

# 基于注意力机制优化的生成对抗网络及其在 海杂波模拟中的应用

张苏恺, 陈 鹏\*, 董紫颖, 王 威

(长安大学信息工程学院, 陕西西安 710064)

**摘 要:** 针对在复杂海况下, 雷达海杂波模拟所面临的全局特征建模不足、多模态生成能力受限以及评估体系单一等挑战, 本文提出了一种基于多头自注意力机制增强的高保真生成对抗网络(Self-Attention High Fidelity Generative Adversarial Network, SA-HIFIGAN). 该模型在生成器与判别器中嵌入了多头自注意力模块, 以增强对海杂波长程时空相关性的建模能力, 并设计了具有分类功能的多尺度与多周期判别器结构. 同时, 本文构建了一个融合分布相似性、频谱误差和统计稳定性的混合评估体系, 实现了对生成杂波的多维质量控制. 通过采用X波段雷达实测数据集进行实验, 验证了模型在幅度概率密度、功率谱密度和时空相关性等指标上的有效性. 实验结果显示, SA-HIFIGAN在上述指标上与实测数据高度吻合, 不仅能根据海况等级生成对应特性的杂波数据, 还在综合评分上优于深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Network, DCGAN)和变分自编码器(Variational Auto-Encoder, VAE)等现有的杂波生成方法.

**关键词:** 多头注意力机制; 生成对抗网络; 海杂波模拟; 条件控制

**基金项目:** 国家自然科学基金(No.62341133); 长安大学青年学者学科交叉团队建设项目(No.3001042400922); 长安大学中央高校基本科研业务费专项资金(No.300102244203, No.300102243401)

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112(2025)09-3345-13

**电子学报 URL:** <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20250475

## Attention Mechanism Optimized Generative Adversarial Networks and Their Application in Sea Clutter Simulation

ZHANG Su-kai, CHEN Peng\*, DONG Zi-ying, WANG Wei

(School of Information Engineering, Chang'an University, Xi'an, Shaanxi 710064, China)

**Abstract:** To address the challenges in radar sea clutter simulation under complex sea conditions, including insufficient global feature modeling, limited multimodal generation capability, and a simplistic evaluation system, this paper proposes a generative adversarial network enhanced by multi-head self-attention mechanisms self-attention high-fidelity generative adversarial network (SA-HIFIGAN). The model incorporates multi-head self-attention modules in both the generator and discriminator to strengthen the modeling of long-range spatiotemporal correlations in sea clutter. Additionally, a multi-scale and multi-period discriminator structure with classification functionality is designed. Furthermore, this paper constructs a hybrid evaluation system integrating distribution similarity, spectral error, and statistical stability, achieving multi-dimensional quality control for generated clutter. Experiments conducted using X-band radar field-measured datasets validate the model's effectiveness in metrics such as amplitude probability density, power spectral density, and spatiotemporal correlation. The results demonstrate that SA-HIFIGAN achieves high consistency with measured data across these metrics. Not only can it generate clutter data with characteristics corresponding to sea state levels, but it also outperforms existing clutter generation methods like deep convolutional generative adversarial network (DCGAN) and variational auto-encoder (VAE) in comprehensive scoring.

**Key words:** multi-head attention mechanism; generative adversarial network; sea clutter simulation; conditional control

**Foundation Item(s):** National Natural Science Foundation of China (No.62341133); Interdisciplinary Team Build-

ing Program for Young Scholars, Chang'an University (No.3001042400922); Fundamental Research Funds for the Central Universities, Chang'an University (No.300102244203, No.300102243401)

## 1 引言

随着海洋强国战略的深入推进,海洋环境感知能力已成为维护国家海洋权益、保障海上安全的核心支撑.海上雷达作为海洋监测体系的关键传感器,其目标探测效能直接关系着海洋资源开发、航运监管和国防建设的战略需求.

海洋界面作为时变散射体,其风浪耦合产生的电磁散射场具有显著空时变异性<sup>[1]</sup>,导致回波信号多模叠加效应.实测表明海杂波功率动态范围超目标信号2~3个量级<sup>[2]</sup>,统计特性呈尖峰厚尾分布,使传统基于瑞利分布的检测方法在小型舰船识别中虚警率较高,波浪破碎形成的瞬态波峰会引发异常散射<sup>[3,4]</sup>,严重影响雷达目标检测能力.无论是建立杂波散射机理模型实现特征解耦<sup>[5]</sup>,或是利用深度学习构建端到端抑制框架<sup>[6]</sup>,都需要高置信度和建模精度的海杂波数据库和海杂波模拟技术.然而,受海洋环境动态性、多尺度耦合效应及实测数据采集成本高昂等因素制约,海杂波模拟方法在复杂场景下面临严峻挑战.

当前杂波模拟技术体系分为两类:基于参数化统计建模的传统方法(如瑞利分布、对数正态分布模型)和智能生成方法.传统方法虽能反映特定海况下的散射机理,但受限于空间敏感性导致的跨场景泛化能力不足,难以表征杂波的空时耦合特性,并且难以拟合现代雷达的非线性和非平稳性.近年来,以生成对抗网络(Generative Adversarial Network, GAN)为代表的海杂波智能生成方法,通过对抗训练隐式学习数据分布,能实现海杂波的隐式分布建模.然而,现有研究仍存在三大瓶颈:

(1)全局特征建模不足.传统卷积神经网络的局部感受野特性限制了其对海杂波长程时空相关性的捕捉能力.

(2)多模态生成受限.高性能的生成模型在生成多种特性的杂波方面受限.

(3)评估体系单一.现有工作多聚焦幅度分布相似性,缺乏对功率谱等关键指标的联合优化.这些问题导致生成数据与实测数据在雷达信号处理链路的端到端性能验证中出现显著偏差.

针对上述挑战,本文提出基于多头自注意力机制增强的生成对抗网络SA-HIFIGAN,主要工作包括:①在海杂波生成器和判别器中引入多头自注意力模块,通过动态特征权重分配机制增强模型对杂波全局时空特征的建模能力;②在传统HIFIGAN的基础上,在判别器中加入分类功能,旨在通过建立跨层特征关联

提升模型对海杂波全局特性的捕捉能力;③构建面向雷达工程应用的混合评估体系,创新性地将分布相似性(Distribution Similarity, DS)、频谱误差(Spectral Similarity, SS)、统计稳定性(STatistical Stability, STS)等指标加权融合,旨在克服传统单一指标评估的局限性.

## 2 相关工作

### 2.1 传统雷达杂波模拟技术

在杂波建模领域,传统方法主要分为基于物理机理和基于实测数据统计特性两大类.基于物理机理的研究侧重于杂波散射机理的建模,尤其在杂波研究中,研究者通常假设海面遵循特定数学模型,并在特定雷达参数与环境条件下,运用电磁散射理论计算海面后向散射回波.该研究方向实质上是运用各种电磁散射理论对环境表面的雷达截面积进行深入探讨.在海杂波散射模型方面,最具代表性的是一系列半经验模型<sup>[7]</sup>,这些模型通过参数化表征,实现了对特定场景散射机理的近似模拟.此外,研究者还开发了多种分析海面电磁散射特性的方法,涵盖基尔霍夫近似<sup>[8]</sup>、微扰法<sup>[9]</sup>等微分方程求解框架,以及融合多尺度特征的小斜率近似<sup>[10]</sup>和双尺度法<sup>[11]</sup>等混合算法.

另一方面,基于统计特性的杂波模拟方法主要关注杂波幅度概率分布模型的研究.这包括能够较好描述均匀的杂波分布特性的Rayleigh分布模型<sup>[12]</sup>,更适合描述平稳海面杂波幅度分布的Weibull分布模型<sup>[13]</sup>,适用于多种海况条件下海杂波幅度分布的K分布模型<sup>[14]</sup>以及在海况等级较高时拟合效果更佳的Pareto分布模型<sup>[15]</sup>等.针对上述杂波分布模型,通常采用零记忆非线性变换法和球不变随机过程法<sup>[16]</sup>进行杂波生成,但这些方法仅能生成符合特定幅度概率分布和功率谱分布的模拟杂波,无法对杂波的空间相关性和非平稳特性进行有效拟合.鉴于不同雷达的工作参数和应用场景各异,不存在一个普适的模型能全面描述所有场景下的杂波幅度分布特性.

综上所述,传统杂波模拟方法通常需要先对真实数据进行建模,再选择合适的模型进行杂波模拟.这一过程不可避免地引入误差,导致生成的模拟杂波与真实杂波存在差异.随着现代雷达分辨率的不断提升,杂波展现出更为复杂的时域特性、空域特性以及非平稳特征,现有模型和仿真方法在拟合这些特性方面面临挑战.

### 2.2 基于深度学习的雷达杂波模拟技术

近年来,深度学习技术在众多领域取得了显著的

成就,特别是在数据样本生成领域,深度生成对抗网络已展现出其在音频、波形等领域的巨大潜力.在波形领域,WaveNet<sup>[17]</sup>可以生成接近真实杂波的波形数据.在图像生成模型的基础上,Jesse Engel等人提出的GAN-Synth<sup>[18]</sup>模型在生成高质量音频数据的同时,速度相较于WaveNet提升了五万倍.在此基础上,基于并行计算的Parallel WaveGAN模型<sup>[19]</sup>进一步提升了波形生成的速度.在高保真度音频生成领域,KONG等人<sup>[20]</sup>提出的HIFIGAN在生成器中加入了多尺度特征融合(Multi-Receptive field Fusion, MRF)组件,并通过融合多尺度和多周期判别器,能够生成更为自然和清晰的音频数据.

目前,国内外学者已经尝试将生成对抗网络引入杂波智能生成领域.2021年,丁斌等人<sup>[21]</sup>使用GAN成功生成了海杂波的实部和虚部,且其生成数据在统计特性和自相关特性上与实际数据高度相似.施祖帅<sup>[22]</sup>则将Info-GAN和WaveGAN结合,利用WaveGAN生成不同海况下的杂波序列,获得了更为真实的模拟结果.2022年,马鑫<sup>[23]</sup>采用DCGAN生成海杂波矩阵,并提出连续条件下海杂波生成模型.2023年,Zhang等人<sup>[24]</sup>通过辅助分类器变分自编码器生成对抗网络(Auxiliary Classifier Variational Auto-Encoder Generative Adversarial Network, AC-VAEGAN)生成地面到海的杂波序列,生成的样品质量优于普通的GAN方法.2024年,Deng等人<sup>[25]</sup>通过VAE生成海杂波数据,结果表明使用VAE生成的杂波幅度概率密度函数比DCGAN更加接近真实值.然而,上述海杂波智能生成模型仍缺乏捕捉全局特征的能力,所采用的单一判别器结构难以在复杂海况下有效监督多尺度散射特征.

此外,国内外研究者对生成对抗网络生成数据的质量评价进行了广泛研究,常用的定量评估指标包括衡量生成图像的分类准确性和多样性的Inception分数<sup>[26]</sup>、评估生成数据与真实数据相似性的模式分数(Matching Score of similarity patterns, MSs)<sup>[27]</sup>、比较真实和生成数据集特征分布差异的Fréchet Inception距离(Fréchet Inception Distance, FID)<sup>[28]</sup>、衡量两个分布之间差异的最大均值差异(Maximum Mean Discrepancy, MMD)<sup>[29]</sup>等.大量实证研究表明,不同的评估指标可能会得出关于生成样本质量的不同结论.上述提及的GAN领域的指标主要从图像的视觉角度评估生成样本的质量,这对于海陆杂波样本的评估并不完全适用.因此,针对真实应用场景选择合适的评价指标显得尤为必要.

### 3 本文方法

#### 3.1 SA-HIFIGAN 框架

为生成更为精细且逼真的杂波数据,本研究基于

HIFIGAN架构构建了一种新型对抗网络,并引入注意力机制以实现性能提升.所提出的SA-HIFIGAN网络架构如图1所示,该网络由生成器、多周期判别器及多尺度判别器构成.由于杂波数据由实部+虚部构成,因此我们将实部与虚部拆分为双通道用于模型训练.杂波数据生成流程涉及将双通道一维杂波数据转换为杂波特征谱,并与条件向量 $c$ 进行拼接后送入生成器.生成器随后输出模拟的杂波数据,该数据与标注有 $y$ 的真实杂波数据一同被送入多周期判别器和多尺度判别器.这两个判别器从不同维度对杂波数据进行鉴别,并输出鉴别结果(真实或模拟,以及杂波类别).通过计算生成杂波与真实杂波之间的 $l_1$ 损失、判别器的真假鉴别损失、特征损失及类别损失,不断优化生成器与判别器,以期达到生成高质量杂波数据的目标.

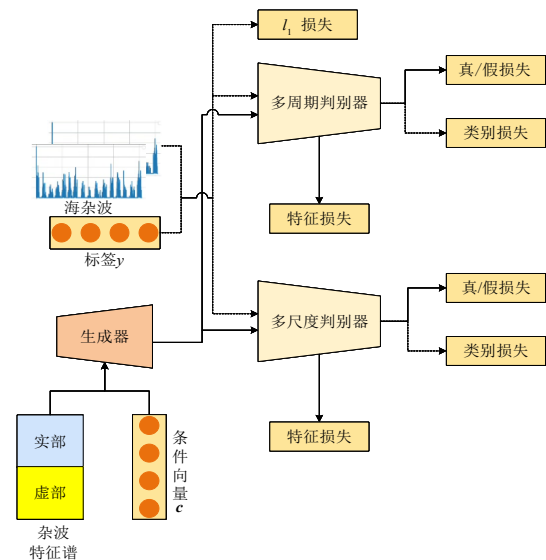


图1 SA-HIFIGAN网络结构图

HIFIGAN的核心优势在于其基于卷积神经网络(Convolutional Neural Network, CNN)的多感受野融合模块(Multi Receptive Field, MRF),它在捕捉杂波信号的局部相关性和周期性模式方面表现极其出色且高效.但是CNN的本质决定了其在建模长程依赖关系方面存在天然短板.杂波信号是需要从全局视角才能捕捉到的缓慢变化趋势或长时相关结构.因此我们提出改进方法是“CNN为主,Attention为辅”的混合架构,结合了CNN的效率、局部建模优势和Attention的全局视野,这种方法在增加生成模型精度的情况下也不会增加大量的模型训练成本.本文所改进的生成器如图2所示,该模型在原先模型的基础上在MRF模块后增加一个多头注意力机制模块<sup>[30]</sup>,以此捕捉杂波的全局特性.该多头注意力模块由8个自注意力模块构成,每个头的维度由输入通道数除以头数得出.

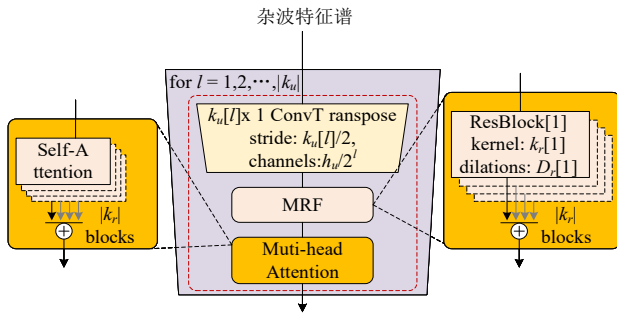


图2 SA-HIFIGAN生成器结构图

生成器的数据传递逻辑被分为条件输入、前期卷积、上采样与残差模块、注意力机制等部分。条件输入部分,输入的条件向量通过一个全连接层被投射为高维的条件向量。该向量被扩展至与杂波特征谱同样的时间步长 $T$ ,并在通道维度上与杂波特征谱进行拼接。前期卷积部分,将拼接后的张量通过一个 $7 \times 1$ 的初始卷积层,进行初步特征提取,并调整通道数。上采样与残差模块部分,数据流进入一个循环结构,单次的循环中,数据通过一个转置卷积层进行上采样,将时间维度 $T$ 扩大 $u$ 倍,同时将通道数减半。上采样后的特征被送入一个多感受野融合模块(MRF),该模块由多个并行的残差块组成,每个残差块内部包含空洞率分别为1、3、5的卷积层,从而能从不同尺度上捕捉局部特征。所有并行残差块的输出被相加并求平均,实现多感受野特征的融合。注意力机制衔接部分,在最后一次上采样和MRF模块处理之后,得到的特征张量被直接送入一个多头自注意力模块。模块内部将这个特征图分别线性投射为 $Q$ (Query)、 $K$ (Key)、 $V$ (Value)。随后,通过计算 $Q$ 和 $K$ 的点积来得到注意力权重,这些权重反映了序列中每个点 $t$ 对于所有其他点 $t'$ 的重要性。最后,用这些权重来加权聚合 $V$ ,从而为每个点生成一个新的特征表示。该模块负责捕捉特征在整个时间维度上的长程依赖关系,对全局信息进行建模。

多尺度判别器源自MelGAN<sup>[31]</sup>声码器的做法,通过连续的平均池化操作逐步减半噪声序列的长度,并在不同尺度上应用多层卷积操作,最终将特征展平,形成多尺度判别器的输出。

多周期判别器的核心在于识别周期性模式,它首先将接收到的一维输入杂波信号,对于一个周期为 $p$ 的子判别器,它首先将一维输入杂波 $x$ 重塑为一个二维图像式的张量,形状变为 $[B, C, T/p, p]$ 。它将信号中原本在时间维度上相距一个完整周期的采样点,对齐到了新二维表示的同一“列”上,使它们从远距离的依赖关系转变为空间上的直接邻居。信号中潜在的周期性模式被显性化为一种局部空间特征,判别器便可以利用强大的二维卷积核在这个 $[B, C, T/p, p]$ 张量上进行分

析,当卷积核在垂直方向上滑动时,它能直接捕捉到信号跨越多个周期的演变规律,为生成器提供了精准而强力的监督信号。

本研究提出的模型在两个判别器的卷积层后均嵌入了多头注意力机制,以增强对全局信息的捕捉能力。这两个判别器不仅负责区分生成数据的真伪,还加入了对生成数据的类别进行判断的功能。在原始的判别器中,经过卷积处理的特征数据在最后会经过一个全连接层得到真实性得分。为了实现分类的效果,我们将卷积处理的特征数据同时输入到另一个我们定义的全连接层中,该全连接层的输入特征向量的维度在本研究中是 $[B, 1024]$ ,输出的维度是 $[B, \text{num-class}]$ ,之后经过Softmax激活函数得到每个样本属于各个类别的预测分数。之后,通过计算分类损失不断的训练模型。其中数据类别标签的输入与输出均采用独热编码方式,输出编码中最大值索引位置代表生成数据的类别。图3和图4分别展示了改进后的多周期判别器和多尺度判别器结构。

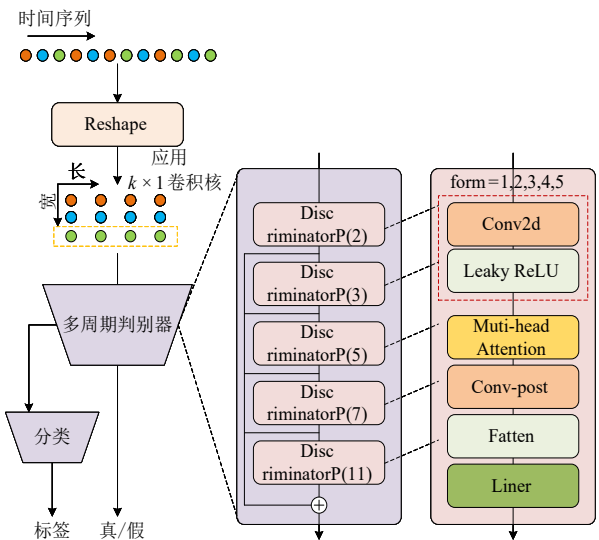


图3 多周期判别器结构图

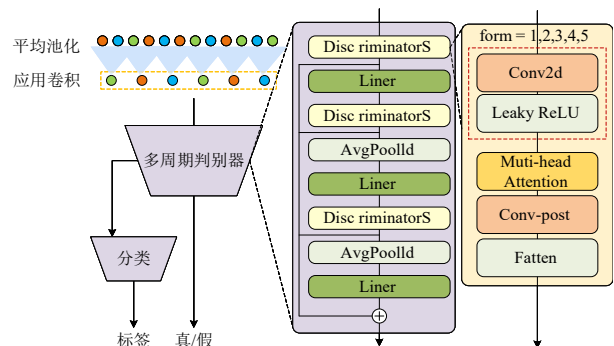


图4 多尺度判别器结构图

条件控制的作用是使得生成器可以在不同的条件下生成不同类型的杂波,解决了 HIFIGAN 模型缺乏多模态生成能力的缺点,使得模型具备了生成具有不同特性的杂波的能力. 离散标签  $c$  是一个长度为类别数的一维向量,在训练时每个标签  $c$  都对应着它所属的类别. 在训练好模型之后,我们可以通过指定标签  $c$  让模型生成不同类别的杂波. 以杂波的实部为例在生成器端,我们将代表杂波类别的离散标签  $c$  首先转换为独热编码,该独热编码向量随后通过一个全连接层被投射成高维的条件向量. 该向量会被扩展并与输入的杂波特征谱进行拼接,形成一个包含了明确类别信息的融合特征,具体拼接过程如图 5 所示. 这样,生成器就能根据给定的类别标签  $c$ ,定向地合成出对应类型的杂波. 在判别器端,除了传统的真伪判断功能,我们还增加了一个辅助分类器. 这个分类器的任务是预测输入杂波的所属类别. 因此,判别器不仅需要判断样本的真假,还需要判断其类别是否正确. 通过在损失函数中加入一个辅助分类损失,我们同时训练网络的对抗和分类能力. 这种设计使生成器产生不仅真实、而且类别特征明显的样本,从而实现了生成过程的精确控制.

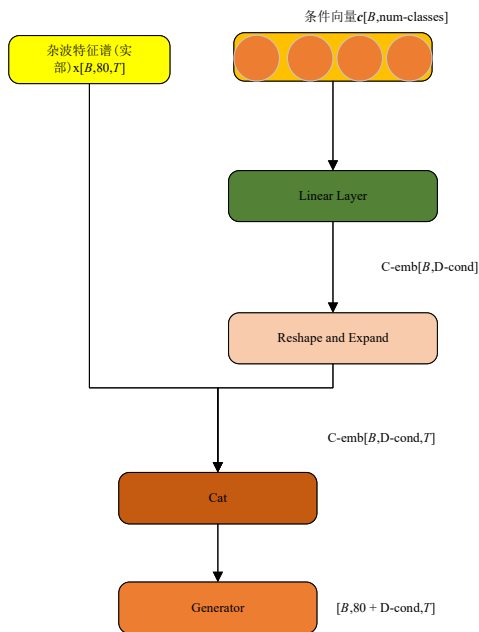


图5 条件嵌入过程

### 3.2 损失函数

原始的 HIFIGAN 损失函数包括三大部分,分别是对抗损失、梅尔谱损失和特征损失. 在做杂波生成时除了时域特性,频域特性也尤为重要,因此需要在损失函数中引入杂波的频域损失. 又因为模型添加了分类功能,因此需要引入生成器与判别器的分类损失. 改进后的 SA-HIFIGAN 的损失函数分为五大部分:第一部分是

生成器和判别器的对抗损失;第二部分是特征匹配损失;第三部分是生成器和判别器的分类损失;第四部分是杂波特征谱损失;第五部分是杂波的频域一致性损失.

首先,生成器与判别器的对抗损失可以表示为

$$L_{\text{adv}}(G) = E_s \left[ \left( D(G(s)) - 1 \right)^2 \right] \quad (1)$$

$$L_{\text{adv}}(D) = E_{(x,s)} \left[ \left( D(x) - 1 \right)^2 + \left( D(G(s)) \right)^2 \right] \quad (2)$$

其中,  $x$  表示真实杂波;  $s$  表示杂波特征谱;  $G(\cdot)$  表示生成器网络;  $D(\cdot)$  表示判别器网络.

杂波特征谱损失是生成波形的杂波特征谱与真实波形的特征谱之间的  $l_1$  距离,如式(3)所示:

$$L_c = E_{(x,s)} \left[ \left\| \phi(x) - \phi(G(s)) \right\|_1 \right] \quad (3)$$

其中,  $\phi(\cdot)$  表示将杂波转换为杂波特征谱的映射函数.

所提生成器和判别器的分类损失分别为

$$L_{\text{CLA}}(G) = E_s p(c|G(s|y)) + E_s \log D(G(s|y)) \quad (4)$$

$$L_{\text{CLA}}(D) = E_x p(c|x) + E_s \log(c|G(s|y)) \quad (5)$$

其中,  $p$  为目标的概率分布;  $y$  为生成条件;  $c$  为杂波所属的类别.

特征匹配损失是用来度量神经网络从真实和生成杂波中提取的特征差异,可定量计算为真实波形和生成波形每一层卷积输出之间的距离,即

$$L_{\text{FM}} = E_{(x,s)} \left[ \sum_{i=1}^T \frac{1}{N_i} \left\| D_i(x) - D_i(G(s)) \right\|_2 \right] \quad (6)$$

其中,  $T$  表示判别器中提取特征的层数;  $D_i$  表示提取的特征;  $N_i$  表示第  $i$  层判别器网络提取的特征数量.

频谱一致性损失函数可以衡量生成波形与真实波形在频域上的差异,即

$$L_{\text{SI}} = E_{(x,s)} \left[ \left\| A(x) - A(G(s)) \right\|_2 \right] \quad (7)$$

其中,  $A$  表示杂波的频谱幅度.

因此,所提 SA-HIFIGAN 的生成器与判别器的总损失函数如式(8)、式(9)所示:

$$L_G = \sum_{k=1}^K \left[ L_{\text{adv}}(G) + \lambda_1 L_{\text{FM}} + \lambda_2 L_{\text{CLA}}(G) \right] + \mu L_c(G) + \kappa L_{\text{SI}} \quad (8)$$

$$L_D = \sum_{k=1}^K \left[ L_{\text{adv}}(D_k) + L_{\text{CLA}}(D_k) \right] \quad (9)$$

## 4 实验及结果

### 4.1 数据集与实现细节

#### 4.1.1 数据集与预处理

本研究采用的杂波数据集,来源于海军航空大学海上目标探测课题组于 2019 年发起的科研项目——

“雷达对海探测数据共享计划”。该计划旨在通过 X 波段固态全相参雷达进行分阶段、多批次的三期海上探测实验,以期构建一个包含完整信息记录的海杂波测量数据库<sup>[32,33]</sup>。本项研究中所使用的 X 波段雷达数据集,特指其中的纯海杂波部分,其杂波总览图详见图 6。




图6 X波段雷达数据集原始杂波数据幅度总览图

本研究构建的数据集包含 7 000 个独立的脉冲序列,每个序列中杂波的周期性序列长度为 2 250,不同距离单元间的幅度特征存在显著差异。为验证所提出模型在杂波时域及空域特性上的生成效果,本研究将数据集划分为时域特性子集(杂波幅度随脉冲数变化)与空域特性子集(杂波幅度随采样点变化)。鉴于不同采样点处杂波幅度的显著差异,本研究对单个采样点的所有脉冲进行了幅度归一化处理。

为验证模型条件控制模块的有效性,本研究有必要构建包含多类别的数据集,而对训练数据集进行预分类则是实现该目标的关键步骤。在原始数据集中,3~4级海况数据在同一个数据文件中,近距离单元对应较低级别的海况数据,远距离单元则对应较高级别的海况数据。因此在处理3~4级海况数据时,按照距离单元进行分割用作海况数据集。本研究选取不同海况等级下 1 000 个距离单元的海杂波数据进行截取与对比分析,分析结果如图 7 所示,清晰地表明海况等级越高,相应的海杂波幅度越大。三个海况等级下的平均幅度概率密度和功率谱密度如图 8 所示,进一步揭示了海况等级与海杂波特征之间的关系。

首先对杂波时域序列  $z[n]$  进行短时傅里叶变换(STFT),得到频谱为

$$Z[k] = \sum_{n=0}^{N-1} z[n] \cdot w[n] \cdot e^{-j2\pi kn/N} \quad (10)$$

其中,  $z[n]$  是杂波信号的第  $n$  个样本;  $w[n]$  是窗口函数(如汉明窗);  $N$  是窗口长度;  $k$  是频率索引。对频谱  $Z[k]$  取模平方,得到功率谱  $Z[k] = |Z[k]|^2$ 。为了增强杂波信号的特征表达能力,对功率谱进行非线性变换:

$$F[k] = \log\left(|Z[k]|^2 + \varepsilon\right) \quad (11)$$






图7 三个海况等级下的幅度变化



(a) 不同海况下的海杂波功率谱密度分布



(b) 不同海况下的海杂波幅度概率密度分布

图8 三个海况等级下功率谱密度和幅度概率密度

其中,  $\varepsilon$  为较小的正值常数,能够避免在非线性变换中对零取对数。  $F[k]$  是本研究所采用的杂波特征谱。接着,对杂波特征谱归一化,即

$$F_{\text{norm}}[k] = \frac{F[k] - \min(F[k])}{\max(F[k]) - \min(F[k])} \quad (12)$$

最后,将归一化后的频谱  $F_{\text{norm}}[k]$  作为模型的输入。

#### 4.1.2 实现细节

本研究在 NVIDIA GeForce RTX 4070 Ti 图形处理单元(GPU)上,利用开源深度学习框架 PyTorch,对模型

进行了训练和性能评估。研究中,模型的训练过程是在三组特定的海杂波数据集上进行的。在模型训练的初始阶段,学习率被设定为  $2 \times 10^{-4}$ 。本研究采用 Adam 优化算法对损失函数进行优化,其中参数 beta 1 和 beta 2 分别设定为 0.8 和 0.99,同时设置了学习率衰减系数为 0.999。模型训练共进行了 2 000 次迭代,每次迭代的数据批次大小被设定为 16。在 STFT 与杂波特征谱中,FFT 窗口大小为 1 024,步长为 256。

## 4.2 实验结果

### 4.2.1 幅度概率密度与功率谱密度

图 9 与图 10 分别展示了本研究提出的杂波模拟技术所生成的杂波样本与实际杂波样本在幅度概率密度及功率谱密度方面的对比分析。分析结果显示,模拟杂波的幅度概率密度曲线与实际杂波的幅度概率密度曲线具有高度一致性,这验证了本研究所构建模型在捕捉杂波时域特性方面的有效性。进一步观察图示数据,模拟杂波的功率谱密度曲线与实际杂波的功率谱密度曲线亦表现出高度吻合,从而进一步证实了本研究所构建模型在准确捕捉杂波频域特征方面的能力。




图9 生成杂波与真实杂波幅度概率密度对比图





图10 生成杂波与真实杂波功率谱密度对比图

### 4.2.2 时间相关性与空间相关性


在高距离分辨率环境下,不同脉冲或距离单元间

的统计独立性不复存在。为提升模型拟合精度,必须全面考虑海杂波的相关性特征。本研究采用自相关函数对真实海杂波数据在时间和空间上的相关性进行描述。

图 11 展示了杂波数据在时间和空间维度的相关系数曲线。具体而言,图 11(a)反映了杂波随脉冲变化的相关系数曲线,图 11(b)则展示了杂波随采样点变化的相关系数曲线。其中,蓝色曲线代表实测杂波数据,红色曲线代表生成的杂波数据。通过对比分析可见,利用 SA-HIFIGAN 生成的杂波在时间和距离相关性上与实测杂波数据高度吻合。这充分表明,本研究所构建的模型能够有效拟合杂波的时空相关性。



(a) 杂波随脉冲变化的相关系数曲线



(b) 随采样点变化的相关系数曲线

图 11 生成杂波数据在时间和空间维度的相关系数曲线

### 4.2.3 分形特征

分形特性作为一种独特的非能量特征,具有在一定程度上抑制信杂比干扰的能力。鉴于海杂波是由海面产生的反向散射电磁波,其内在结构呈现出显著的粗糙性,因此,本文采用随机游走模型<sup>[34]</sup>来验证海杂波的分形特性,具体操作如下:


首先将一组海杂波时域信号去均值归一化,得到  $x = \{x_i, i = 1, 2, \dots, n\}$ ; 随后定义随机游走模型:

$$y(n) = \sum_{i=1}^n x_i \quad (13)$$


$$G(m) = \sqrt{(y(m+n) - y(n))^2} \quad (14)$$

其中,  $G(m)$  符合  $G(m) \sim m^H$  就可以认为该海杂波有分形特征, 其中  $H$  为 Hurst 指数. 具体的判定方式为观察在双对数坐标下  $G(m)$  与时域尺度  $m$  关系曲线在某一区间内是否呈现较好的线性关系, 线性部分曲线斜率即为 Hurst 指数值  $H$ .

在本研究中, 我们分别将生成海杂波与真实杂波的实部与虚部进行提取, 并绘制为  $\log_2 F(m) \sim \log_2(m)$  对数对比曲线. 如图 12 所示. 在 0~10 的区间内, 生成海杂波的实部和虚部  $\log_2 F(m) \sim \log_2(m)$  曲线均近似为一条直线, 说明生成海杂波的幅值序列在该尺度上具有分形特征, 且与真实海杂波的分形特征具有较高的相似性.



(a) 杂波实部的 Hurst 指数分形特征曲线



(b) 杂波虚部的 Hurst 指数分形特征曲线

图 12 真实杂波与生成杂波的 Hurst 指数分形特征对比

#### 4.2.4 生成样本质量的综合评估

为了更精确地评估 SA-HIFIGAN 生成海陆杂波样本的质量, 本研究使用了生成对抗网络领域的传统评估指标与信号处理领域的统计评估指标, 并将上述指标进行线性加权作为综合评估指标, 对 SA-HIFIGAN 生

成的杂波数据进行综合质量评估. 所采用的指标具体如下:

(1) 分布相似性使用核密度估计来估计真实杂波数据的概率密度分布, 利用估计得到的真实数据的概率密度模型, 计算生成数据在该模型下的对数似然值, 最后计算这些对数似然值的平均值作为 DS 指标, 具体为

$$DS = \frac{1}{N} \sum_{i=1}^N \lg p_{\text{real}}(x_i^{\text{gen}}) \quad (15)$$

其中,  $N$  是生成数据的样本数量,  $p_{\text{real}}(x_i^{\text{gen}})$  通过核密度估计得到的真实数据的概率密度模型生成在数据点  $x_i^{\text{gen}}$  处的值.

(2) 频谱相似性是对真实杂波数据和生成杂波数据进行快速傅里叶变换, 将时域信号转为频域信号. 通过计算真实数据和生成数据的幅度谱之间差异的平均值来衡量频谱幅度的整体差异程度, 具体为

$$SS = \frac{\frac{1}{N} \sum_{i=1}^N |A_{\text{real}}(x_i) - A_{\text{gen}}(x_i)|}{\frac{1}{N} \sum_{i=1}^N A_{\text{real}}(x_i)} \quad (16)$$

其中,  $A_{\text{real}}(x_i)$  是真实数据在  $x_i$  处的频率;  $A_{\text{gen}}(x_i)$  是生成数据在频率  $x_i$  处的频率.

(3) 统计稳定性是计算真实杂波数据和生成杂波数据的均值、方差和标准差并进行比较. 使用均值、方差和标准差的差异之和除以真实数据的均值、方差和标准差的绝对值之和, 再用 1 减去该比值得到统计稳定性指标 STS, 具体如式 (17) 所示:

$$STS = 1 - \frac{|\mu_{\text{real}} - \mu_{\text{gen}}| + |\sigma_{\text{real}}^2 - \sigma_{\text{gen}}^2| + |\sigma_{\text{real}} - \sigma_{\text{gen}}|}{|\mu_{\text{real}}| + \sigma_{\text{real}}^2 + \sigma_{\text{real}}} \quad (17)$$

其中,  $\mu_{\text{real}}$  代表真实样本的均值;  $\mu_{\text{gen}}$  代表生成样本的均值;  $\sigma_{\text{real}}$  代表真实样本的标准差;  $\sigma_{\text{gen}}$  代表生成样本的标准差.

由于 DS 和 STS 指标越接近 1 表示相似度越高, 而 SS 指标越接近 0 表示相似度越高. 对这三个指标进行加权相加得到最终的评价指标如式 (18) 所示:

$$\text{Score} = DS \times \omega_1 + (1 - SS) \times \omega_2 + STS \times \omega_3 \quad (18)$$

在式 (18) 中, 因为 Score 仅为线性加权和, 所以无论权重如何分配 (包括极端情况), 我们所提模型在 Score 中的排名始终稳定最优. 因此, 权重分配的具体数值不影响最终结论, 采用经验设置 DS 权重占比为 0.4, SS 和 STS 的权重占比都为 0.3.

为了验证本文方法与现有深度学习方法在杂波生成效果上的差异, 我们选取 WaveGAN、DCGAN 和 VAE 作为基准模型进行对比. 这些模型之前被研究人员成功应用于海杂波生成任务, 并在相似数据集上取得了

良好效果. 我们使用四种模型(包括本文方法)各生成 64 组杂波数据,并基于本文提出的量化指标与测试集中的真实杂波数据进行系统性对比分析,从而全面评估各方法的生成质量.

表 1 列出了本文方法与现有的基于深度学习的杂波模拟方法在两组数据集下的对比结果. 从表 1 中可以看出本文方法在 DS 和 SS 指标上取得了最佳效果. 在 STS 指标上略低于 DCGAN. 在总指标 Score 要优于其余三种方法.

### 4.3 条件控制杂波生成结果

为检验 SA-HIFIGAN 模型在动态训练过程中的效果及其对数据分布的拟合能力,本研究通过两组对比

实验进行了深入分析. 实验中,利用已训练完成的模型生成了 128 组杂波数据样本. 图 13 与图 14 分别展示了模型在不同训练周期下生成的杂波数据特征的演变情况:(a) Epoch = 100; (b) Epoch = 200; (c) Epoch = 500; (d) Epoch = 2 000. 图中,绿色曲线代表 2 级海况的杂波数据,红色曲线代表 3 级海况的杂波数据,而蓝色曲线则代表 4 级海况的杂波数据. 随着训练周期的增加,时域波形在多尺度参数的作用下逐渐展现出差异化的分离趋势,相应的幅度概率密度曲线形态差异性显著增强,这表明模型具备了渐进式的学习能力. 此外,在生成的 128 组杂波数据样本中,有 124 组数据的类别被准确识别,这说明该模型模块能够有效地控制不同类别的杂波生成.

表 1 不同方法在 X 波段雷达实测数据集的指标结果

方法	指标			
	DS(↑)	SS(↓)	STS(↑)	SCORE(↑)
WaveGAN <sup>[21]</sup>	0.716	0.344	0.789	0.799 ± 0.01
DCGAN <sup>[22]</sup>	0.735	0.337	0.799	0.813 ± 0.007
VAE <sup>[24]</sup>	0.725	0.341	0.785	0.802 ± 0.009
SA-HIFIGAN	0.745	0.314	0.796	0.822 ± 0.008

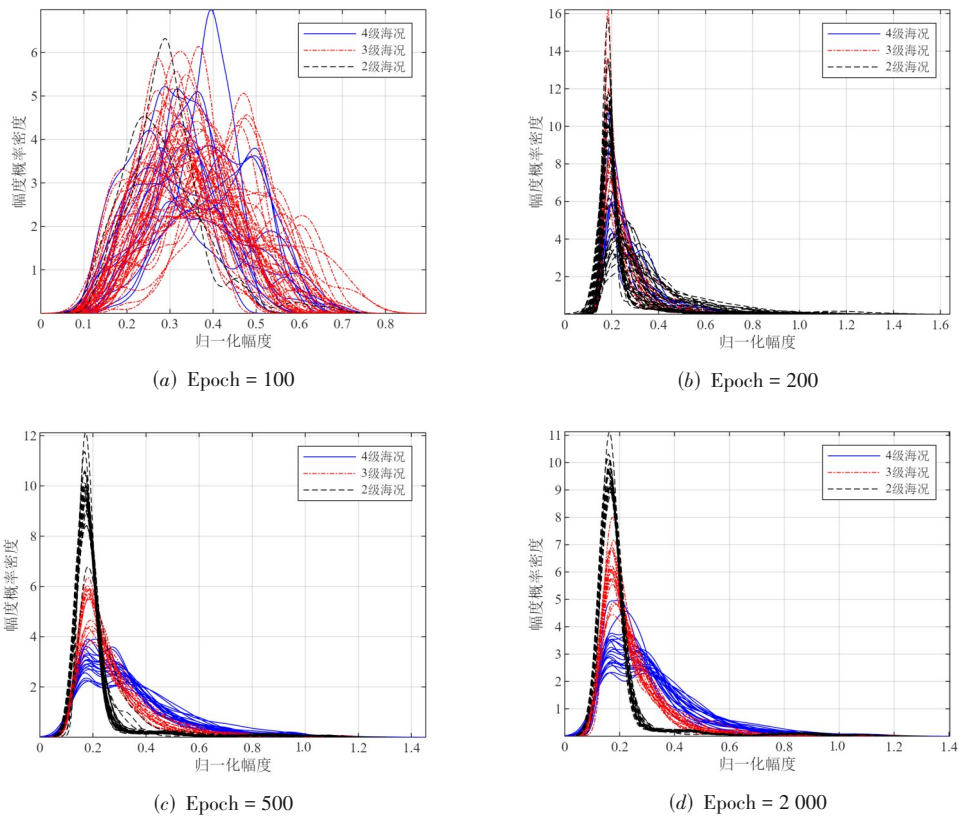


图 13 不同训练轮次时生成的各海况海杂波幅度概率密度对比




图 14 不同训练轮次各海况下功率谱密度对比

为探究SA-HIFIGAN在多类别混合数据集环境下对单一类别杂波生成性能的影响,本研究对八种不同类别分别进行了性能评估.表2展示了在单类别数据量为1 000、总数据量为3 000的条件下,通过训练过程获得的生成杂波数据性能指标.表3则记录了每次训练仅针对单一类别、单类别数据量为1 000时的生成数据性能指标.

表 2 混合数据集训练下各个类别数据指标结果

类别	DS(↑)	SS(↓)	STS(↑)	SCORE(↑)
海况等级 2	0.741	0.318	0.789	0.822 ± 0.008
海况等级 3	0.749	0.311	0.797	0.825 ± 0.008
海况等级 4	0.745	0.323	0.785	0.815 ± 0.008

表 3 单数据集训练下各个类别数据指标结果

类别	DS(↑)	SS(↓)	STS(↑)	SCORE(↑)
海况等级 2	0.745	0.314	0.796	0.822 ± 0.008
海况等级 3	0.751	0.312	0.791	0.823 ± 0.008
海况等级 4	0.740	0.329	0.787	0.812 ± 0.008

观察表中数据,混合数据集与单一类别数据集在三种海况类别上的加权得分表现出高度一致性,从而可以推断,采用混合数据集进行训练对模型输出结果

的影响是有限的.

#### 4.4 消融实验

为验证多头注意力机制和条件控制模块的有效性,本研究通过消融实验进行了深入分析.实验中,我们选取了包含不同注意力配置的模型进行对比,包括未集成多头注意力机制的基线模型HIFIGAN、仅在生成器中集成多头注意力机制的DG-HIFIGAN模型、仅在判别器中引入注意力机制的DD-HIFIGAN模型、移除了条件控制模块的DAC-HIFIGAN模型,以及本文提出的SA-HIFIGAN模型.所有模型均在同一数据集上进行训练,并对其性能进行了综合比较.

表4展示了不同模型在多头注意力机制消融实验中的结果.从DS和SS指标可以看出,本文提出的SA-HIFIGAN模型在生成杂波的幅度和频域方面均更接近真实数据,SA-HIFIGAN模型表现出更优的性能,相较于未集成多头注意力机制的基线模型HIFIGAN有显著改进.即使在移除条件控制模块后,DAC-HIFIGAN模型性能与SA-HIFIGAN模型差异较小,仍优于其他对比模型.因此可以得出结论,多头注意力机制模块能够显著提升海杂波生成模型的性能,而条件控制模块对生成杂波质量的负面影响有限.

表 4 注意力模块消融实验结果

模型	描述	DS(↑)	SS(↓)	STS(↑)	SCORE(↑)
HIFIAGN	原始基线模型	0.729	0.329	0.794	0.809 ± 0.007
DG-HIFIAGN	仅生成器添加注意力机制	0.735	0.325	0.789	0.812 ± 0.012
DD-HIFIAGN	仅判别器添加注意力机制	0.737	0.321	0.785	0.813 ± 0.013
SA-HIFIAGN	本文所提模型	0.745	0.314	0.796	0.822 ± 0.008
DAC-HIFIAGN	所提模型剔除分类模块	0.747	0.312	0.789	0.821 ± 0.009

## 5 结论

本文针对海杂波智能生成问题,提出了一种结合多头自注意力机制和混合评估体系的生成对抗网络 SA-HIFIAGN,旨在提升海杂波模拟的精度与泛化能力.实验结果表明,该模型在幅度概率密度、功率谱密度、时空相关性和分形特征等方面均能有效逼近实测海杂波数据,尤其在分布相似性和频谱一致性指标上优于现有主流方法.通过引入条件控制模块,模型能够根据不同海况等级生成相应的杂波样本,具备良好的分类生成能力.同时,混合评估体系提升了模型训练的多维监督能力,有助于生成数据在雷达信号处理链路中的实际应用.本文的消融实验进一步验证了多头注意力机制对模型性能的正向影响,而条件控制模块对整体生成质量的负面影响相对有限.综上,SA-HIFIAGN在海杂波生成的精度、稳定性与可控性方面取得了一定进展,为高分辨率雷达环境模拟提供了新的技术路径.未来研究将探索更精细的海况参数建模与模型轻量化设计,并探索生成数据在恒虚警检测器中的闭环验证.本研究为复杂海洋环境下的雷达信号处理提供了高保真杂波生成工具,对提升海上目标检测率具有工程应用价值.

## 参考文献

[1] SKOLNIK M I. Radar Handbook[M]. New York: McGraw-Hill, 1970.

[2] GU T C. Detection of small floating targets on the sea surface based on multi-features and principal component analysis[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(5): 809-813.

[3] CAO X W, CHENG Y Q, WU H, et al. Nonstationary moving target detection in spiky sea clutter via time-frequency manifold[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 3510505.

[4] ZHAO P, WU Z S, ZHANG Y S, et al. Analysis of the influencing factors on S-band sea spikes[J]. Electronics, 2022, 11(24): 4225.

[5] HUANG P H, ZOU Z H, XIA X G, et al. Multichannel sea clutter modeling for spaceborne early warning radar and clutter suppression performance analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(10): 8349-8366.

[6] ZHANG J P, ZHANG Y S, XU X Y, et al. Estimation of sea clutter inherent Doppler spectrum from shipborne S-band radar sea echo[J]. Chinese Physics B, 2020, 29(6): 068402.

[7] GREGERS-HANSEN V, MITAL R. An empirical sea clutter model for low grazing angles[C]//2009 IEEE Radar Conference. Piscataway: IEEE, 2009: 1-5.

[8] RODRIGUEZ E. Beyond the Kirchhoff approximation[J]. Radio Science, 1989, 24(5): 681-693.

[9] SOTO-CRESPO J M, NIETO-VESPERINAS M, FRIBERG A T. Scattering from slightly rough random surfaces: A detailed study on the validity of the small perturbation method[J]. Journal of the Optical Society of America A, 1990, 7(7): 1185-1201.

[10] VORONOVICH A. Small-slope approximation for electromagnetic wave scattering at a rough interface of two dielectric half-spaces[J]. Waves in Random Media, 1994, 4(3): 337-367.

[11] AWADA A, AYARI M Y, KHENCHAF A, et al. Bistatic scattering from an anisotropic sea surface: Numerical comparison between the first-order SSA and the TSM models[J]. Waves in Random and Complex Media, 2006, 16(3): 383-394.

[12] KERR D E. Propagation of Short Radio Waves[M]. New York: McGraw-Hill, 1951.

[13] LI G, YU K B. Modelling and simulation of coherent Weibull clutter[J]. IEE Proceedings F Radar and Signal Processing, 1989, 136(1): 2.

[14] JAKEMAN E, PUSEY P. A model for non-Rayleigh sea echo[J]. IEEE Transactions on Antennas and Propagation, 1976, 24(6): 806-814.

[15] ARNOLD B C. Pareto distribution[EB/OL]. (2015-09-16)[2025-05-25]. <https://doi.org/10.1002/9781118445112.stat01100.pub2>.

- [16] MARIER L J. Correlated K-distributed clutter generation for radar detection and track[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1995, 31(2): 568-580.
- [17] VAN DEN OORD A, DIELEMAN S, ZEN H, et al. Wavenet: A generative model for raw audio[EB/OL]. (2016-12)[2025-05-25]. [https://www.academia.edu/41680066/WAVENET\\_A\\_GENERATIVE\\_MODEL\\_FOR\\_RAW\\_AUDIO](https://www.academia.edu/41680066/WAVENET_A_GENERATIVE_MODEL_FOR_RAW_AUDIO).
- [18] DONAHUE C, MCAULEY J, PUCKETTE M. Adversarial audio synthesis[EB/OL]. (2019-02-09) [2025-09-02]. <https://arxiv.org/abs/1802.04208>.
- [19] YAMAMOTO R, SONG E, KIM J M. Parallel wavegan: A fast waveform generation model based on generative adversarial networks with multi-resolution spectrogram[C]// *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing*. Piscataway: IEEE, 2020: 6199-6203.
- [20] KONG J, KIM J, BAE J. HiFi-GAN: Generative adversarial networks for efficient and high fidelity speech synthesis[C]// *The 34th Conference on Neural Information Processing Systems*. New York: ACM, 2020:17022-17033.
- [21] 丁斌, 夏雪, 梁雪峰. 基于深度生成对抗网络的海杂波数据增强方法[J]. *电子与信息学报*, 2021, 43(7): 1985-1991.  
DING B, XIA X, LIANG X F. Sea clutter data augmentation method based on deep generative adversarial network[J]. *Journal of Electronics & Information Technology*, 2021, 43(7): 1985-1991. (in Chinese)
- [22] 施祖帅. 基于深度学习的雷达杂波模拟技术研究[D]. 成都: 电子科技大学, 2021.  
SHI Z S. Research on Radar Clutter Simulation Technology Based on Deep Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2021. (in Chinese)
- [23] 马鑫. 基于深度生成学习的雷达杂波模拟技术研究[D]. 成都: 电子科技大学, 2022.  
MA X. Radar Clutter Simulation Based on Deep Generative Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2022. (in Chinese)
- [24] ZHANG X X, WANG Z F, LU K, et al. Data augmentation and classification of sea land clutter for over-the-horizon radar using AC-VAEGAN[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5104416.
- [25] DENG X Y, HUI B W, HAN X, et al. A method for generating sea clutter data based on variational autoencoder[C]// *2024 9th International Conference on Signal and Image Processing*. Piscataway: IEEE, 2024: 54-61.
- [26] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs[C]// *Proceedings of the 30th International Conference on Neural Information Processing Systems*. New York: ACM, 2016: 2234-2242.
- [27] CHE T, LI Y R, JACOB A P, et al. Mode regularized generative adversarial networks[EB/OL]. (2017-03-02)[2025-09-01]. <https://arxiv.org/abs/1612.02136>.
- [28] HEUSEL M, RAMSAUER H, UNTERTHINER T, et al. GANs trained by a two time-scale update rule converge to a local Nash equilibrium[C]// *Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: ACM, 2017: 6629-6640.
- [29] DZIUGAITE G K, ROY D M, GHAMRANI Z. Training generative neural networks via maximum mean discrepancy optimization[C]// *Proceedings of the Thirty-First Conference on Uncertainty in Artificial Intelligence*. New York: ACM, 2015: 258-267.
- [30] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks[C]// *Proceedings of the 36th International Conference on Machine Learning*. Cambridge: PMLR, 2019: 7354-7363.
- [31] KUMAR K, KUMAR R, DE BOISSIERE T, et al. MelGAN: Generative adversarial networks for conditional waveform synthesis[C]// *33rd Conference on Neural Information Processing Systems*. New York: ACM, 2019: 32.
- [32] 刘宁波, 董云龙, 王国庆, 等. X波段雷达对海探测试验与数据获取[J]. *雷达学报*, 2019, 8(5): 656-667.  
LIU N B, DONG Y L, WANG G Q, et al. X-band radar sea detection test and data acquisition[J]. *Journal of Radars*, 2019, 8(5): 656-667. (in Chinese)
- [33] 丁昊, 刘宁波, 董云龙, 等. 雷达海杂波测量试验回顾与展望[J]. *雷达学报*, 2019, 8(3): 281-302.  
DING H, LIU N B, DONG Y L, et al. Overview and prospects of radar sea clutter measurement experiments[J]. *Journal of Radars*, 2019, 8(3): 281-302. (in Chinese)
- [34] XIA F, LIU J Y, NIE H S, et al. Random walks: A review of algorithms and applications[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2020, 4(2): 95-107.

## 作者简介




张苏恺 男,2001年8月出生于广东省深圳市.现为长安大学硕士研究生.主要研究方向为雷达杂波智能生成.

E-mail: 2023124114@chd.edu.cn



陈鹏 男,1992年4月出生于安徽省合肥市.博士,硕士生导师.现为长安大学信息工程学院副教授.主要研究方向为多模信道传播与定位技术.

E-mail: pchen@chd.edu.cn



董紫颖 女,2002年12月出生于湖北省武汉市.现为长安大学硕士研究生.主要研究方向为基于FMCW毫米波的无人机空对地雷达感知信道测量、分析与建模.

E-mail: 2024124026@chd.edu.cn



王威 男,1981年9月出生于湖北省荆门市.博士,博士生导师.现为长安大学信息工程学院教授.主要研究方向为无线电信道传播与建模、通信感知一体化技术.

E-mail: wei.wang@chd.edu.cn