

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2023.0429

基于改进 TCN-Elman 神经网络的 电离层杂波抑制方法

刘强, 尚尚*, 乔铁柱, 祝健, 石依山

(江苏科技大学 海洋学院, 镇江 212003)

摘 要: 高频地波雷达因其卓越的海面目标探测能力, 被世界各国应用于海上工程领域, 而提升其目标探测能力的关键要素之一在于回波信号中电离层杂波的抑制, 针对这一现象, 提出一种基于瓶颈膨胀卷积模块改进时序卷积 (ITCN)-Elman 神经网络结合混合注意力机制的电离层杂波预测抑制模型 (Mixatt-ITCN-Elman)。对电离层杂波时间序列进行相空间重构和乱序归一化, 利用 ITCN 提取高维相空间内的空间特征, 依据自注意力机制突出其中关键的空间特征, 将空间特征与原时间序列组合输入 Elman 神经网络, 结合注意力机制突显序列的空时特征, 通过空时特征与 Elman 神经网络输出序列组合输出, 得到最终预测结果。所提模型与 Elman、TCN、Att-CNN-Elman 和 TCN-Elman 模型相对比, 具有较好的预测性能和稳定性, 对于电离层杂波的抑制具有较高应用价值。

关 键 词: 高频地波雷达; 电离层杂波; 时序卷积网络; Elman 神经网络; 注意力机制

中图分类号: TN957.54

文献标志码: A

文章编号: 1001-5965(2025)09-3203-09

高频地波雷达 (high frequency surface wave radar, HFSWR) 作为现代海洋探测监控遥感领域的主要新兴技术之一, 利用高频频段 (3~30 MHz) 无线电波实现导电海平面绕射传播, 具备一系列工程优势 (如传播衰减小速度快、探测超视距大范围、检测全天候全时段、造价成本低以及频段反隐身等), 在军民应用领域有着巨大的实用价值^[1-2]。实际工程应用中, 由于海上情况的时变性和突发性, 其发射的垂直极化电磁波受多种客观因素 (如大气、同频段无线电等) 的影响而产生不可控散射, 使得雷达目标回波中掺杂着多种干扰, 其中电离层杂波干扰问题尤为显著, 因其较高的反射能量和广泛的距离单元覆盖范围, 对雷达弱目标检测性能产生了至关重要的影响。因此, 如何有效抑制电离层杂波干扰成为热点方向并持续开展研究。

纵观高频地波雷达电离层杂波抑制方法研究, 根据抑制处理方法不同, 分为电离层杂波基础特性层面抑制和电离层杂波建模层面抑制。电离层杂波基础特性层面抑制分为单通道杂波处理和多通道杂波处理。单通道杂波处理适用于某些简单情况以及特定需求, 当杂波分布更为复杂或与目标特性相近时, 则达不到预期效果, 造成抑制不彻底或目标丢失, 如子空间分解类^[3]、时频特性类^[4]和小波分解类^[5]。子空间分解类通过特征值划分噪声和信号子空间, 实现特定范围特征值的杂波抑制, 与目标特征值相近的电离层杂波抑制效果不佳; 时频特性类基于时域和频域相关联, 适用于单一情况, 复杂情况下易造成目标丢失; 小波分解类通过多尺度分析实现抑制, 对于平稳信号抑制效果好, 反之抑制能力受限, 目标信号受损。多通道杂波处理解决

收稿日期: 2023-06-30; 录用日期: 2023-11-03; 网络出版时间: 2023-11-13 16:44

网络出版地址: link.cnki.net/urlid/11.2625.V.20231110.1522.002

基金项目: 国家自然科学基金 (61801196); 江苏省研究生科研与实践创新计划资助项目 (SJCX23_2138)

*通信作者. E-mail: shangshang@just.edu.cn

引用格式: 刘强, 尚尚, 乔铁柱, 等. 基于改进 TCN-Elman 神经网络电离层杂波抑制方法 [J]. 北京航空航天大学学报, 2025, 51 (9): 3203-3211. LIU Q, SHANG S, QIAO T Z, et al. Ionospheric clutter suppression method based on improved TCN-Elman neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51 (9): 3203-3211 (in Chinese).

了多数单通道杂波处理的问题,但主要依赖于系统阵列的大小,对初始系统的要求高,排列复杂,成本昂贵,如旁瓣对消类^[6]、自适应波束形成类^[7]、空时自适应类^[8]、极化滤波类^[9]和偏振滤波类^[10]。旁瓣对消类利用辅助通道加权对消,抑制效果受目标方向性影响;自适应波束形成类多用于多通道杂波处理,调整波束实现抑制,需要高算法和计算资源;空时自适应类通过多通道信息调整参数,提高信号质量,但计算维度高且耗时,不利于实时处理;极化滤波类利用垂直和水平极化实现抑制,但系统复杂且成本高;偏振滤波类通过偏振信息实现抑制,但硬件要求高且处理时间长,工程实现困难。

在电离层杂波建模层面抑制,通过对电离层杂波信号建模,实现电离层杂波抑制。依据电波传播理论和光线追踪结合多普勒光谱分析搭建模型,实现自适应识别处理,但模型的准确性取决于数据集的多少,计算复杂度较高,如电离层杂波模型^[11]、电离层杂波功率模型^[12];依据电离层不同层高所产生电离层杂波统计特性的不同,结合智能杂波分类,实现点对点分类抑制,效果高于单一方法处理,但不同统计特性需使用不同抑制方法,系统较为复杂,如电离层杂波分类建模^[13]、马尔可夫跳跃电离层高度偏差建模^[14];依据电离层杂波的混沌特性,采用非线性预测类方法建立混沌动力学模型,从时间序列上进行建模,实现电离层杂波的抑制,预测精度高,抑制效果好,具有强大的计算能力以及时变适应能力,如电离层杂波混沌模型^[15]。

近年来,随着深度学习和电子硬件的爆发式增长,深度学习成功应用于混沌时间序列预测,相较于传统神经网络,具备更高的预测精度、更强的计算能力以及更优的时变适应能力等优势。文献^[16]提出一种改进后时域卷积模型,在保证精度的前提下,提高了训练速度,网络更加稳定,但由于模型使用了大量的卷积模块,适用于数据量大的预测情景;文献^[17]提出一种注意力机制优化混合神经网络的时序预测模型,在高维和低维的问题处理上,都具有不错的表现;文献^[18]利用混沌理论与 Elman 神经网络组合,提高海水冷却系统参数的短期预测精度,为航运智能化提供了新的研究方向。

相较于现有电离层杂波抑制方法,受到电离层空时变化的限制,可能影响雷达弱目标检测的性能。伴随着深度学习的爆发式增长,电离层杂波混沌模型对非线性数据具有更好的拟合逼近能力、计算能力以及稳定性。为了进一步提高电离层杂波抑制效果,深入研究电离层杂波特性,本文提出一种基于改进时域卷积(improved temporal convolutional network, ITCN)-Elman 神经网络结合混合注意

力机制(mixed attention mechanism)的电离层杂波预测抑制模型(Mixatt-ITCN-Elman),其中引入了瓶颈膨胀卷积残差模块,自注意力机制(self-attentive mechanism)和注意力机制(attention mechanism),运用 ITCN 和 Elman 神经网络实现电离层杂波复杂时间序列预测抑制。该方法首先将雷达回波信号中电离层杂波时间序列进行数据预处理,即相空间重构和乱序归一化;其次,利用自注意力机制自迭代突显卷积放大后的空间特征;最后,利用注意力机制提取混合模型的空时特征,得到最终预测结果。实验结果表明,Mixatt-ITCN-Elman 模型能有效实现电离层杂波时间序列的预测抑制,较其他模型具有更好的预测精度、网络梯度结构和时变适应能力,优化了电离层杂波抑制效果。

1 数据预处理

1.1 电离层杂波混沌特性验证

本文采用主成分分析法(principal component analysis, PCA)和最大李雅普诺夫(Lyapunov)指数法^[19]分别从定性和定量 2 个方面对电离层杂波时间序列的混沌特性进行验证。主成分分析法首先通过计算得电离层杂波时间序列相空间矩阵 $X_{l \times m}$ (l 为轨道维数, m 为嵌入维数)的协方差矩阵 C ,其次计算得 C 的特征值 λ ,按从大到小排序并对其进行求和得 γ 。以嵌入维数 m 为 x 轴, $\ln(\lambda_i/\gamma)$ 为 y 轴绘出主成分分析图如图 1 所示,电离层杂波主成分在图上呈一条斜率为负的直线,斜率 $k=-0.15$,从而定性地判断电离层杂波时间序列具有混沌特性。




图 1 电离层杂波主成分分析图

Fig. 1 Principal component analysis of ionospheric clutter

Lyapunov 指数法通过 Wolf 方法计算最大 Lyapunov 指数,意为系统相邻轨线在相空间中随时间演化是收敛或是发散的指数率,定义为

$$\lambda_1 = \frac{1}{t_m - t_0} \sum_{k=1}^m \log_2 \frac{L(t_k)}{L(t_{k-1})} \tag{1}$$

式中: m 为最大迭代次数; $L(t_k)$ 为邻近两点在 t_k 时刻

间距。计算得到电离层杂波最大 Lyapunov 指数 $\lambda = 0.3795 > 0$, 从而定量地判断电离层杂波时序序列具有混沌特性。综上所述, 判断电离层杂波时序序列具有混沌特性。

1.2 电离层杂波相空间重构

为有效提取时间序列动力系统模型内包含的信息, 通过相空间重构将一维时间序列拓展至高维相空间, 近似恢复出反映原始混沌系统演化特征的混沌吸引子。本文采用 C-C 方法^[20]得到相空间重构所需要的嵌入维数 m 和时间延迟 τ 。

假设, 电离层杂波一维时间序列 $x(n)$ 为

$$\{x(n)|n = 1, 2, \cdots, N\} \tag{2}$$

经相空间重构, 将一维时间序列扩展至 m 维相空间, 得高维相空间序列 X :

$$X_i = \{x_i, x_{i+\tau}, \cdots, x_{i+(m-1)\tau} | i = 1, 2, \cdots, N-(m-1)\tau\} \tag{3}$$

根据 Haykin^[21] 所提出的预测方程观点, 电离层杂波预测方程为

$$x_{i+m\tau} = F(x_i, x_{i+1}, \cdots, x_{i+m\tau-1}) \tag{4}$$

1.3 数据乱序归一化

在深度学习领域中, 不同评价指标具有不同的量纲和量纲单位, 数据归一化处理可有效消除奇异样本数据所导致的影响, 在一定程度上提高模型的训练速度和收敛精度, 而乱序处理能有效提高模型的泛化能力, 防止模型产生“过拟合”现象。公式如下:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \tag{5}$$

$$x'' = \{x'(i) | i = \text{randperm}(N)\} \tag{6}$$

1.4 电离层杂波抑制

高频地波雷达回波信号 R-D 谱中, 同一片电离层杂波云团内部非线性动力系统相似, 利用相邻距离单元中不含目标的电离层杂波时间序列作为训练样本建立预测模型, 因电离层杂波的动力系统与目标信号不同, 通过将原始距离单元雷达回波与预测值对消实现电离层杂波的抑制, 实现目标信号的保留。电离层杂波预测抑制模型的建立过程如图 2 所示。




图 2 电离层杂波抑制流程

Fig. 2 Flow chart of ionospheric clutter suppression

步骤 1 选取距离单元中不含目标的电离层杂波时间序列作为训练样本输入, 并对其进行数据预处理。

步骤 2 设置训练误差容限和最大训练迭代次数, 将重构相空间 D 和时间序列 T 输入 Mixatt-ITCN-Elman 模型中迭代训练, 得到电离层杂波预测模型。

步骤 3 将原始距离单元雷达回波数据与预测值相对消, 实现雷达回波中电离层杂波的抑制。

2 Mixatt-ITCN-Elman 模型

Mixatt-ITCN-Elman 模型如图 3 所示, 不同网络处理侧重点不同, 即最后产生的作用也不同。预处理后的高维相空间序列既包含原始混沌系统的空间特征, 也蕴含着大量的时间特征。将一维时间序列重构至高维相空间, 放大序列的空时特征, 通过乱序归一化消除尺度效应, 利用瓶颈膨胀卷积残差

模块和残差连接以提高模型的非线性映射能力, 更好地适应数据中的复杂特征, 用于捕捉电离层杂波数据中的长期和短期变化, 通过 ITCN 模型提取高维相空间内的空间特征, 运用自注意力机制自迭代突出序列中关键的空间特征, 运用 Elman 模型的短时记忆功能提取空间特征下的时间特性和高维相空间的关联性, 并采用注意力机制捕获突出模型训练后的关键信息, 使得模型更具有适应性和泛化能力, 能够更好地解决电离层杂波的复杂性问题。模型详细描述如下。

2.1 TCN 模块

针对传统神经网络无法大规模并行处理的弊端, 时序卷积网络 (temporal convolutional network, TCN) 模型以卷积神经网络为基础, 通过扩展感受野和堆叠参残差块来增强其性能, 具备多项优点, 其中包括有效捕捉时间序列之间的依赖关系、避免梯度弥散以及并行计算输出等。其核心组成部分




图 3 Mixatt-ITCN-Elman 模型

Fig. 3 Mixatt-ITCN-Elman model

包括因果卷积、膨胀卷积和残差模块，模块介绍如下。

2.1.1 因果卷积

相较于卷积神经网络 (convolutional neural networks, CNN) 的前后时间信息同时提取，因果卷积与循环神经网络 (recurrent neural networks, RNN) 相类似，为单向结构，如图 4 所示。为确保未来时间序列信息不会泄露到过去，且输入序列长度与输出序列长度一致，对输入序列进行填充，以遵循因果关系规则。因需要感知视野联系前向时间序列，在处理长序列问题时，不可避免地要求网络具有更深的结构或更大的滤波器，网络层数的不断累积，使得训练更加复杂。




图 4 因果卷积结构

Fig. 4 Causal convolution structure

2.1.2 膨胀卷积

为适应各种类型的序列，得到更大的感知视野，在因果卷积的基础上加入膨胀因子，以较少的层数获得较大范围的序列信息。对于一维时间序列 $\{x_1, x_2, \dots, x_i\}$ ，滤波器 $\{f_1, f_2, \dots, f_k\}$ ，在 x_m 处的膨胀卷积公式为

$$F(m) = (x * _d f)(m) = \sum_{n=0}^{k-1} f(n) \cdot x_{m-d \cdot n} \quad (7)$$

式中： $*$ 为卷积运算； d 为膨胀因子，呈指数增长 ($d = 2^k$)； k 为卷积核大小； $x_{m-d \cdot n}$ 为前向联系序列，由于膨胀卷积输入输出特性，每一层都得在序列最左端补值，数量为 $(k-1)d$ 。如图 5 所示，卷积核 $k=2$ ，膨胀因子 $d=[1, 2]$ 。




图 5 膨胀卷积结构

Fig. 5 Expansion convolution structure

2.1.3 残差模块

随着网络层数的不断叠加，带来种种好处的同时，问题也随之而来，如梯度范数过大、梯度弥散以及训练集精度下降等，残差连接便可有效解决这些问题。如图 3 所示，其结构类似于长短期记忆网络 (long short-term memory, LSTM) 中控制门，网络权重的链式反向传播学习由 $x \rightarrow f(x)$ 映射减少为 $x \rightarrow (f(x) - x)$ 映射，使得特征学习更为简单，优化了模型的泛化能力。

2.2 注意力机制

在深度学习领域，注意力机制模仿人类认知注意力被提出，用于提取模型特征，提高模型精度和训练速度，广泛应用于计算机视觉领域和自然语言处理领域等^[22]。本文将注意力机制应用于提取 Mixatt-ITCN-Elman 模型中的关键空时特征，优化模型的训练精度，以提高模型的精确性和稳定性。如

图 6 所示, 注意力机制可以理解作为一种对于序列权重赋值求和的全连接网络, 主要负责对序列特征向量的加权求和, 从而提取关键特征向量 c , 计算公式如下:

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^n \exp(e_j)} \quad (8)$$

$$c = \sum_{i=1}^n \alpha_i V_i \quad (9)$$

式中: α 为 V 的注意力权重; e 为个体序列相似性, $e_i = \text{MLP}(\mathbf{K}, \mathbf{L})$, 其全连接层激活函数为 $\tanh$, $\mathbf{K}$ 为参量 Query, $\mathbf{L}$ 为参量 Value; n 为 Elman 网络输入步长; v 为 Elman 网络输出向量。




图 6 注意力模型

Fig. 6 Attention model

2.3 自注意力机制

自注意力机制为注意力机制中变体分支, 其不仅包含个体序列的主体信息, 也包含和其他序列的关系信息, 为目标序列内部元素互相做注意力机制, 因其权重是动态变化的, 具有适应度高以及计算速度快等优势^[23]。本文将自注意力机制应用于残差模块中, 用于捕获个体序列之间的关系信息, 有效优化了空间特征提取的准确性和全面性。如图 7 所示, 自注意力机制与注意力大体流程类似, 但内部个体序列相似性 e 计算方式不同, 计算公式如下:

$$e_{ij} = \frac{Q_i K_j}{\sqrt{d}} \quad (10)$$




图 7 自注意力模型

Fig. 7 Self-attention model

式中: d 为 Q 和 K 的维度, K 为参量 Key。

2.4 ITCN 模块

图 3 列出了 ITCN 模块的结构框架, 在 TCN 模块的基础上引入自注意力机制, 通过自注意力机制自迭代捕获高维相空间序列的空间特征, 提升模型的自适应能力和特征提取能力。同时, 将残差模块中一维卷积模块结合瓶颈残差^[24]和膨胀卷积生成瓶颈膨胀卷积模块, 用于灵活改变序列维度, 提升感知视野, 提高模型的计算能力和预测精度, 从而提高模型的稳定性和精确性。

2.5 Elman 模块

Elman 神经网络又称局部反馈神经网络, 如今已成功应用于各个领域^[25-26]。相对于传统反向传播神经网络增加了一个具有短期记忆功能的特殊结构层, 即承接层, 有效提高了网络的非线性处理能力、时变适应能力以及全局稳定性。结构如图 8 所示, 数学模型如下:

$$x(k) = f(w_2 x_c(k) + w_1 u(k) + b_1) \quad (11)$$

$$x_c(k) = x(k-1) \quad (12)$$

$$y(k) = g(w_3 x(k) + b_2) \quad (13)$$

式中: k 为当前时刻状态; y 、 x 、 u 、 x_c 分别为输出向量、隐含层节点向量、输入向量和承接层节点向量; w 为各层之间权重矩阵; b 为各层阈值; f 为 $\tanh$ 函数; g 为 purelin 函数。




图 8 Elman 模块

Fig. 8 Elman module

3 实验分析与验证

本文中, 用于实验的系统配置包括 AMD Ryzen7 5800H with Radeon Graphics GPU、Nvidia GeForce RTX 3050 Ti GPU 和 Python(3.8 版本)。实验选用工作频率 5.1 MHz, 调制周期 49.77 ms, 脉冲宽度 0.42 ms, 脉冲重复周期 2.37 ms, 基带信号采样频率 0.1 MHz

的高频地波雷达(哈尔滨工业大学威海实验站)实测数据进行结果验证。由于雷达回波信号具有相位信息,需分别构建实部和虚部模型。下面实验以实部数据模型为例,虚部模型同理。根据 C-C 方法计算获得电离层杂波时间序列嵌入维数 $m=3$,时间延迟 $\tau=5$,故而可得 Elman 神经网络的输入层节点为 15,隐含层节点为 5,承接层节点为 5,输出层节点为 1。

电离层杂波预测模型的预测精度评估计算公式如下:

$$\sigma = 1 - \frac{\text{var}(\mathbf{y}_i - \hat{\mathbf{y}}_i)}{\text{var}(\hat{\mathbf{y}}_i)} \tag{14}$$

式中: $\text{var}()$ 为方差; $\hat{\mathbf{y}}_i$ 为时间序列预测值; $\mathbf{y}_i$ 为时间序列真实值。

为验证 Mixatt-ITCN-Elman 模型对于电离层杂波相邻距离单元的预测能力,利用 Elman 模型、TCN 模型、TCN-Elman 模型以及加入注意力机制的 CNN-Elman 模型形成对比实验,为评价模型的预测性能,本实验采用 4 个评价指标进行具象化评估,分别为均方根误差(RMSE, R)、平均绝对误差(MAE, M)、平均绝对百分比误差(SMAPE, S)和斯皮尔曼相关系数(ρ),公式分别如下:

$$R = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\mathbf{y}}_i - \mathbf{y}_i)^2} \tag{15}$$

$$M = \frac{1}{n} \sum_{i=1}^n |\hat{\mathbf{y}}_i - \mathbf{y}_i| \tag{16}$$

$$S = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{\mathbf{y}}_i - \mathbf{y}_i|}{(|\hat{\mathbf{y}}_i| + |\mathbf{y}_i|)/2} \tag{17}$$

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \tag{18}$$

式中: n 为预测样本长度; d_i 为时间序列位次差。

选取雷达回波数据第 75 距离单元中不含目标信号的电离层杂波构建 1 024 组实验训练样本集,将第 66 距离单元构建实验测试样本集,每个模型独立运行 30 次取平均值,各个模型训练误差指标结果如表 1 所示。

如表 1 所示, Mixatt-ITCN-Elman 与 Elman、TCN、Att-CNN-Elman 和 TCN-Elman 模型对比,表中各项误差指标均为最优,即本文所提出的 Mixatt-ITCN-Elman 模型预测精度准确性高且稳定性较强。值得注意的是, Mixatt-ITCN-Elman 与 TCN-Elman 模型相比,得到了进一步的提升,说明瓶颈膨胀卷积模块能有效提高模型的计算能力,同时自注意力机制能进一步突出序列的空间特征,注意力机制能捕获

表 1 模型训练误差指标对比

Table 1 Comparison of model training error metrics

模型	R	M	$S/\%$	ρ
Elman	0.053 0	0.042 6	7.203 8	0.968 2
TCN	0.030 5	0.020 3	3.895 8	0.993 2
Att-CNN-Elman	0.020 8	0.015 7	2.543 2	0.997 2
TCN-Elman	0.020 1	0.013 8	2.155 1	0.997 4
Mixatt-ITCN-Elman	0.010 0	0.007 6	1.145 5	0.999 2

突出模型训练后的关键信息,从而提高模型预测值。单一模型 TCN 优于 Elman,说明时间序列相空间重构到高维空间后,从空间特征方面进行预测要胜于时间特征。TCN-Elman 模型相对于单一模型 TCN 和 Elman 来说,各项误差指标得到了一定程度的提升,说明 Elman 神经网络能有效提取时间序列空时特征下的时间特征,优化网络的预测性能。

如表 2 所示,在 100 次 epochs 迭代训练下,单一模型 Elman 和 TCN 训练时间较短,为 6.28 s 和 14.74 s,但精度与混合模型 Att-CNN-Elman、TCN-Elman 和 Mixatt-ITCN-Elman 相比预测精度较低。混合模型 Att-CNN-Elman、TCN-Elman 和 Mixatt-ITCN-Elman 中 TCN-Elman 模型训练时间最长,为 20.42 s, Mixatt-ITCN-Elman 模型预测精度最高,训练时间相较于 TCN-Elman 模型短了 1.72 s,相对于 Att-CNN-Elman 模型长了 2.74 s,预测精度提高为 99.66%,综合各个模型的训练误差指标、训练时间和训练精度对比, Mixatt-ITCN-Elman 模型综合优势较高,具有较好的预测性能。

表 2 模型训练时间和预测精度对比

Table 2 Comparison of model training time and prediction accuracy

模型	训练时间/s	预测精度/%
Elman	6.28	90.56
TCN	14.74	96.88
Att-CNN-Elman	15.96	98.55
TCN-Elman	20.42	98.64
Mixatt-ITCN-Elman	18.70	99.66

为进一步验证模型对于电离层杂波的抑制效果和抑制过程中对于目标信号是否产生影响,分别在第 66、86 和 106 距离单元中加入一个多普勒频率为 0.5 Hz 的目标信号。由表 3 和图 9 所示,第 66 距离单元中,目标信号被完全淹没,极大地影响了后续雷达目标检测的性能,经单一模型 Elman 和 TCN 抑制后,电离层杂波得到一定程度的抑制,但预测精度较低,抑制效果较差,信杂比较处理之前分别提升了 8.78 dB 和 14.26 dB,然而,电离层杂波幅值仍与目标信号幅值相近,无法有效识别出目标

表 3 模型不同距离单元信杂比对比

Table 3 Comparison of signal-to-clutter ratio for different distance units of the model

模型	信杂比/dB		
	66距离单元	86距离单元	106距离单元
原始	-2.96	1.14	9.27
Elman	5.82	10.22	17.65
TCN	11.30	19.21	25.19
Att-CNN-Elman	12.53	17.15	24.72
TCN-Elman	12.58	19.70	24.83
Mixatt-ITCN-Elman	15.55	25.81	30.51

信号; 相比于单一模型较快的训练速度, 混合模型的训练时长有所增加, 但对于电离层杂波的抑制效果得到了极大的提升, 经 Att-CNN-Elman 和 TCN-Elman 模型预测抑制后, 信杂比较处理之前分别提升 15.49 dB 和 15.54 dB, 目标信号已基本显现, 但目标周围的电离层杂波幅值较高, 为高频地波雷达目标检测带来了一定难度; 经 Mixatt-ITCN-Elman 模

型处理后, 将电离层杂波抑制至背景噪声附近的同同时, 还有效解决了目标信号周围电离层杂波幅值相近的问题, 目标信号得到较为完整的保存, 较处理之前提升 18.51 dB, 相较于混合模型 Att-CNN-Elman 和 TCN-Elman, 信杂比分别进一步提升 3.02 dB 和 2.97 dB。且在目标信号处于未淹没于电离层杂波的第 86 距离单元和较远距离的第 106 距离单元时, Att-CNN-Elman 模型处理效果低于 TCN 和 TCN-Elman 模型, 抑制效果产生了波动, 而 Mixatt-ITCN-Elman 模型的信杂比依旧优于其他模型, 且抑制效果更为稳定。虽训练时长较 Att-CNN-Elman 模型有所提高, 但时长增加幅度不大, 较原始 TCN-Elman 模型训练时长有所降低, 综上所述, Mixatt-ITCN-Elman 模型综合优势较大, 对于电离层杂波具有较好的预测和抑制效果表现。图 10 为同一时刻 Mixatt-ITCN-Elman 模型处理不同距离单元电离层杂波群距离-多普勒对比, 经 Mixatt-ITCN-Elman 模型处理后, 群距离-多普勒图上电离层杂波云团




图 9 各模型抑制结果对比

Fig. 9 Comparison of suppression results among different models




图 10 实测数据电离层杂波抑制前后群距离-多普勒谱对比

Fig. 10 Comparison of group distance-Doppler spectra before and after ionospheric clutter suppression of measured data

处理效果显著,目标信号可有效识别。

4 结 论

针对高频地波雷达回波信号中电离层杂波云团干扰目标检测问题,结合瓶颈膨胀卷积模块优化残差模块,利用自注意力机制突出 ITCN 模型的空间特征,注意力机制捕获混合模型 ITCN-Elman 的空时特征,提出了一种基于 Mixatt-ITCN-Elman 模型的电离层杂波云团预测抑制模型。结合相空间理论,将一维时间序列拓展至高维相空间,采用 ITCN 模型提取高维相空间的空间特征,自注意力机制突显空间特征,Elman 模型依据空间特征提取出序列内的时间特征。最后,通过注意力机制对序列的特征进行提取,提高预测精度,构建电离层杂波云团预测抑制模型,实现电离层杂波云团的预测抑制。实验结果表明,本文提出的模型相较于模型 Elman、TCN、Att-CNN-Elman 和 TCN-Elman 效果更好,极大程度上提高了电离层杂波预测的精确性和稳定性,在抑制电离层杂波云团的基础上,有效保留了目标信号,降低了目标信号周围的电离层杂波幅值,在电离层杂波抑制中具有良好的研究前景,为进一步提升雷达目标探测性能提供了可靠的理论依据。

参考文献 (References)

[1] COOK T M, TERRILL E J, GARCIA-MORENO C, et al. Observations of ionospheric clutter at near equatorial high frequency radar stations[J]. *Remote Sensing*, 2023, 15(3): 603.

[2] YANG X G, WANG M J, HUANG W M, et al. Experimental observation and analysis of ionosphere echoes in the mid-latitude region of China using high-frequency surface wave radar and ionosonde[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 4599-4606.

[3] CHEN Z Z, XIE F, ZHAO C, et al. An orthogonal projection algorithm to suppress interference in high-frequency surface wave radar[J]. *Remote Sensing*, 2018, 10(3): 403.

[4] WANG Z Q, LI Y J, SHI J N, et al. Spread sea clutter suppression in HF hybrid sky-surface wave radars based on general parameterized time-frequency analysis[J]. *International Journal of Antennas and Propagation*, 2020, 2020: 1-12.

[5] JANGAL F, SAILLANT S, HELIER M. Ionospheric clutter mitigation using one-dimensional or two-dimensional wavelet processing [J]. *IET Radar, Sonar & Navigation*, 2009, 3(2): 112-121.

[6] DING M K, WEI Y S, YU L, et al. Adaptive suppression of mainlobe spread Doppler clutter with high directivity for HFSSWR using oblique projection[J]. *Electronics Letters*, 2019, 55(23): 1245-1247.

[7] LI J M, YANG Q, ZHANG X. Space-time adaptive processing algorithm based on hyper beamforming for ionospheric clutter suppression in small-array high-frequency surface wave radar[J]. *IET*

Radar, Sonar & Navigation, 2023, 17(4): 545-555.

[8] LI Y J, WANG Z Q, XU L, et al. Spread sea clutter suppression via prior knowledge-based space time adaptive processing in high frequency hybrid sky-surface wave radar[J]. *IET Radar, Sonar & Navigation*, 2023, 17(5): 830-844.

[9] YANG Y L, MAO X P, HOU Y G, et al. A two-step method for ionospheric clutter mitigation for HFSWR with two-dimensional dual-polarized received array[J]. *IEEE Access*, 2020, 8: 105903-105913.

[10] GENG H, LIANG Y, YANG F, et al. Joint estimation of target state and ionospheric height bias in over-the-horizon radar target tracking[J]. *IET Radar, Sonar & Navigation*, 2016, 10(7): 1153-1167.

[11] CHEN S Y, HUANG W M, GILL E W. A vertical reflection ionospheric clutter model for HF radar used in coastal remote sensing[J]. *IEEE Antennas and Wireless Propagation Letters*, 2015, 14: 1689-1693.

[12] CHEN S Y, GILL E W, HUANG W M. A high-frequency surface wave radar ionospheric clutter model for mixed-path propagation with the second-order sea scattering[J]. *IEEE Transactions on Antennas and Propagation*, 2016, 64(12): 5373-5381.

[13] 位寅生, 周建宇, 许荣庆. 基于杂波聚类与贪婪策略的电离层杂波智能处理方法[J]. *雷达学报*, 2020, 9(4): 589-607.

WEI Y S, ZHOU J Y, XU R Q. Intelligent suppression method for ionospheric clutter based on clustering and greedy strategy[J]. *Journal of Radars*, 2020, 9(4): 589-607(in Chinese).

[14] GENG H, LIANG Y, CHENG Y H. Target state and Markovian jump ionospheric height bias estimation for OTHR tracking systems[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(7): 2599-2611.

[15] LYU Z, YU C, LIU A . Chaotic dynamics of ionospheric clutter from high frequency surface wave radar[C]//IET International Radar Conference. London: IET, 2020: 1640-1646.

[16] CHENG W, WANG Y, PENG Z, et al. High-efficiency chaotic time series prediction based on time convolution neural network[J]. *Chaos, Solitons & Fractals*, 2021, 152: 111304.

[17] HUANG W J, LI Y T, HUANG Y. Prediction of chaotic time series using hybrid neural network and attention mechanism[J]. *Acta Physica Sinica*, 2021, 70(1): 010501.

[18] WEI L, CAO H, MA Z H. Parameter prediction of marine seawater cooling system based on chaos-Elman combined model[J]. *IEEE Access*, 2022, 10: 77272-77283.

[19] WOLF A, SWIFT J B, SWINNEY H L, et al. Determining Lyapunov exponents from a time series[J]. *Physica D: Nonlinear Phenomena*, 1985, 16(3): 285-317.

[20] 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.

[21] HAYKIN S. Radar clutter attractor: implications for physics, signal processing and control[J]. *IEE Proceedings-Radar, Sonar and Navigation*, 1999, 146(4): 177-188.

[22] 陈永, 陈锦, 陶美风. 多尺度特征和注意力融合的生成对抗壁画修复[J]. *北京航空航天大学学报*, 2021, 49(2): 254-264.

CHEN Y, CHEN J, TAO M F. Mural inpainting with generative adversarial networks based on multi-scale feature and attention fusion[J]. *Journal of Beijing University of Aeronautics and Astro-*

nautics, 2023, 49(2): 254-264(in Chinese).

[23] ZHU W Q, WANG Z Y, WANG X C, et al. A Dual self-attention mechanism for vehicle re-Identification[J]. *Pattern Recognition*, 2023, 137: 109258.

[24] KIM D, KIM Y. Understanding effects of architecture design to invariance and complexity in deep neural networks[J]. *IEEE Access*, 2021, 9: 9670-9681.

[25] XING W Y, BAI Y L, DING L, et al. Application of a hybrid model based on GA-ELMAN neural networks and VMD double processing in water level prediction[J]. *Journal of Hydroinformatics*, 2022, 24(4): 818-837.

[26] SUN Y Z, ZHANG J H, YU Z J, et al. WOA (whale optimization algorithm) optimizes Elman neural network model to predict porosity value in well logging curve[J]. *Energies*, 2022, 15(12): 4456.

Ionospheric clutter suppression method based on improved TCN-Elman neural network

LIU Qiang, SHANG Shang*, QIAO Tiezhu, ZHU Jian, SHI Yishan

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

Abstract: High-frequency surface wave radar is used in the field of offshore engineering worldwide because of its excellent sea surface target detection capability. One of the key elements to improve its target detection capability lies in the suppression of ionospheric clutter in the echo signal. In response, this paper proposed an ionospheric clutter prediction and suppression model (Mixatt-ITCN-Elman) based on bottleneck expansion convolution module improved temporal convolution (ITCN)-Elman neural network combined with hybrid attention mechanism. First, the ionospheric clutter time series was reconstructed in phase space and subjected to disordered normalization. The spatial features within the high-dimensional phase space were extracted by using ITCN, and the key spatial features were highlighted by combining the self-attention mechanism. Then, the spatial features were combined with the original time series and input into the Elman neural network. The spatial-temporal features of the sequences were highlighted by combining the attention mechanism. Finally, the spatial-temporal features combined with the Elman neural network output sequence were output to obtain the final prediction result. In comparison with Elman, TCN, Att-CNN-Elman, and TCN-Elman models, the proposed model has better prediction performance and stability, having high application value for the suppression of ionospheric clutter.

Keywords: high-frequency surface wave radar; ionospheric clutter; temporal convolutional network; Elman neural network; attention mechanism

* Corresponding author. E-mail: shangshang@just.edu.cn