

文章编号: 2095-4980(2025)08-0855-08

基于改进 DnCNN 的高频地波雷达海洋回波谱去噪方法

王 珽, 赵 晨, 陈泽宗, 吴思滔

(武汉大学 电子信息学院, 湖北 武汉 430072)

摘 要: 高频地波雷达(HFSWR)工作波段的电磁环境极其复杂, 包含无线电干扰、海杂波和电离层杂波在内的噪声会严重影响船只目标识别准确度。为解决这个问题, 本文提出一种改进的前馈去噪卷积神经网络(DnCNN)抑制 HFSWR 海洋回波信号中的噪声。根据 HFSWR 海洋回波信号中噪声的特点, 从图像块(patch)大小、卷积核大小、网络深度等方面对原始 DnCNN 进行修改, 使其适合 HFSWR 去噪任务。基于 HFSWR 海试数据生成了包含 10 000 对距离-多普勒(RD)谱的数据集, 并将其平均划分为训练集和测试集。对测试集中 3 组 RD 谱(分别以海杂波、射频干扰和电离层杂波为主要噪声)的去噪结果分析表明, 改进 DnCNN 模型在噪声抑制和船只目标信号幅度方面保持性能上均显著优于原始 DnCNN。此外, 对整个测试集的统计结果显示, 改进 DnCNN 去噪指标峰值信噪比平均为 44.13 dB, 显著高于原始 DnCNN 的 35.58 dB。综上所述, 改进 DnCNN 在抑制 HFSWR 海洋回波噪声的同时很好地保持了船只目标信号的幅值。

关键词: 高频地波雷达; 海洋回波; 距离多普勒谱; 卷积神经网络; 去噪

中图分类号: TN958.93

文献标志码: A

DOI: 10.11805/TKYDA2024031

Denoising method of High-Frequency Surface Wave Radar ocean echo spectrum based on improved DnCNN

WANG Ting, ZHAO Chen, CHEN Zezong, WU Sitao

(School of Electronic Information, Wuhan University, Wuhan Hubei 430072, China)

Abstract: The electromagnetic environment of the working frequency band of High-Frequency Surface Wave Radar(HFSWR) is extremely complex. Noise, including radio frequency interference, sea clutter, and ionospheric clutter, can severely affect the accuracy of ship target identification. To address this issue, an improved feedforward Denoising Convolutional Neural Network(DnCNN) is proposed to suppress the noise in HFSWR marine echo signals. Based on the characteristics of the noise in HFSWR marine echo signals, the original DnCNN is modified in terms of patch size, convolutional kernel size, and network depth to make it suitable for the HFSWR denoising task. A dataset containing 10 000 pairs of Range-Doppler(RD) spectra is generated based on HFSWR sea trial data and is evenly divided into training and testing sets. Analysis of the denoising results of three groups of RD spectra in the testing set (with sea clutter, radio frequency interference, and ionospheric clutter as the main noise sources, respectively) shows that the improved DnCNN model significantly outperforms the original DnCNN in both noise suppression and maintaining the amplitude of ship target signals. Moreover, statistical results of the entire testing set indicate that the Peak Signal-to-Noise Ratio(PSNR) of the improved DnCNN denoising metric is 44.13 dB on average, which is significantly higher than the 35.58 dB of the

收稿日期: 2024-01-18; 修回日期: 2024-02-28

基金项目: 国家自然科学基金面上资助项目

引用格式: 王珽,赵晨,陈泽宗,等. 基于改进 DnCNN 的高频地波雷达海洋回波谱去噪方法[J]. 太赫兹科学与电子信息学报, 2025,23(8):855-862. DOI:10.11805/TKYDA2024031.

Citation format: WANG Ting,ZHAO Chen,CHEN Zezong,et al. Denoising method of High-Frequency Surface Wave Radar ocean echo spectrum based on improved DnCNN[J]. Journal of Terahertz Science and Electronic Information Technology, 2025,23(8):855-862. DOI:10.11805/TKYDA2024031.

original DnCNN. In summary, the improved DnCNN effectively suppresses the noise in HFSWR marine echoes while well preserving the amplitude of ship target signals.

Keywords: High-Frequency Surface Wave Radar(HFSWR); sea-echo; Range-Doppler spectrum; Convolutional Neural Networks; denoising

高频地波雷达(HFSWR)是一种利用高频电磁波(3~30 MHz)在地平线上提供目标监测和海洋遥感功能的仪器,广泛用于船只监测、海洋环境监测和海洋资源勘测等领域。但高频波段的电磁环境极其复杂,包含无线电干扰、海杂波和电离层杂波在内的噪声会严重影响船只目标识别准确度^[1],去噪成为HFSWR船只监测的关键问题。

各国研究人员针对HFSWR海洋回波信号中不同种类的噪声提出了多种噪声抑制方法。针对海杂波,如基于奇异值分解和分数阶傅里叶变换的滤波方法^[2]和基于正交投影的方法^[3];针对射频干扰(Radio Frequency Interference, RFI),如图像处理 and 子空间投影组成的抑制方法^[4]和基于逆时域加窗和复杂经验模态分解的抑制方法^[5];针对电离层杂波,如基于小波变换的抑制方法^[6]、降维空时自适应处理联合域局部化算法^[7]以及基于斜投影偏振滤波器的抑制方法^[8]。上述传统方法虽能够在一定程度上提高HFSWR海洋回波信号的质量,但均是针对单一类型噪声,适应性有待进一步提高。随着HFSWR船只监测技术的发展,传统HFSWR海洋回波信号去噪方法已不能满足船只监测的需求,迫切需要寻找更加智能的去噪方法。近年来,随着计算机硬件的发展和深度残差网络的引入,神经网络在训练速度和网络深度方面都得到了显著提升,促进了深度学习的快速发展。卷积神经网络(CNN)作为有监督深度学习模型,由于其独特的卷积层和权重共享特性,具有更高的性能和更低的计算复杂度,在图像去噪^[9]、目标检测^[10]、图像分类^[11]、动作识别^[12]和特征学习^[13]等许多领域都取得了显著的成果。此外,还成功用于雷达目标检测^[14]和HFSWR海洋遥感领域,如自动杂波/干扰检测^[15-16]、杂波/干扰信号分类^[17]和海流预测^[18]。这些成功的应用展示了CNN在HFSWR海洋遥感领域广阔的发展前景。

本文将改进前馈去噪卷积神经网络(DnCNN)用于距离-多普勒(RD)谱去噪。由于原始的DnCNN主要用于抑制高斯噪声,直接用于HFSWR海洋回波信号效果尚有改善空间。根据HFSWR噪声的特点,调整了DnCNN的图像块(patch)大小、卷积核大小、网络深度等参数,并基于实测数据生成包含10 000对RD谱的数据集,分为训练集 and 测试集进行了去噪实验,分析比较了原始DnCNN和改进DnCNN的去噪性能。

1 原始 DnCNN

1.1 网络架构

DnCNN是张凯等在2017年提出的深度学习去噪网络^[9]。图1为DnCNN的网络架构:a)输入层:由卷积层(Convolutional Layer, Conv)和修正线性单元(Rectified Linear Unit, ReLU)函数组成,接收带噪RD谱输入;b)隐藏层:每层在Conv和ReLU函数中间加入批量归一化(Batch Normalization, BN)。其中Conv负责滤波和特征提取,通过卷积操作捕捉RD谱的空间结构特征。BN用于优化训练过程并增强网络的稳定性。ReLU函数引入非线性特性,提升网络对复杂RD谱特征及噪声分布的学习能力;c)输出层:由Conv构成,接收隐藏层的输出,并生成残差作为输出。




Fig.1 DnCNN architecture

图1 DnCNN网络架构

DnCNN采用深度卷积神经网络架构,可学习复杂的RD谱特性和噪声模型。为加速训练和提高网络的稳定性,DnCNN在隐藏层中每个Conv后都使用了BN。BN可使网络对输入数据的变化更加鲁棒,并且有助于防止梯度消失或梯度爆炸问题。

1.2 去噪原理

DnCNN通过使用卷积神经网络学习带噪RD谱的噪声分布模型,实现噪声去除。DnCNN的核心思想是利用深度卷积神经网络学习RD谱的残差映射。它采用了残差学习的概念,即网络的目标是学习输入带噪RD谱和其

对应的干净 RD 谱之间的残差, 而不是直接去学习去噪后的 RD 谱本身。对于有噪声的 RD 谱, 可表示为:

$$y = x + n \quad (1)$$

式中: y 为带噪 RD 谱; x 为干净 RD 谱; n 为带噪 RD 谱和干净 RD 谱之间的残差。RD 谱去噪的目标是从带噪 RD 谱中恢复干净 RD 谱 x , DnCNN 将带噪 RD 谱 y 作为网络输入, 旨在通过残差学习建立 n 和 y 之间的映射, 即

$$\mathfrak{R}(y; \Theta) \approx n \quad (2)$$

式中 $\Theta = \{W, b\}$ 为网络参数, 包括权重 W 和偏移量 b 。为使 $\mathfrak{R}(y; \Theta)$ 尽可能接近 n , 使用以下损失函数学习网络中的可训练参数 Θ :

$$\ell(\Theta) = \frac{1}{2P} \sum_{i=1}^P \left\| \mathfrak{R}(y_i; \Theta) - (y_i - x_i) \right\|_F^2 \quad (3)$$

式中: P 为训练集中带噪-干净训练 RD 谱对数量; $\mathfrak{R}(y_i; \Theta)$ 为 y_i 中噪声的估计。 $\ell(\Theta)$ 越小, 参数 Θ 的优化越好, 相应的 $\mathfrak{R}(y; \Theta)$ 就会越接近 n , 则可得

$$y - \mathfrak{R}(y; \Theta) \approx x \quad (4)$$

从而实现了带噪 RD 谱中噪声的抑制。

2 改进 DnCNN

2.1 去噪模型搭建与训练

网络训练的主要目的是更新隐藏层网络参数, 得到最终的去噪网络。HFSWR 海洋回波谱的 DnCNN 去噪模型的训练流程如下:

1) 数据集准备: 从海试数据中读取雷达 RD 谱, 根据船舶自动识别系统(Automatic Identification System, AIS)数据结合人工判断生成带噪 RD 谱对应的干净 RD 谱, 构建 DnCNN 所需的带噪-干净 RD 谱对数据集。

2) 划分数数据集: 按照 1:1 比例将数据集划分为训练集、测试集。

3) 网络搭建: 采用 Matlab 的 MATConvNet 工具箱构建 DnCNN 网络。原始 DnCNN 共有 17 层网络, 输入层: 64 个 $3 \times 3 \times 1$ 的卷积核; 隐藏层: 15 层, 64 个 $3 \times 3 \times 64$ 卷积核; 输出层: 1 个 $3 \times 3 \times 64$ 卷积核。通过 Training options 配置训练选项, 采用 Adam 优化器进行参数寻优。

4) 模型训练: 模型训练需设置 patch size、batch size、epoch 和 learning_rate 等模型超参数, 训练过程中存储每一个 epoch 得到的 DnCNN 网络模型。patch size 默认设置为 40×40 , 由于硬件(NVIDIA GeForce RTX 3050 OEM GPU)条件限制, batch size 最终确定为 64, 相应 epoch 为 20, learning_rate 设置在 $[10^{-5}, 10^{-3}]$ 范围内。

5) 模型去噪: 将测试数据中带噪 RD 谱输入训练好的去噪模型中, 得到网络输出对应的残差, 进一步得到去噪 RD 谱。

6) 性能评估: 将图像去噪领域经典指标峰值信噪比(Peak Signal-to-Noise Ratio, PSNR, 公式中用 R_{PSN} 表示)用于去噪性能评估:

$$R_{\text{PSN}} = 10 \lg \left(\frac{I_{\max}^2}{E_{\text{MS}}} \right) \quad (5)$$

式中: $I_{\max}$ 为带噪 RD 谱的最大值; E_{MS} 为去噪 RD 谱与干净 RD 谱之间的均方误差:

$$E_{\text{MS}} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [I(i, j) - K(i, j)]^2 \quad (6)$$

式中: $I(i, j)$ 为去噪 RD 谱第 i 个距离元、第 j 个频率点的值; $K(i, j)$ 为干净 RD 谱对应位置的点; M 和 N 分别为 RD 谱距离元数和频率点数。

PSNR 是一种经典衡量图像质量的指标。一般来说, PSNR 高于 40 dB, 说明去噪效果极好; 在 30~40 dB 之间, 通常表示去噪效果尚可, 但去噪 RD 谱和干净 RD 谱有明显差异; 在 20~30 dB 之间, 说明去噪效果不理想; 低于 20 dB, 表示去噪效果不可接受。

2.2 DnCNN 参数改进

1) patch size: 基于 patch 的图像去噪技术通常使用大小为 40 的 patch。高噪声水平通常需要更大的有效 patch

size 来捕获更多用于图像恢复的上下文信息。考虑到 HFSWR 回波信号的信噪比通常较低, 因此需要较大的有效 patch size 来描述噪声的分布并包含足够的有效信息, 但过大的 patch 会导致训练困难。大量测试实验表明, 使用大小为 20×128 的 patch 来训练网络可取得更好的去噪性能。因此, 使用大小为 20×128 的 patch 训练网络。

2) 卷积核大小: 卷积层主要用于自动特征提取, 增加卷积核的数量通常可以提取更多的特征。为使网络预测的噪声足够接近实测的 HFSWR 噪声, 需要提取足够的特征来训练网络; 另一方面, 习惯上使用一堆多个小卷积核而不是较大的卷积核, 这样网络可以具有更少的参数和更多的非线性。因此, 调整卷积核的大小。第一个卷积层使用 128 个大小为 $3 \times 3 \times 1$ 的卷积核, 最后一个卷积层使用 1 个大小为 $3 \times 3 \times 128$ 的卷积核。对于其余卷积层, 使用 128 个大小为 $3 \times 3 \times 128$ 的卷积核。

3) 网络深度: 为得到更好的去噪效果, 对 DnCNN 网络的网络深度和卷积核大小进行优化调整。一般而言, 深层神经网络比浅层神经网络具有更好的性能, 但当网络层数达到一定程度时, 其性能会饱和。继续增加网络深度, 性能没有太大提升, 但训练时间大幅增加。为找到合适的网络深度, 使用控制变量方法训练网络(patch size 和卷积核大小设置为改进后数值, 其他参数见图 2)。表 1 给出了网络深度在 6~20 之间的网络对 RD 谱噪声的抑制效果, 以及网络的训练时间。从表 1 中可以发现, 14 层后网络去噪能力没有明显提升, 但网络训练时间会大幅增加。为更好地权衡性能和效率, 最终确定网络深度为 14。




Fig.2 DnCNN network training process

图2 DnCNN网络训练流程

表1 不同网络深度下网络去噪表现

Table1 Network performance at different depths

item	6	8	10	12	14	16	18	20
PSNR/dB	25.39	31.54	34.77	42.92	44.13	44.71	44.99	45.11
training time/h	6.99	9.75	12.51	15.28	17.97	20.65	23.34	26.03

3 实验

3.1 数据集

图 3(a) 为在浙江舟山海域开展的海上试验中朱家尖雷达站获取的带噪 RD 谱。图中紫色实线框表示船只目标信号, 蓝色短虚线框表示海杂波信号, 绿色长虚线框表示 RFI 信号, 红色点划线框表示电离层杂波信号。由于 DnCNN 网络是一个监督去噪网络, 要求输入成对的带噪-干净数据进行网络训练。图 3(b) 为图 3(a) 对应的干净 RD 谱。干净 RD 的生成借助了目标船只的船舶 AIS 信息, AIS 信息用于在距离多普勒谱上标记船只信号的位置。干净 RD 谱由以下步骤生成: a) 人工结合船舶 AIS 信息将原始带噪 RD 谱中船只目标生成位置标签并保存; b) 根据位置标签将船只目标从带噪 RD 谱复制到无噪背景上, 构成带噪-干净 RD 谱对, 即数据集的组成元素。对数据

集进行划分, 将其分为训练集和测试集, 用于训练和评估去噪模型。基于 CNN 的信号重建方法的性能很大程度上取决于训练集的多样性。为提升 DnCNN 网络的泛化能力, 使其更适合 HFSWR 去噪, 需建立尽可能丰富的数据集来训练网络, 最终数据集包含 5 000 对带噪-干净 RD 谱。训练集中 5000 对含有海杂波, 1 747 对含有 RFI, 469 对含有电离层杂波。测试集中 5 000 对含有海杂波, 1 665 对含有 RFI, 486 对含有电离层杂波。




Fig.3 RD spectrum of HFSWR sea-echo

图3 HFSWR 海洋回波 RD 谱

3.2 实验结果

为测试 DnCNN 的去噪性能, 从训练数据集不同时段实测数据中选取了主要噪声分别为海杂波、RFI 和电离层杂波的 3 种典型带噪-干净 RD 谱对(HFSWR 海洋回波中必然存在很强的海杂波信号, 含有 RFI 和电离层杂波的 RD 谱同样存在此噪声)。通过对比剖析改进 DnCNN 和原始 DnCNN 对这 3 种 RD 谱的去噪效果, 说明改进 DnCNN 在去噪性能方面的优势。




Fig.4 Result of sea clutter suppression

图4 海杂波抑制效果

1) 主要噪声为海杂波的 RD 谱。图 4(a)为一种典型的以海杂波为主要噪声的带噪 RD 谱, 图 4(d)是与之对应的干净 RD 谱。可以看到 RD 谱中有 8 个船只目标信号。从图 4(b)发现, 经过改进 DnCNN 去噪后, 噪声(主要是海杂波)被彻底抑制的同时, 8 个船只目标信号均清晰可见。反观图 4(c), 经过原始 DnCNN 去噪后, 橙色框标示的 3 处目标衰减严重, 肉眼已经无法分辨, 并且黑色框所标示处还存在与目标信号相似的噪声残留。为更加清晰地展示改进 DnCNN 和原始 DnCNN 去噪效果的差异, 选取图 4(a)~(d)的第 78 个距离元进行对比分析, 如图 4(e)所

示。图中紫色长划线几乎和橙色双划线完全贴合，可见经过改进 DnCNN 去噪后，噪声被完全抑制，并且船只目标信号未见衰减。第 78 个距离元的多普勒谱原本有一个船只目标信号，如图 4(e) 中红色箭头所示。观察红色箭头所指处的蓝色虚线可以看出，船只目标信号衰减在 10 dB 以上，已经很难识别出来。

2) 主要噪声为 RFI 的 RD 谱。图 5(a) 为一种典型的以 RFI 为主要噪声的带噪 RD 谱。图 5(d) 是与之对应的干净 RD 谱，谱中有 6 个船只目标信号。从图 5(b) 中可以很轻易找到与图 5(d) 位置吻合的 6 个船只目标信号，而图 5(c) 中除了以上提到的 6 个目标信号外，黑框标示处存在极容易被误判为目标信号的噪声残留。选取图 5(a)~(d) 的第 10 个距离元进行对比分析，如图 5(e) 所示。红色箭头指出了第 10 个距离元船只目标信号的位置、目标信号所在的频率。紫色长划线和橙色双划线紧密贴合，而蓝色虚线略低一些，可见原始 DnCNN 去噪还是对目标信号造成了衰减。黑色箭头所指的位置对应的则正是图 5(c) 中黑框标示的噪声残留，蓝色虚线与绿色实线基本贴合，也说明了此处噪声基本未被抑制。




Fig.5 Result of RFI suppression

图 5 RFI 抑制效果




Fig.6 Result of ionospheric clutter suppression

图 6 电离层杂波抑制效果

3) 主要噪声为电离层杂波的 RD 谱。图 6(a) 是一种典型的以电离层杂波为主要噪声的带噪 RD 谱。图 6(d) 是与之对应的干净 RD 谱, 谱中有 4 个船只目标信号。4 个船只目标信号在图 6(b) 的相应位置都清晰可见, 而在图 6(c) 中, 橙色框标示处已经很难看出目标信号的存在, 此外黑色框标示处存在与目标信号疑似的噪声残留。为更清晰观察黄色框处目标信号衰减情况, 选取图 6(a)~(d) 的第 57 个距离元进行对比分析, 如图 6(e) 所示。红色箭头指示船只目标信号的位置, 紫色长划线和橙色双划线十分吻合, 而蓝色虚线幅度低了 10 dB 左右, 经过原始 DnCNN 去噪, 船只目标信号衰减不少。而观察船只目标信号右侧黑色箭头所标示处可见原始 DnCNN 的电离层杂波抑制效果也不如改进 DnCNN。最终造成的结果是无法从原始 DnCNN 去噪后的 RD 谱中分辨出船只目标。

综合以上 3 种典型带噪 RD 谱的去噪结果分析, 改进 DnCNN 相比原始 DnCNN 在 HFSWR 去噪任务上性能更加出色, 主要体现在噪声信号抑制和船只目标信号保持两个方面。此外, 对整个测试集的统计结果表明, 改进 DnCNN 去噪指标峰值信噪比平均为 44.13 dB, 显著高于原始 DnCNN 的 35.58 dB。

4 结论

本文设计了一种改进的 DnCNN, 用于 HFSWR 海洋回波谱去噪。它具有以下优点: a) 可以训练单个模型来对不同类型和水平的噪声信号实现去噪任务; b) 改进后的 DnCNN 不需要参数调试, 可自动完成去噪任务; c) 网络能够智能识别噪声并抑制噪声, 去噪后信号幅度基本没有衰减。在未来的工作中, 将使用不同雷达系统收集的更多数据集来验证所提出的方法。

参考文献:

- [1] CHEN Zezong, HE Chao, ZHAO Chen, et al. Enhanced target detection for HFSWR by 2-D MUSIC based on sparse recovery[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(11): 1983–1987. DOI: 10.1109/LGRS.2017.2745048.
- [2] CHEN Zezong, HE Chao, ZHAO Chen, et al. Using SVD-FRFT filtering to suppress first-order sea clutter in HFSWR[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(7): 1076–1080. DOI: 10.1109/LGRS.2017.2697458.
- [3] LI Jian, CHEN Zezong, ZHAO Chen, et al. First-order sea clutter suppression for high-frequency surface wave radar using orthogonal projection in spatial-temporal domain[J]. IEEE Geoscience and Remote Sensing Letters, 2022(19): 1–5. DOI: 10.1109/LGRS.2021.3050144.
- [4] WANG W, WYATT L R. Radio frequency interference cancellation for sea-state remote sensing by high-frequency radar[J]. IET Radar, Sonar & Navigation, 2011(5): 405–415. DOI: 10.1049/iet-rsn.2010.0041.
- [5] ESLAMI NAZARI M, HUANG W M, ZHAO C. Radio frequency interference suppression for HF surface wave radar using CEMD and temporal windowing methods[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 212–216. DOI: 10.1109/LGRS.2019.2920092.
- [6] IER M. Ionospheric clutter mitigation using one-dimensional or two-dimensional wavelet processing[J]. IET Radar, Sonar & Navigation, 2009, 3(2): 112–121. DOI: 10.1049/iet-rsn_20070095.
- [7] LI Yajun, WEI Yinsheng, XU Rongqing, et al. An ionospheric Es layer clutter model and suppression in HF surfacewave radar[J]. International Journal of Antennas and Propagation, 2013(2): 320645. DOI: 10.1155/2013/320645.
- [8] MAO Xingpeng, HONG Hong, DENG Weibo, et al. Research on polarization cancellation of nonstationary ionosphere clutter in HF radar system[J]. International Journal of Antennas and Propagation, 2015(5): 631217. DOI: 10.1155/2015/631217.
- [9] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2017, 26(7): 3142–3155. DOI: 10.1109/TIP.2017.2662206.
- [10] ZHANG Shilong, YU Zhuoran, LIU Liyang, et al. Group R-CNN for weakly semi-supervised object detection with points[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA: IEEE, 2022: 9407–9416.
- [11] DING Yao, ZHANG Zhili, ZHAO Xiaofeng, et al. Multi-feature fusion: graph neural network and CNN combining for hyperspectral image classification[J]. Neurocomputing, 2022(501): 246–257. DOI: 10.1016/j.neucom.2022.06.031.
- [12] SENTHILKUMAR N, MANIMEGALAI M, KARPAKAM S, et al. Human action recognition based on spatial-temporal relational model and LSTM-CNN framework[J]. Materials Today: Proceedings, 2022(57): 2087–2091. DOI: 10.1016/j.matpr.2021.12.004.
- [13] TANG Yin, ZHANG Lei, MIN Fuhong, et al. Multiscale deep feature learning for human activity recognition using wearable sensors[J]. IEEE Transactions on Industrial Electronics, 2023, 70(2): 2106–2116. DOI: 10.1109/TIE.2022.3161812.

- [14] 牟效乾,陈小龙,苏宁远,等. 基于时频图深度学习的雷达动目标检测与分类[J]. 太赫兹科学与电子信息学报, 2019,17(1): 105–111. (MU Xiaoqian, CHEN Xiaolong, SU Ningyuan, et al. Radar detection and classification of moving target using deep convolutional neural networks on time–frequency graphs[J]. Journal of Terahertz Science and Electronic Information Technology, 2019,17(1):105–111.) DOI:10.11805/TKYDA201901.0105.
- [15] ZHANG L, YOU W, WU Q M J, et al. Deep learning–based automatic clutter/interference detection for HFSWR[J]. Remote Sensing, 2018,10(10):1517. DOI:10.3390/rs10101517.
- [16] LI Can, WANG Zengfu, ZHANG Zhishan, et al. Sea/land clutter recognition for over–the–horizon radar via deep CNN[C]// 2019 International Conference on Control, Automation and Information Sciences(ICCAIS). Chengdu, China: IEEE, 2019:1–5. DOI: 10.1109/ICCAIS46528.2019.9074545.
- [17] SHAO Guangqing, CHEN Yushi, WEI Yinsheng. Deep fusion for radar jamming signal classification based on CNN[J]. IEEE Access, 2020(8):117236–117244. DOI:10.1109/ACCESS.2020.3004188.
- [18] THONGNIRAN N, JITKAJORNWANICH K, LAWAWIROJWONG S, et al. Combining attentional CNN and GRU networks for ocean current prediction based on HF radar observations[C]// Association for Computing Machinery. New York: Association for Computing Machinery, 2020:440–446. DOI:10.1145/3373509.3373549.

作者简介:

王 璵(1999–), 女, 硕士, 主要研究方向为高频地波雷达信号处理. email:2017301200381@whu.edu.cn.

赵 晨(1985–), 男, 博士, 副教授, 博士生导师, 主要研究方向为无线电海洋探测.

陈泽宗(1966–), 男, 博士, 教授, 博士生导师, 主要研究方向为无线电海洋环境探测.

吴思滔(1994–), 男, 博士, 主要研究方向为船载相干微波雷达探海.