

DOI:10.3969/j.issn.1672-2337.2025.05.001

基于VAE-WGAN的海杂波幅度-时频联合生成建模

刘宁波¹, 刘新亮², 董云龙¹, 丁昊¹, 关键¹, 孙殿星²

(1. 海军航空大学信息融合研究所, 山东烟台 264001; 2. 哈尔滨工程大学, 黑龙江哈尔滨 150001)

摘要: 针对传统统计模型在模拟海杂波时频特性中的局限性, 本文提出了一种基于改进生成对抗网络(Generative Adversarial Network, GAN)的海杂波数据生成方法。通过将复数海杂波分解为幅度和时频分量, 分别输入变分自编码器-沃瑟斯坦生成对抗网络(Variational Autoencoder-Wasserstein Generative Adversarial Network, VAE-WGAN)进行训练, 利用VAE的潜在空间编码和WGAN的稳定对抗训练融合生成复杂幅度分布与时变特性、并兼具幅度与相位特性的复数信号。为增强模型性能, 引入梯度惩罚机制约束鉴别器Lipschitz连续性, 有效缓解模式崩溃问题; 集成自注意力模块强化对海尖峰(Sea Spikes)等局部强散射特征的捕捉能力, 显著提升生成信号的时空相关性。实验设计覆盖2~5级海况, 每级海况分别构建[64, 64]、[128, 128]、[256, 256]三组数据集, 共完成12组交叉验证, 结果表明, 生成数据在幅度分布、归一化频谱、时间相关性及时频特性上与实测数据高度一致, 验证了模型对跨海况场景与变尺度时序数据的泛化能力。

关键词: 海杂波; 生成对抗网络; 时频特性; 数据增强

中图分类号: TN959.72

文献标志码: A

文章编号: 1672-2337(2025)05-0473-09

引用格式: 刘宁波, 刘新亮, 董云龙, 等. 基于VAE-WGAN的海杂波幅度-时频联合生成建模[J]. 雷达科学与技术, 2025, 23(5): 473-481.

LIU Ningbo, LIU Xinliang, DONG Yunlong, et al. Joint Magnitude-Time-Frequency Generative Modeling of Sea Clutter Using VAE-WGAN[J]. Radar Science and Technology, 2025, 23(5): 473-481.

Joint Magnitude-Time-Frequency Generative Modeling of Sea Clutter Using VAE-WGAN

LIU Ningbo¹, LIU Xinliang², DONG Yunlong¹, DING Hao¹, GUAN Jian¹, SUN Dianxing²

(1. Institute of Information Fusion, Naval Aviation University, Yantai 264001, China; 2. Harbin Engineering University, Harbin 150001, China)

Abstract: To address the limitations of traditional statistical models in simulating the time-frequency characteristics of sea clutter, a sea clutter data generation method based on an enhanced generative adversarial network (GAN) is proposed in this paper. The complex sea clutter is decomposed into amplitude and time-frequency components, which are separately fed into a variational autoencoder-Wasserstein generative adversarial network (VAE-WGAN) for training. The outputs are then integrated to synthesize complex signals with both amplitude and phase characteristics. To enhance the model performance, a gradient penalty mechanism is introduced to constrain the Lipschitz continuity of the discriminator, effectively mitigating the mode collapse. A self-attention module is incorporated to strengthen the model's ability to capture localized strong scattering features, such as sea spikes, significantly improving the spatiotemporal correlation of generated signals. Experiments cover sea states 2~5, with three datasets of dimensions [64, 64], [128, 128], and [256, 256] constructed for each sea state. Twelve cross-validation trials demonstrate that the synthetic data exhibit high consistency with measured data in amplitude distribution, normalized spectrum, temporal correlation, and time-frequency characteristics. These results validate the model's generalization capability across varying sea states and multi-scale temporal scenarios.

Key words: sea clutter; generative adversarial network; time-frequency characteristics; data enhancement

0 引言

海杂波作为雷达电磁波与动态海面相互作用

产生的后向散射回波^[1], 是影响海上目标检测的核心干扰源。其物理特性受海面风速、波浪形态、雷达极化方式等多因素耦合影响, 呈现出显著的非

收稿日期: 2025-05-13; 修回日期: 2025-07-21

基金项目: 国家自然科学基金(No.62388102, 62101583); 泰山学者工程(No.tsqn2002211246)

平稳、非均匀和非高斯特征。在高分辨率雷达体制下,海杂波中频繁出现的海尖峰现象,表现为持续时间短、功率高的孤立脉冲,极易导致虚警率升高,严重制约慢速小目标的检测性能。研究表明,海尖峰的时频特性(如多普勒谱展宽、幅度分布非对称性)与目标信号存在高度重叠,传统恒虚警率(Constant False Alarm Rate, CFAR)检测方法在复杂海况下的适用性显著降低^[2]。因此,构建精确的海杂波时频特性模型,对优化雷达信号处理算法、提升目标检测概率具有关键意义。

长期以来,零记忆非线性变换(Zero Memory Nonlinearity, ZMNL)和球不变随机过程(Spherically Invariant Random Process, SIRP)是海杂波仿真的主流方法^[3]。ZMNL通过非线性映射生成特定分布的随机序列,但其功率谱受变换过程干扰,难以准确复现实测数据的频谱特性^[4]。SIRP虽能独立控制幅度分布与功率谱,但其参数估计依赖经验模型,协方差矩阵估计误差易导致生成信号的时空相关性失真。例如,在K分布杂波仿真中,SIRP需预设纹理分量的统计参数,而实际海面动态变化使参数先验信息获取困难,导致模型泛化能力受限。此外,传统方法对复数信号的相位特性建模能力不足,难以满足现代雷达全极化信号处理的需求。这些缺陷在高分辨率、低掠射角场景下尤为突出,需要新型数据驱动方法突破统计模型的固有限制。

生成对抗网络(GAN)通过生成器与鉴别器的对抗训练,可自动学习复杂数据分布,为海杂波建模提供了新思路。早期研究如Vanilla GAN在Wi-Fi信号生成中已验证其分布拟合能力,但存在模式崩溃和训练不稳定的固有问题^[5]。为了缓解模式崩溃,文献^[6]通过引入VAE编码器KL散度最小化学习海杂波的潜在分布,解码器结合重参数化技巧重构信号,确保生成过程的可微性和分布连续性,VAE利用其显式概率建模能力有效缓解了模式崩溃现象。Wasserstein GAN(WGAN)通过引入Wasserstein距离替代Jensen-Shannon散度,显著提升了生成样本的多样性和训练稳定性。文献^[7]进一步改进的WGAN-GP模型采用梯度惩罚(Gradient Penalty)机制,约束鉴别器的Lipschitz连续性,解决了权重剪裁导致的梯度消失问题,对GAN

训练不稳定的问题提供了有效帮助。生成对抗网络及其衍生模型虽然在合成数据生成方面展现出卓越性能^[8],然而现有的GAN框架多聚焦于实数信号生成(如图像、音频波形),而对复数信号(如雷达信号、SAR图像、通信信号)的联合幅度-相位建模研究不足,特别是针对海杂波的建模任务仍存在显著局限性^[9-12]。海杂波数据因其非平稳时空耦合特性及高维非线性统计分布,导致传统GAN框架在训练过程中频繁出现梯度弥散与模式坍塌现象^[13]。特别地,海杂波数据生成需满足多尺度特征保真约束,要求生成模型不仅能维持训练稳定性,还需精确捕获相位相干性与多普勒谱相关性^[14]。

基于以上分析,本文针对传统GAN存在的梯度消失与振荡问题,提出VAE-WGAN网络,通过潜在空间结构化约束与Wasserstein距离优化实现稳定训练;针对相位失真问题,进一步提出幅度-相位联合建模的双通道VAE-WGAN框架,通过复数信号解耦与短时傅里叶变换将复信号分解为幅度与时频分量,并引入自注意力机制使幅度通道约束长拖尾分布匹配度,相位通道减少高频成分的生成偏差。

1 幅度-相位联合建模及网络框架构建原理

本节主要介绍了海杂波基于双通道VAE-WGAN网络的幅度-时频联合建模方法。在网络中引入VAE和WGAN-GP两种网络,通过两个网络之间的联合生成来实现对海杂波特性的仿真。特别地,在网络构建中,考虑到海杂波为复数数据且非平稳特性难以仿真,本文构造了幅度-相位联合建模的双通道VAE-WGAN框架,分别实现对海杂波平稳特性和非平稳特性的有效仿真。

1.1 幅度-相位联合建模

整体网络生成杂波数据流程如图1所示。本研究采用两个独立的VAE-WGAN网络分别处理时频数据和幅度数据。每个网络都通过其自身的训练过程学习数据的特征和分布,最终形成两个参数和权重不同的网络。具体步骤如下:

1) 时频数据生成:一维实测海杂波通过短时傅里叶变换(Short-Time Fourier Transform, STFT)得到二维时频数据并对每一个元素取模后输入VAE-WGAN网络,使网络可以直接学习仿真海杂波时频特性,生成的仿真时频数据随后通过逆短时傅里叶变换(Inverse Short-Time Fourier Transform, ISTFT)处理,得到一维的仿真相位数据。虽然取模操作会丢失时频数据的相位信息,逆变换后可能会导致波形偏移或震荡失真,但是本文仅分析时频域能量分布,可以忽略该问题。

2) 幅度数据生成:实测数据取模值得到幅度数据,输入VAE-WGAN网络,学习海杂波序列的平稳特性,生成仿真幅度数据。

3) 数据融合:将ISTFT处理后的仿真相位数据的相位提取出来,与仿真幅度数据的幅度相结

合, $x' = |x|e^{j\theta}$,在不丢失幅度信息和时频特性的情况下生成最终的仿真复数数据。

通过这种分离训练和数据融合的方法,本研究的模型能够充分利用时频数据和幅度数据的特征,生成更接近真实海杂波数据的仿真结果。




图1 整体网络生成杂波数据流程

1.2 双通道VAE-WGAN网络模型框架

本节描述了VAE-WGAN网络框架的组成部分,并对网络中的各个组成部分的作用及原理进行了解释和分析。整体网络框架如图2所示,共包含3个网络部件,即编码器、生成器和鉴别器。

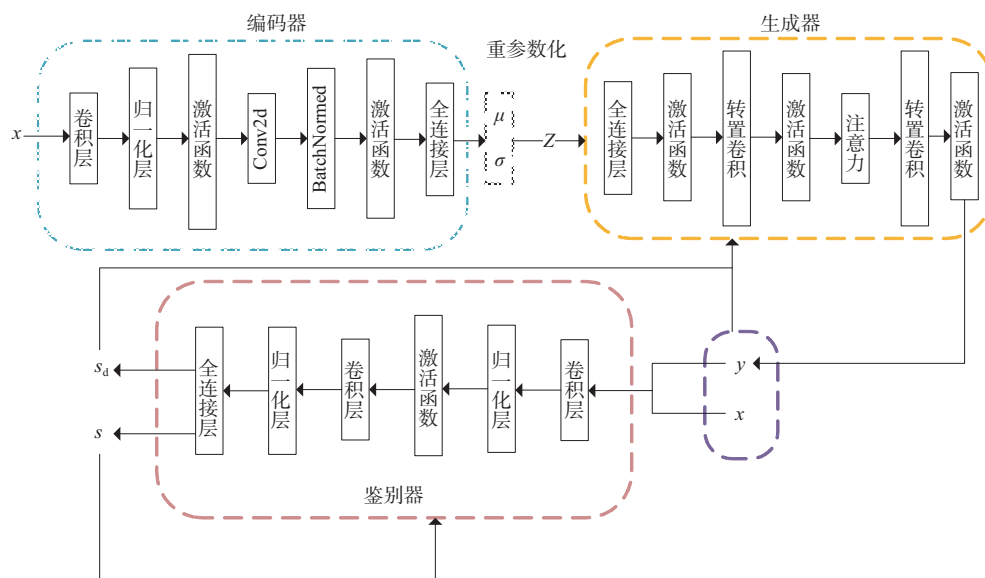


图2 VAE-WGAN的网络架构图

WGAN的生成器同时也是VAE的解码器。编码器中使用批归一化(Batch Normalization, BN)层,通过标准化输入减少内部协变量偏移,减少输入活动的方差,有助于稳定学习过程,减少对权重初始化的依赖。但是由于鉴别器模块要对每个样本独立地施加梯度惩罚,所以在鉴别器的模型架构中不能使用BN算法,而是选择利用权重归一化(Weight Normalization, WN)来代替BN层。它通过改变权重向量的长度和方向来改善优化问题的条件,从而加快随机梯度下降的收敛速度,不

依赖于批次大小,不会向梯度中引入噪声,并且计算量更小。

文章模型3个核心部件分别是:

1) 变分自编码器(VAE)

作为概率生成模型的代表性方法,VAE通过潜在空间参数化重构实现对数据深层统计规律的编码^[15]。在本文模型中,VAE利用KL散度驱动的变分推断策略,将输入信号映射至各向异性高斯分布的潜在空间,并通过可微采样生成统计特性可验证的合成数据。模型中编码器负责将输入数

据 x 映射到潜在空间的一个概率分布(本文选取的是正态分布),正态分布参数 μ 和 σ 均由编码器生成。随后通过重参数化技巧获得隐变量 z 。重参数化公式如式(1)所示,式中 ϵ 为服从标准正态分布的噪声。重参数化技巧将随机变量的采样过程转化为可微的函数,从而减少了梯度估计的方差,使得模型更稳定。

$$z = \mu + \sigma \odot \epsilon, \epsilon \sim N(0, 1) \tag{1}$$

2) 带有梯度惩罚的瓦瑟斯坦生成对抗网络(WGAN-GP)

WGAN-GP是GAN的重要改进版本,通过引入梯度惩罚项,解决了传统GAN在训练过程中的模式坍塌和训练不稳定问题^[16]。在海杂波生成任务中,WGAN-GP通过约束生成器和鉴别器之间的梯度,确保鉴别器满足Lipschitz条件,从而实现更稳定的训练过程和更好的收敛性。这一改进使得生成器能够生成更加多样化且高质量的海杂波数据,避免了数据生成的单一性和发散性。

3) 自注意力机制

海杂波数据具有复杂的空间和时间相关性,

传统的卷积神经网络难以有效捕捉这些复杂特征关系。通过引入稀疏注意力模式或低秩逼近等优化技术,自注意力机制在处理大规模海杂波数据时的计算效率得到了显著提升,使其能够高效地应用于实际任务中^[17]。此外,本研究引入自注意力机制,能够动态地关注数据中不同位置和特征之间的关系,从而生成更为真实和高质量的海杂波数据。

本文以[256,256]大小的数据集为例展示模型参数设计,如图3所示,输入数据 x 从编码器输入逐层减小,最终通过全连接层转化为两个长度为64的一维向量,并重构为变量 z ,输入生成器后通过转置卷积逐层增大恢复为[256,256]大小的生成数据,并与实测数据一起输入鉴别器进行判断。这里需要设置合适的损失函数来让生成器和鉴别器相互对抗来提高模型的学习能力。本文模型的单元化设计可以通过增加或减少单元数量来改变输入与输出数据的数据大小,有利于验证模型对不同尺寸大小数据的适应能力。

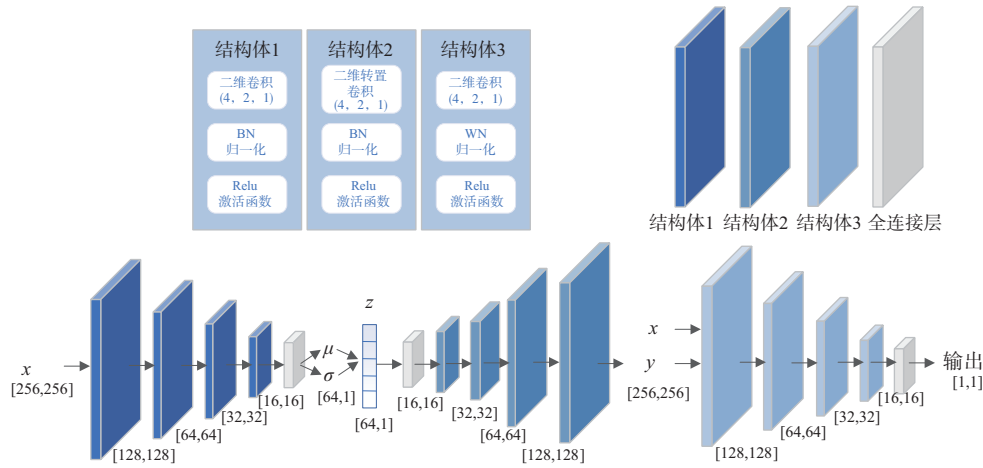


图3 模型参数设计与数据尺寸变化过程

1.3 损失函数

VAE-WGAN的损失函数设计需要综合VAE和WGAN的核心思想,结合两者的数学目标与正则化机制。

1) 鉴别器损失函数

由于鉴别器在训练阶段只涉及自身,因此可以直接将 x 和 y 作为输入样本进行训练。WGAN通

过使用 Wasserstein 距离来强化模型的训练,使得生成的样本更稳定。这种距离被表述为鉴别器输出的期望值差异:

$$W(p_{\text{real}}, p_{\text{fake}}) = E_{x \sim p_{\text{real}}}[D(x)] - E_{z \sim p(z)}[D(x)] + 10 \times \text{gradient_penalty} \tag{2}$$

公式(2)中 $W(p_{\text{real}}, p_{\text{fake}})$ 衡量的是真实数据分布和生成数据分布之间的某种差异度量, $E_{x \sim p_{\text{real}}}[D(x)]$

为鉴别器D对从真实数据分布中采样得到的数据的输出的期望, $E_{z \sim p_r(z)}[D(x)]$ 为鉴别器D对从生成数据分布(由潜在变量分布生成的数据)中采样得到的数据的输出的期望,也就是把生成器生成的样本 x 输入到鉴别器D中,再对这些输出结果求平均。

其中, $gradient_penalty$ 为梯度惩罚项,如公式(3)所示, $\nabla_{\hat{x}} D(\hat{x})$ 表示鉴别器D关于插值样本 \hat{x} 的梯度, $\|\nabla_{\hat{x}} D(\hat{x})\|_2$ 是该梯度的 L_2 范数, $E_{\hat{x}}$ 表示对所有插值样本 \hat{x} 求期望。

$$gradient_penalty = E_{\hat{x}} \left[\left(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1 \right)^2 \right] \quad (3)$$

鉴别器的损失函数为

$$L_D = -W(p_{real}, p_{fake}) = - \left(E_{x \sim p_{real}}[D(x)] - E_{z \sim p_r(z)}[D(x)] + 10 \times gradient_penalty \right) \quad (4)$$

2) 变分自编码器损失函数

VAE的损失函数包括重构损失和KL散度部分,如公式(5)所示,重构损失 L_{recon} 采用BCE(Binary Cross-Entropy)损失函数, KL散度可由公式(6)计算得到,式中 β 为根据训练轮数调整的系数, M 为潜在变量的维度, $logvar_l$ 为第 l 个潜在变量的对数方差, μ_l 为第 l 个潜在变量的均值。

$$L_{VAE} = L_{recon} + L_{KL} \quad (5)$$

$$L_{KL} = -0.5 \times \beta \times \sum_{l=1}^M \left(1 + logvar_l - \mu_l^2 - \exp(logvar_l) \right) \quad (6)$$

本文使用逐步增加 β 的方法,也称为 β -VAE。该方法开始时使用较低的 β 值,随着训练的进行逐渐增大,最终达到目标值。这种策略可帮助模型在初期更好地拟合训练数据,而在后期又能增强潜在空间的规范性。

3) 生成器损失函数

生成器的损失需结合 Wasserstein 距离和 VAE 的部分,在这里,生成器的目标是 minimized 重构损失、KL散度,同时最大化 Wasserstein 距离,计算公式如式(7)所示:

$$L_G = L_{recon} + L_{KL} - \gamma W(p_{real}, p_{fake}) \quad (7)$$

VAE的重构损失要求生成数据精确拟合输入,而WGAN鼓励生成数据分布覆盖真实分布,可

能导致生成样本多样性优先于局部精确性。训练时通过动态调整权重(如调整KL散度损失权重 β 与 Wasserstein 损失权重 γ)平衡两者。

2 仿真分析

本节利用仿真分析验证该模型对海杂波统计特性的模拟能力以及对不同海况、不同长度序列的泛化能力,实验设计12组数据集:覆盖2~5级海况,64/128/256三组步长,共完成12组跨参数域交叉验证,并在幅度分布、频谱、时间相关性及时频特性等方面进行结果分析。

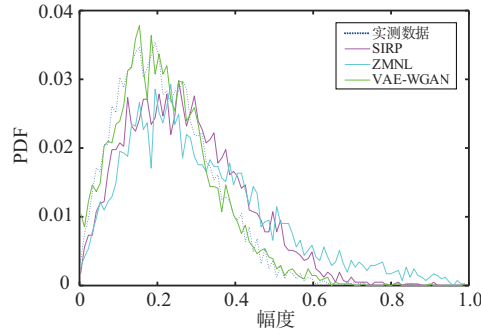
实验依托 Python3.10.14、PyTorch2.4.0、CUDA12.1 环境,运行于 Windows11 64 位系统,硬件配置为 AMD Ryzen9 处理器、16 GB 内存以及 NVIDIA4060 GPU。训练 2 000 个 epoch, batch 大小设为 64。VAE 部分采用 Adam 优化器,学习率 0.000 2; WGAN 鉴别器则使用无动量的 RMSprop 优化器,学习率 0.000 1。

实验数据源自“雷达学报网站”2022年第1期“雷达对海探测数据共享计划”,属于X波段不同海况下的雷达试验数据^[18]。下边以4级海况[64, 64]大小数据为实测数据进行分析,构建数据集时,选取1~400距离单元,使数据只包含海杂波数据不含目标,脉冲总长度为131 072,以4 096个脉冲为一组、2 048个脉冲为采样间隔,共25 600组数据,其中20 480组用作训练集,5 120组数据作为测试集,其中每一组数据都包含幅度数据和时频数据。本文主要从以下几个维度评估生成数据质量:

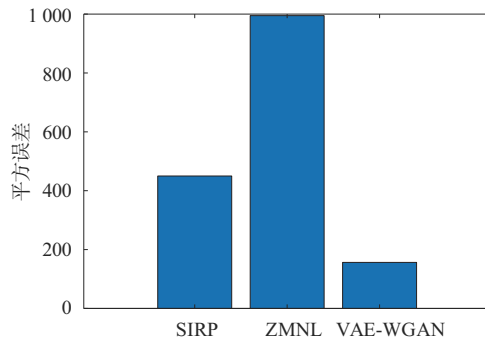
1) 幅度分布特性验证:对比实测与本文模型生成海杂波数据的幅度分布一致性。分别计算出实测数据、本文模型仿真数据、基于K分布的传统仿真方法ZMNL和SIRP仿真数据基于累积分布函数的微分计算概率密度函数(Probability Density Function, PDF),设定脉冲数为4 096,脉冲区间数为100,两种传统方法的参数都是通过实测数据计算得来。图4结果表明,VAE-WGAN生成数据的幅度概率分布与实测数据拟合程度优于两种传统方法,尤其在分布尾部的拟合效果。本文通过卡方误差量化仿真误差,其计算公式为

$$\chi^2 = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i} \quad (8)$$

式中, O_i 为第 i 个观测值(实际值), E_i 为第 i 个期望值(理论值或模型预测值), n 为数据点的总数。VAE-WGAN 的卡方误差更低, 证实其能够真实模拟海杂波的幅度分布。



(a) 概率密度曲线



(b) 基于卡方误差的幅度分析拟合优度对比

图 4 幅度分布特性验证结果

2) 频谱特性验证: 运用归一化功率谱估计方法分析频谱特性的一致性。利用 1 024 点快速傅里叶变换 (Fast Fourier Transform, FFT) 估计功率谱, 采用 512 点汉明窗和 256 点重叠数。生成数据与实测数据的归一化功率谱密度曲线结果如图 5 所示, 拟合度较高。通过计算余弦相似度量仿真误差, 具体计算公式为

$$\text{Cosine Similarity} = \frac{\sum_{i=1}^n (X_i - Y_i)}{\sqrt{\sum_{i=1}^n X_i^2} \times \sqrt{\sum_{i=1}^n Y_i^2}} \quad (9)$$

计算结果为 0.85, 表明 VAE-WGAN 生成模型在频谱特性上与实测数据具有较高的一致性。

3) 时间相关性验证: 对比实测与生成数据的

时间自相关函数曲线, 如图 6 所示, 二者几乎完全重合。通过计算余弦相似度量仿真误差, 结果为 0.81, 这表明生成的海杂波数据在模拟时间相关性方面效果良好。

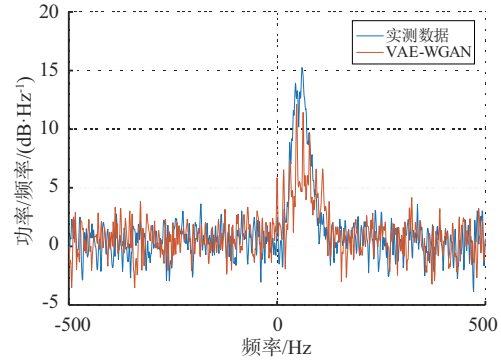


图 5 归一化功率谱曲线对比

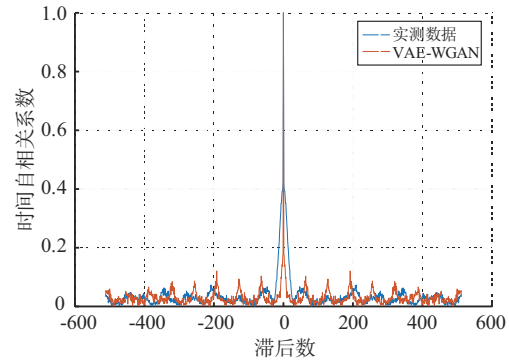




图 6 归一化时间自相关系数对比


4) 泛化能力验证: 为验证模型跨海况泛化能力, 补充 2 级到 5 级海况的统计特性分析, 如图 7 所示, 包括 2 级到 5 级海况下的幅度分布、归一化功率谱及时间自相关函数对比结果。跨海况验证充分证明, 模型在 2 级至 5 级海况范围内展现出卓越的泛化能力。



(a) 幅度概率密度对比曲线




(b) 归一化功率谱对比曲线




(c) 时间自相关函数对比曲线

图7 2级到5级海况统计特性对比曲线

5) 时频特性验证: 鉴于海杂波的非平稳特性, 需利用 STFT 对数据进行时频分析。分析实测与生成海杂波数据的时频特性, 如图8所示, 生成数据在零频附近与实测数据能量分布相似, 但是其他频率分量存在一些噪声干扰。本文通过时频谱质心和带宽^[19]对仿真效果进行验证。



(a) 实测数据



(b) 生成数据

图8 64×64数据时频图

对每个样本时频图第30个时刻的质心与带宽进行统计分析, 计算每个时刻的频谱质心与均方根带宽如公式(10)~(11)所示:

$$Q = \sum_{f_s/2}^{f_s/2-1} \hat{S}(f_i) \quad (10)$$

$$\hat{f}_c = \frac{1}{Q} \sum_{-f_s/2}^{f_s/2-1} f_i \hat{S}(f_i) \quad (11)$$

$$\hat{B}_w = \sqrt{\frac{1}{Q} \sum_{-f_s/2}^{f_s/2-1} (f_i - \hat{f}_c)^2 \hat{S}(f_i)} \quad (12)$$

式中: Q 为该信号多普勒谱的功率水平; f_s 为脉冲重复频率, 该期数据的脉冲重复频率为 2 000 Hz; $S(f_i)$ 为第 i 个频点处的功率谱密度; f_c 为质心; B_w 为带宽。

本文将质心和带宽的经验 PDF 曲线与其高斯分布拟合曲线进行对比, 如图9所示, 发现其 PDF 曲线与高斯分布拟合效果良好, 说明各时刻的频谱质心与均方根带宽符合高斯分布。这种分布特性源于海杂波的物理本质: 时频谱的质心偏移和带宽展宽由海面大量独立散射体的多普勒频移叠加形成。根据中心极限定理, 当独立随机因素数量足够多时, 其统计特性必然趋近高斯分布。本文通过计算均方根误差定量验证该假设, 从图10可以看到, 高斯分布显著优于瑞利分布、对数正态分布和韦布尔分布。选择高斯分布建模不仅符合物理规律, 其对称性和可导性更为 Z 分数置信区间评估提供数学基础。

本文以统计学 Z 分数为衡量, Z 分数也叫标准分数 (Standard Score), 它是以标准差为尺子去度量某一原始分数偏离平均数的距离, 这段距离含

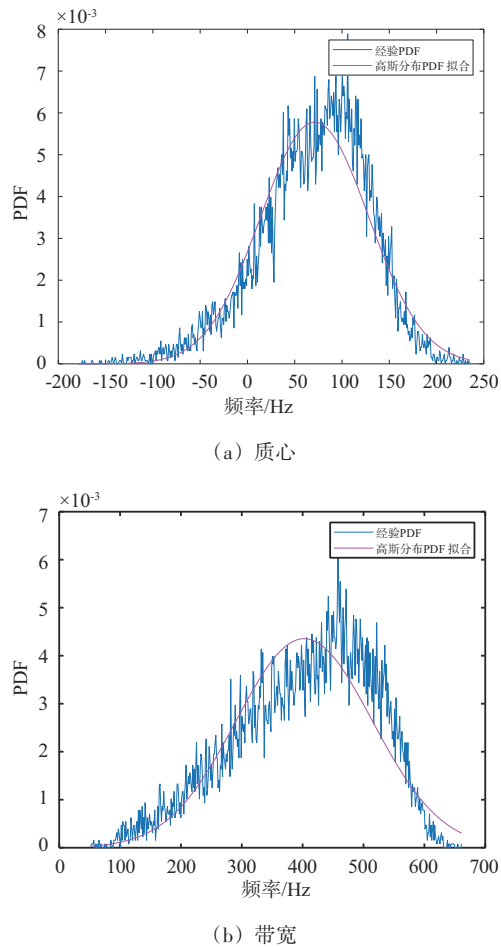

图9 $T=30$ 时测试集时频图质心与带宽PDF拟合曲线

图10 不同分布拟合度均方根误差检验

有几个标准差, Z 分数就是几。从而确定这一数据在全体数据中的位置。计算公式为

$$Z = \frac{x - \mu}{\sigma} \quad (13)$$

式中, x 为生成数据时频图的质心和带宽, μ 和 σ 为验证集质心和均方根带宽的均值和标准差。本文

选择以 $|Z| \leq 2$ 为标准, 此时高斯分布置信区间 ($\mu - 2\sigma, \mu + 2\sigma$) 对应的置信度大约是 95%, 若某时刻的质心和均方根带宽满足 $|Z| \leq 2$, 则认为该时刻的仿真是成功的。最终, 以所有时刻的仿真成功率作为评价模型性能的标准。

此次对比实验中, 分别选取了不同网络在 4 种海况等级和 3 种大小数据集上的准确率和每 100 个 epoch 的运行时间, 如表 1~3 所示。其中 GAN 网络对应的是全连接网络, DCGAN 对应的是卷积网络, WGAN 是在卷积网络的基础上增加了梯度惩罚约束, VAE 代表的是全连接网络加上潜在空间特征提取, 以此验证不同模块在海杂波数据生成中的性能差异。[64, 64] 与 [256, 256] 代表的是数据集中单个数据序列长度, 对比的是网络在长序列数据的可扩展性。每个网络都选用 Adam 优化器, 学习率设为 0.000 2, 卷积层参数设置和本文模型一样选择二维卷积层 Conv2d(4, 2, 1)。

表1 不同网络在 [64, 64] 数据集上的准确率和运行时间

生成网络	2级海况	3级海况	4级海况	5级海况	运行时间/s
GAN	76.6%	90.6%	96.9%	89.1%	100
DCGAN	76.6%	89.1%	93.8%	84.4%	135
WGAN	81.3%	93.8%	98.4%	90.6%	140
VAE	82.8%	90.6%	96.9%	93.8%	180
VAE-WGAN	90.6%	93.8%	98.4%	95.3%	140

表2 不同网络在 [128, 128] 数据集上的准确率和运行时间

生成网络	2级海况	3级海况	4级海况	5级海况	运行时间/s
GAN	81.3%	86.7%	85.9%	89.8%	200
DCGAN	82%	87.5%	88.3%	90.6%	215
WGAN	83.6%	93.8%	94.5%	93.7%	300
VAE	82.8%	91.4%	92.9%	94.5%	280
VAE-WGAN	92.2%	98.4%	96.9%	94.5%	270

表3 不同网络在 [256, 256] 数据集上的准确率和运行时间

生成网络	2级海况	3级海况	4级海况	5级海况	时间/s
GAN	84%	84.8%	84.4%	82.4%	2 000
DCGAN	64.8%	76.2%	81.6%	73.8%	575
WGAN	82.8%	83.2%	86.7%	85.5%	1 150
VAE	83.6%	83.6%	91.4%	84.8%	800
VAE-WGAN	93.8%	95.7%	93.8%	94.5%	920

VAE-WGAN 模型通过融合 VAE 的重参数化技术与 WGAN 的梯度惩罚机制, 在多海况、多规模数据场景中展现出优势。实验表明, 其 VAE 模块

通过潜在空间特征提取有效解决了传统模型对微弱时频特征捕捉不足的问题,在2级海况下准确率达93.8%,较DCGAN提升29%;WGAN模块的梯度惩罚约束显著提升训练稳定性,使5级海况准确率稳定在94.5%以上,同时将[256,256]数据训练耗时压缩至标准GAN的46%(920 s)。相较于单一架构模型,VAE-WGAN的复合设计通过参数共享与联合优化(KL散度+Wasserstein距离)实现了效率与性能的平衡:时间增长系数(6.57)低于WGAN(8.21),数据扩展波动(0.8%)仅为WGAN的2/3,且在[256,256]数据集上综合准确率较次优模型提升10.2个百分点,验证了其在高复杂度动态系统建模中的鲁棒性与可扩展性。

3 结束语

本研究提出基于双通道VAE-WGAN网络的海杂波数据仿真方法,通过双通道对抗架构同步优化海杂波的平稳统计特性与动态时频特征,结合自注意力机制精准捕获幅度分布的长拖尾特性和高频能量成分,有效解决了传统方法的模式崩溃、相位失真瓶颈问题。此外,12组数据集实验表明,该方法在低/高海况下分别实现了弱散射体统计重构与非平稳时频结构建模,以及对长序列数据仿真的稳健性。该框架为复杂电磁环境仿真提供了新范式,在雷达系统优化、目标检测算法验证等领域具有重要应用价值,未来将进一步融合物理模型增强极端场景的生成可信度。

参考文献:

- [1] ZHANG Zijun, FAN Yifei, ZHANG Shaofeng, et al. Statistical Characteristics Analysis Based on a Measured Ku-Band Sea Clutter Dataset[C]//2024 IEEE 7th International Conference on Electronic Information and Communication Technology, Xi'an, China: IEEE, 2024:664-667.
- [2] 黄勇,陈小龙,关键.实测海尖峰特性分析及抑制方法[J].雷达学报,2015,4(3):334-342.
- [3] ZHANG Bo, LUO Feng, ZHANG Linrang, et al. Covariance Matrix Estimation Method in Compound Gaussian Sea Clutter[C]//2011 CIE International Conference on Radar, Chengdu, China: IEEE, 2011:1965-1967.
- [4] 丁昊,董云龙,刘宁波,等.海杂波特性认知研究进展与展望[J].雷达学报,2016,5(5):499-516.
- [5] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020, 63(11):139-144.
- [6] ZHU Yanping, HUANG Lei, CHEN Jixin, et al. VGDOCoT: A Novel DO-Conv and Transformer Framework via VAE-GAN Technique for EEG Emotion Recognition[J]. Frontiers of Information Technology & Electronic Engineering, 2024, 25(11):1497-1514.
- [7] 屈乐乐,王禹桐.基于WGAN-GP的微多普勒雷达人体动作识别[J].雷达科学与技术,2022,20(2):195-201.
- [8] LIU Songzuo, YAN Honglu, MA Lu, et al. UACC-GAN: A Stochastic Channel Simulator for Underwater Acoustic Communication[J]. IEEE Journal of Oceanic Engineering, 2024,49(4):1605-1621.
- [9] 李昆,朱卫纲.基于MDGAN网络的数据集扩增方法[J].雷达科学与技术,2020,18(2):211-217.
- [10] HOU Lingyi, WANG Xiao, YANG Bo, et al. Retrieval of Three-Dimensional Wave Surfaces from X-Band Marine Radar Images Utilizing Enhanced Pix2Pix Model[J]. Journal of Marine Science and Engineering, 2024, 12(12):2229-2245.
- [11] 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.
- [12] CHATTERJEE S, HAZRA D, BYUN Y-C. GAN-Based Synthetic Time-Series Data Generation for Improving Prediction of Demand for Electric Vehicles[J]. Expert Systems with Applications, 2024(3):125838.
- [13] SMITH J, JOHNSON R. Generative Models in Radar Systems: Opportunities and Challenges[J]. IEEE Aerospace and Electronic Systems Magazine, 2023, 38(3):34-45.
- [14] 李骁,施赛楠,董泽远,等.基于时频域深度网络的海面小目标特征检测[J].雷达科学与技术,2022,20(2):209-216.
- [15] RONG C,OUYANG Shuxin,SUN Huabo.Anomaly Detection in QAR Data Using VAE-LSTM with Multihead Self-Attention Mechanism[J]. Mobile Information Systems, 2022(30):8378187.
- [16] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved Training of Wasserstein GANs[C]//Neural Information Processing Systems, Long Beach, California, USA: [s.n.], 2017:5767-5777.
- [17] APARNA V, HRIDIKA K V, NAIR P S, et al. Automating Dose Prediction in Radiation Treat-(下转第490页)

- Speed Target Detection with Bistatic MIMO Radar [J]. IEEE Trans on Geoscience and Remote Sensing, 2023, 61: 1-15.
- [10] ZENG Cengcang, WANG Fangzhou, LI Hongbin, et al. Target Detection for Distributed MIMO Radar with Non-orthogonal Waveforms in Cluttered Environments [J]. IEEE Trans on Aerospace and Electronic Systems, 2023, 59(5):5448-5459.
- [11] LU Jiabin, LIU Feifeng, SUN Jingyi, et al. Joint Estimation of Target Parameters and System Deviations in MIMO Radar with Widely Separated Antennas on Moving Platforms [J]. IEEE Trans on Aerospace and Electronic Systems, 2021, 57(3):3015-3028.
- [12] LI Zhe, DING Zegang, WANG Yinzi, et al. Space Target Detection Based on DBF and GRFT for Ground-Based Distributed Radar [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21:1-5.
- [13] RAO Xuan, TAO Haihong, SU Jia, et al. Axis Rotation MTD Algorithm for Weak Target Detection [J]. Digital Signal Processing, 2014(3):81-86.
- [14] YANG Jiefang, ZHANG Yunhua, MI Yunpeng, et al. A Novel Algorithm for Maneuvering Target Coherent Integration Based on Second-Order Keystone and Radon Fourier Transform [C]//IET International Radar Conference, Chongqing, China: IET, 2023:2458-2463.
- [15] 黄鹏辉. 复杂运动目标长时间相参积累方法研究[D]. 西安:西安电子科技大学, 2017.
- [16] ZOU Yifei, LI Xiukun, YU Ge. Adaptive WVD Cross-Term Removal Method Based on Multidimensional Property Differences [J]. Journal of Marine Science and Application, 2025, 24:774-788.
- [17] LI Xiaolong, CUI Guolong, YI Wei, et al. Coherent Integration for Maneuvering Target Detection Based on Radon-Lv's Distribution [J]. IEEE Signal Processing Letters, 2015, 22(9):1467-1471.
- [18] 陈小龙, 黄勇, 关键, 等. MIMO 雷达微弱目标长时积累技术综述[J]. 信号处理, 2020, 36(12):1947-1964.
- [19] DENG Jiangyun, SUN Zhi, CHEN Haixu, et al. Passive Localization Method of LFM Signal Transmitter Based on Multi-Channel Joint Accumulation in FrFT Domain [C]//International Conference on Information Fusion, Venice, Italy: IEEE, 2024:1-6.
- [20] LIU Xinghua, XU Zhenhai, LIU Xiang, et al. A Clean Signal Reconstruction Approach for Coherently Combining Multiple Radars [J]. Journal on Advances in Signal Processing, 2018(1):1-11.

作者简介:

张晓波 男, 博士, 研究员, 主要研究方向为雷达系统。

李相海 男, 博士, 讲师, 主要研究方向为天基分布式雷达微弱目标信号相参处理。

徐星苑 女, 博士研究生, 主要研究方向为高速机动目标探测成像。

高翔 男, 硕士研究生, 主要研究方向为天基分布式雷达 SAR-GMTI 处理。

杨志伟 男, 博士, 教授, 主要研究方向为天基雷达空中动目标探测成像。

(上接第 481 页)

ment Planning Using Self-Attention-Based Dense Generative Adversarial Network [C]//Fourth Congress on Intelligent Systems, Singapore: Springer, 2024:15-28.

[18] 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.

[19] 周子铂, 王鑫奎, 蔡万勇, 等. 联合时频分析和谱估计的机动目标 ISAR 成像[J]. 雷达科学与技术, 2021, 19(4):393-402.

作者简介:

刘宁波 男, 博士, 教授, 主要研究方向为雷达信号智

能处理、海上目标探测技术。

刘新亮 男, 硕士研究生, 主要研究方向为海杂波仿真和特征分析。

董云龙 男, 博士, 教授, 主要研究方向为多传感器信息融合、雷达目标检测与跟踪。

丁昊 男, 博士, 副教授, 主要研究方向为海杂波特性和抑制、海杂波中目标检测。

关键 男, 博士, 教授, 主要研究方向为雷达信号处理、海上目标探测检测。

孙殿星 男, 博士, 副研究员, 主要研究方向为机动目标跟踪、信息融合。