdots \\ x(L-(m-1)\tau) & \cdots & x(L) \end{bmatrix} \quad (5)$$

式中, X_i 表示相空间中的一个相点; m 、 τ 分别表示嵌入维数和嵌入延迟时间。本文选取 C-C 法^[16]来计算 m 和 τ 的取值。

为提升 GRU 网络的运行速度, 进行输入、输出样本构造前, 先对重构后的电离层杂波序列按式(6)执行归一化操作, 同样, 对 GRU 网络预测模型输出结果按式(7)执行反归一化操作。

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (6)$$

$$\hat{y} = y' \times (x_{\max} - x_{\min}) + x_{\min} \quad (7)$$

式中, x_{\max} 、 x_{\min} 分别表示观测值中的最大值、最小值; x' 、 y' 和 \hat{y} 分别表示归一化后的观测值、归一化后的模型输出值及反归一化后的模型输出值。

进而, GRU 网络的输入样本 X 及输出样本 Y 可表示如下:

$$X = \begin{bmatrix} x'(1) & \cdots & x'(L-1+(m-1)\tau) \\ \vdots & & \vdots \\ x'(1+(m-1)\tau) & \cdots & x'(L-1) \end{bmatrix} \quad (8)$$

$$Y = (x'(2+(m-1)\tau), x'(3+(m-1)\tau), \dots, x'(L)) \quad (9)$$

文中建立的预测模型, 其输入层节点个数等于嵌入维数 m 。

1.3 OARO

ARO 是基于兔群在自然界中的绕道觅食和随机躲藏两种生存策略而开发出来的, 该算法具有实现简单、灵活性强及寻优精度高等优点, 但仍存在收敛速度慢、易陷入局部最优等缺陷。为此, 本文提出将反向学习策略^[17]和柯西变异^[18]引入标准 ARO 中, 以此来改善标准 ARO 的寻优性能, 并将改进后的 ARO 标称为 OARO。具体操作如下:

① 融入反向学习策略

为改善初始种群质量, 提升算法的寻优速度, 在种群初始化阶段融入反向学习策略。现给定种群规模为 N , 其数学描述如下:

$$OP_j = lb_j + ub_j - P_j \quad (10)$$

式中, P_j 为第 j 个兔子个体的初始位置 ($j=1, 2, \dots, N$); lb_j 、 ub_j 分别为解空间的上界和下界; OP_j 为 P_j 的反向个体位置。

随后, 将 P 和 OP 种群合并, 计算合并后的每只兔子个体的适应度值, 然后根据适应度值大小将个体按升序规则排序, 顺次选取前 N 个兔子个体构成 OARO 的初始种群。

② 融入柯西变异策略

为改善标准 ARO 在寻优过程中易陷入局部最优问题, 本文提出在标准 ARO 算法每次迭代完成后, 融入柯西变异策略, 对兔子个体采取变异策略, 并计算变异后兔子个体的适应度值, 随后与变异前个体适应度值进行对比, 选择最优个体参与下一次寻优任务。其数学描述如下:

$$P_{j_new} = P_j \times \tan(\pi \times (r_{\text{rand}} - 0.5)) \quad (11)$$

式中, P_{j_new} 为变异后的兔子个体位置; r_{rand} 为 $(0, 1)$ 的随机数。

2 实例验证及分析

2.1 数据集及实验环境配置

本文从威海高频雷达站某一时间段内观测到的多批电离层杂波数据中, 选取了其中 23 批四个

距离元上的观测数据作为数据集。雷达工作频率为 5.1 MHz, 四个距离元分别为 82、84、86 及 90, 观测数据分为 I 通道和 Q 通道。本文以第 82 距离元观测数据(共 5 888 个)为例, 对两通道数据分别建立预测模型。以 Q 通道数据(共 2 944 个)为例, 选取前 19 批观测数据(共 2 432 个)作为训练样本, 对后四批观测数据(共 512 个)进行预测, 并从训练数据中选取 600 个观测数据作为验证样本集。另外, 为进一步验证所提模型的可靠性, 又从第 84、86 及 96 距离元中, 分别选取了后四批观测数据(共 512 个)作为测试样本集。I 通道预测模型建立所需数据集的分配情况同 Q 通道。

实验环境配置: Windows 10 企业版, Intel i7 CPU, 8GB RAM; 集成开发环境: MATLAB R2020b; GRU 网络模型的搭建基于软件内嵌的 Deep Learning Toolbox, 其版本为 14.1。

2.2 模型评价指标

为衡量提出的 OARO-GRU 网络预测模型的预测性能, 本文选取了平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)及决定系数 R^2 (Coefficient of Determination) 三种常用的评价指标, 具体计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

式中, n 为测试集样本数量, y_i 、 \hat{y}_i 分别为观测值和反归一化后的预测值; \bar{y} 为测试集样本中的平均值。MAE 和 RMSE 的值越小, 表明提出的 OARO-GRU 网络预测模型的预测性能越好; R^2 值大小表征观测值与预测值的拟合程度, 其值越接近 1, 表明拟合程度越高, 模型的预测性能越好。

2.3 相关参数配置

GRU 网络包含隐层节点个数、初始学习速率和最大迭代次数在内的三个超参数的取值范围分别配置为: [1, 100]、[0.001, 0.01]、[1, 256]。输出节点个数配置为 1, 关于输入节点个数, 通过 C-C 法分别计算出 I 通道的嵌入维数为 4、Q 通道的嵌入维数为 6。因此, I 通道预测模型的输入节点个数配

置为 4, Q 通道配置为 6。针对 OARO 参数配置, 其种群规模 N 配置为 5, 最大迭代次数 T 配置为 15。

为突显本文建立的 OARO-GRU 网络预测模型的优越性, 选择了反向传播神经网络(Back Propagation Neural Network, BPNN)、支持向量回归(Support Vector Regression, SVR)、极限学习机(Extreme Learning Machine, ELM)、GRU、ARO-GRU、AEO(Artificial Ecosystem Optimization)^[19]-GRU、SCA(Sine Cosine Algorithm)^[20]-GRU 这 7 种预测模型作为对照组。其中, BPNN、SVR 和 ELM 这 3 种单一预测模型是为突出 GRU 网络在电离层杂波序列预测中的优势, 单一预测模型中涉及到的相关参数取值均在最佳情况下设定; ARO-GRU、AEO-GRU 和 SCA-GRU 这 3 种混合预测模型是为: 一方面展现混合预测模型的优势, 另一方面表明 OARO 相较于常用的元启发式优化算法, 在寻优精度上的优越性。混合预测模型中涉及到的包含种群规模、最大迭代次数及解空间范围在内的参数取值均与 OARO-GRU 网络预测模型参数配置一致。

2.4 结果分析

为确保实验结果的可靠性, 文中所有预测模型均独立运行 20 次。经测试, 8 种预测模型分别第 82 距离元 I 通道和 Q 通道上的平均预测结果见表 1。同时, 为便于直观分析不同预测模型的输出值与实际观测值间的差距, 分别绘制了如图 2 和图 3 所示的预测结果曲线。

通过分析表 1 可以得出以下结论: ① GRU 更适合处理具有混沌特性的电离层杂波序列。具体的, 对比 GRU、SVR、ELM 和 BPNN 这 4 种单一时间预测模型, GRU 相较于其他 3 种模型, 在 I 和 Q 两通道上, 其 RMSE、MAE 的取值均最小, I 通道上其值分别为 4.130 1E-05、3.181 8E-05, Q 通道上其值分别为 4.867 2E-05、3.773 2E-05。而 R^2 值最大, 在 I 和 Q 两通道上取值分别为 0.837 1、0.811 9; ② 利用元启发式优化算法执行 GRU 网络超参数值优选, 可以显著改善 GRU 网络的预测精度。具体的, 对比 ARO-GRU、AEO-GRU、SCA-GRU 和 GRU 这 4 种预测模型, 不论是在 I 通道上或是在 Q 通道上, 前 3 种预测模型的 RMSE、MAE 及 R^2 值均明显优于单一预测模型 GRU。以 ARO-GRU 在 Q 通道上的预测结果为例, 其 RMSE、MAE 分别为 1.922 0E-05、1.471 6E-05, 相较于 GRU, 分别减少了 60.51%、61.00%, 而 R^2 值为 0.970 3, 相

表 1 第 82 距离元不同预测模型评价指标对比

Table 1 Comparison of evaluation metrics of different prediction models in 82th range cell

Models	I			Q		
	RMSE	MAE	R ²	RMSE	MAE	R ²
OARO-GRU	1.820 9E-05	1.376 2E-05	0.968 4	1.433 0E-05	1.095 1E-05	0.983 7
ARO-GRU	2.277 9E-05	1.748 9E-05	0.950 6	1.922 0E-05	1.471 6E-05	0.970 3
AEO-GRU	2.179 8E-05	1.656 0E-05	0.954 8	1.806 6E-05	1.376 2E-05	0.974 0
SCA-GRU	2.615 5E-05	2.023 0E-05	0.934 7	2.005 5E-05	1.541 8E-05	0.968 0
GRU	4.130 1E-05	3.181 8E-05	0.837 1	4.867 2E-05	3.773 2E-05	0.811 9
SVR	5.847 7E-05	4.424 6E-05	0.676 0	5.528 4E-05	4.253 2E-05	0.758 7
ELM	5.890 6E-05	4.466 6E-05	0.671 2	5.785 3E-05	4.452 0E-05	0.735 8
BPNN	5.948 3E-05	4.503 6E-05	0.664 5	5.788 0E-05	4.442 9E-05	0.735 4




图 2 第 82 距离元 I 通道上不同预测模型预测结果曲线
Fig. 2 The prediction result curves of different prediction models on the 82th range cell I channel

较于 GRU, 提升了 19.52%; ③ OARO-GRU 网络预测模型相较于其他 3 种混合对比预测模型, 具有较高的预测精度, 同时也验证了文中针对标准 ARO 提出的改进策略是有效的。具体的, 对比 OARO-GRU、ARO-GRU、AEO-GRU 和 SCA-GRU 这 4 种预测模型, 在 I 和 Q 两通道上, 本文提出的 OARO-GRU 网络预测模型在 3 个评价指标的取值均明显优于其他 3 种。以 OARO-GRU 与 AEO-GRU 为例, 在 I 通道上, OARO-GRU 的 RMSE、MAE 取值分别为 1.820 9E-05、1.376 2E-05, 相较于 AEO-GRU, 分别减少了 16.46%、16.89%, 而 R² 值为

0.968 4, 相较于 AEO-GRU 提升了 1.43%; 在 Q 通道上, OARO-GRU 网络预测模型在给定的 3 个评价指标上, 相较于 AEO-GRU, 其 RMSE、MAE 分别减少了 20.68%、20.42%, 而 R² 值则提升了 0.99%。

进一步观察图 2 和图 3 所示的预测结果曲线可以看出: GRU 网络输出的预测值相较于实际观测




图 3 第 82 距离元 Q 通道上不同预测模型预测结果曲线
Fig. 3 The prediction result curves of different prediction models on the 82th range cell Q channel

值, 不论是在 I 通道上或是 Q 通道上, 拟合曲线在波峰和波谷处均出现了明显的滞后现象, 而其他 4 种混合预测模型则不存在滞后现象, 再次验证了利用元启发式优化算法可以显著改善 GRU 网络的

预测性能。另外，OARO-GRU网络预测模型相较于其他3种混合预测模型，在I和Q两通道上对实际观测值的拟合程度明显更高，突显了OARO-GRU网络具有较高预测精度的优势。

为验证OARO-GRU网络预测模型的可靠性，分别选取第84、第86和第90距离元后四批I、Q两通道实际观测数据作为验证数据集，并选取ARO-GRU、AEO-GRU和SCA-GRU这3种混合预测模型作为对照组，以 R^2 值作为模型评价指标，测试结果见表2。

观察并分析表2可以得出以下结论：①随着距离元的增加，OARO-GRU网络预测模型相较于对比模型，仍具有较高的预测精度。对比4种混合预测模型在某一距离元上的预测结果，OARO-GRU网络预测模型相较于其他3种预测模型，不论是在I通道上或是Q通道上，其 R^2 值均优于对比模型。以第90距离元两通道上预测结果为例，OARO-GRU网络预测模型在I通道上，其 R^2 值为0.965 0，相较于ARO-

GRU、AEO-GRU和SCA-GRU网络预测模型，分别提升了4.23%、2.94%和6.58%；在Q通道上，其 R^2 值为0.975 7，相较于上述3种对比模型，分别提升了5.11%、3.92%和7.20%；②顺次对比表2中其他3种混合预测模型，OARO-GRU网络预测模型的 R^2 值以第82距离元作为基准，随着距离元的增加，其递减程度最低，具有较高的可靠性。具体的，在I通道上的3个验证距离元上，顺次递减0.15%、0.31%、0.35%；而ARO-GRU顺次递减0.89%、1.44%、2.60%；AEO-GRU顺次递减0.54%、1.08%、1.81%；SCA-GRU顺次递减0.82%、1.72%、3.12%。在Q通道上，OARO-GRU网络预测模型的 R^2 值顺次递减0.29%、0.63%、0.81%；而ARO-GRU顺次递减1.00%、1.86%、2.06%；AEO-GRU顺次递减0.91%、1.29%、1.48%；SCA-GRU顺次递减1.53%、1.71%、2.18%。

综上，本文提出的OARO-GRU网络预测模型具有较高的预测精度及可靠性。

表2 其他距离元混合预测模型 R^2 值对比

Table 2 Comparison of R^2 value using different hybrid prediction models on other range cells

Range-Cell	OARO-GRU		ARO-GRU		AEO-GRU		SCA-GRO	
	I	Q	I	Q	I	Q	I	Q
84	0.966 9	0.980 8	0.942 1	0.960 6	0.949 6	0.965 1	0.927 0	0.953 2
86	0.965 4	0.977 5	0.936 9	0.952 3	0.944 5	0.961 4	0.918 6	0.951 4
90	0.965 0	0.975 7	0.925 9	0.950 3	0.937 5	0.959 6	0.905 5	0.946 9

3 结束语

为有效减缓电离层杂波对HFSWR的影响，进一步提升HFSWR的目标探测能力，本文利用实测电离层杂波数据，通过GRU网络结合改进ARO，建立了一种预测精度高、可靠性强的OARO-GRU电离层杂波短期预测模型。文中通过将GRU网络与SVR、BPNN和ELM这3种常用的单一时间预测模型进行对比，在第82距离元I、Q两通道上，GRU网络获得的MAE、RMSE取值均最小，而 R^2 值最大，分别为0.837 1、0.811 9，证明了GRU网络更适合用来处理具有混沌特性的电离层杂波序列；针对标准ARO存在的收敛速度慢、易陷入局部最优等问题，文中提出了两种改进策略并将改进后的新算法OARO用于执行GRU网络三个超参数值的优选，通过对比单一预测模型GRU网络，不论是在I通道上或是Q通道上，OARO-GRU网

络获得的预测结果均显著优于GRU网络。以 R^2 值为例，OARO-GRU网络在I、Q两通道上的取值分别为0.968 4、0.983 7，相较于GRU网络，对应通道上分别提升了15.69%、21.16%。因此，借助元启发式优化算法可显著提升GRU网络的预测精度；为验证OARO的优势，文中选用常用的两种同类型元启发式算法进行了对比，证明了OARO显著的寻优能力；另外，通过使用OARO-GRU网络对包含第84、86及90距离元上的电离层杂波数据进行短期预测，来验证OARO-GRU网络的可靠性。相较于ARO-GRU、AEO-GRU和SCA-GRU这3种对比模型，随着距离元的增加，OARO-GRU网络获得的 R^2 值仍明显优于对比模型，且递减程度最低。以90距离元I通道为例，OARO-GRU网络其 R^2 值为0.965 0，相较于对比模型，分别提高了4.23%、2.94%、6.58%；并以第82距离元I通道为基准，4种预测模型在该距离元上获得的 R^2 值分别

减少了 0.35%、2.60%、1.81% 和 3.12%，OARO-GRU 网络其 R^2 值递减程度最低，验证了文中提出的预测模型具有较强的可靠性。本文建立的电离层杂波短期预测模型为有效改善 HFSWR 的探测性能提供了新的思路。

参考文献

- [1] LI J M, YANG Q, ZHANG X, et al. Space-time adaptive processing clutter-suppression algorithm based on beam reshaping for high-frequency surface wave radar[J]. Remote Sensing, 2022, 14(12): 2935 - 2950.
- [2] LI Y, HE M K, ZHANG N. An ionospheric clutter recognition method based on machine learning[C]//IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting, 2017.
- [3] LYU Z, YU C J, LIU A J, et al. Comparative study on chaos identification of ionospheric clutter from HFSWR [J]. IEEE Access, 2019, 7: 157437 - 157448.
- [4] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[EB/OL]. (2014-09-03) [2023-11-01]. <https://arxiv.org/abs/1406.1078>.
- [5] ZARZYCKI K, ŁAWRYŃCZUK M. LSTM and GRU neural networks as models of dynamical processes used in predictive control: A comparison of models developed for two chemical reactors[J]. Sensors, 2021, 21(16): 5625-5651.
- [6] 马丽文, 张金鹏, 吴家骥, 等. 基于门控循环神经网络的海杂波幅度预测 [J]. 电波科学学报, 2020, 35(2): 257-263.
MA Liwen, ZHANG Jinpeng, WU Jiaji, et al. Prediction of sea clutter using gated feedback recurrent neural network[J]. Chinese Journal of Radio Science, 2020, 35(2): 257-263.
- [7] YU J N. Short-term airline passenger flow prediction based on the attention mechanism and gated recurrent unit model[J]. Cognitive Computation, 2022, 14(2): 693-701.
- [8] HONG J C, YANG H X, MA F. Multi-forward-step battery voltage prediction for real-world electric vehicles using gated recurrent units[J]. Journal of Energy Storage, 2023, 73: 109056-109063.
- [9] ZHANG S Q, LUO J, WANG S Y, et al. Oil price forecasting: A hybrid GRU neural network based on decomposition-reconstruction methods[J]. Expert Systems with Applications, 2023, 218: 119617-119631.
- [10] QURESHI S, SHAIKH F, KUMAR L, et al. Short-term forecasting of wind power generation using artificial intelligence[J]. Environmental Challenges, 2023, 11: 100722-100734.
- [11] LAWAL A I, KWON S, HAMMED O S, et al. Blast-induced ground vibration prediction in granite quarries: An application of gene expression programming, anfis, and sine cosine algorithm optimized ANN[J]. International Journal of Mining Science and Technology, 2021, 31(2): 265-277.
- [12] ISLAM N, IRSHAD K. Artificial ecosystem optimization with deep learning enabled water quality prediction and classification model[J]. Chemosphere, 2022, 309(1): 136615-136624.
- [13] GÜLMEZ B. Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm[J]. Expert Systems with Applications, 2023, 227: 120346-120361.
- [14] WANG L Y, CAO Q J, ZHANG Z X, et al. Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems [J]. Engineering Applications of Artificial Intelligence, 2022, 114: 105082-105112.
- [15] TAKENS F. Detecting strange attractors in turbulence[C]//Dynamical Systems and Turbulence, Warwick 1980: Proceedings of A Symposium Held at The University of Warwick 1979/80, 2006.
- [16] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. Physica D: Nonlinear Phenomena, 1999, 127(1-2): 48-60.
- [17] MAHDAVI S, RAHNAMAYAN S, DEB K. Opposition based learning: A literature review[J]. Swarm and Evolutionary Computation, 2018, 39: 1-23.
- [18] SALGOTRA R, SINGH U, SINGH S, et al. A new set of mutation operators for dragonfly algorithm[J]. Arabian Journal for Science and Engineering, 2021, 46(9): 8761-8802.
- [19] ZHAO W G, WANG L Y, ZHANG Z X. Artificial ecosystem-based optimization: A novel nature-inspired meta-heuristic algorithm[J]. Neural Computing and Applications, 2020, 32(13): 9383-9425.
- [20] MIRJALILI S. SCA: A sine cosine algorithm for solving optimization problems[J]. Knowledge-Based Systems, 2016, 96: 120-133.

[作者简介]

- 乔铁柱 1998年生, 硕士研究生。
尚尚 1982年生, 副教授, 硕士生导师。
石依山 1999年生, 硕士研究生。
刘强 1999年生, 硕士研究生。

(本文编辑: 杨秀丽)