

DOI: 10.3969/j.issn.1671-0673. 2026. 02. 002

生成—抑制联合学习框架下的海杂波抑制方法

刘翔宇¹, 张红敏¹, 陈 彬¹, 伍红州²

(1. 信息工程大学, 河南 郑州 450001; 2. 96471 部队, 陕西 渭南 715400)

摘要: 雷达进行海上目标探测时, 不可避免地受海杂波影响, 当海杂波速度与低速目标相近, 处理平台无法有效分离与抑制杂波, 导致目标检测困难。针对此问题, 在构造杂波模型与真实海况数据拟合的杂波拟合网络的基础上, 提出一种基于高阶统计量的快速收敛损失函数, 有效实现网络对真实杂波幅度分布和相关性的学习, 将杂波拟合网络输出递进输入到信号增强网络, 两个网络构成生成—抑制联合学习框架(GSIL)。实验结果表明, GSIL 的杂波分离与抑制性能得到提升, 与信号增强网络结构相同的卷积神经网络模型(CNN)相比, 在杂波抑制比上提高了 3 dB, 相比动目标显示(MTI)算法在信杂比改善因子上提高 0.3, 取得了较好的杂波抑制效果, 证明了算法的有效性。

关键词: 生成—抑制联合学习框架; 杂波抑制; 联合损失函数; 目标检测

中图分类号: TN971.1

文献标识码: A

文章编号: 1671-0673(2026)02-0136-09

Sea Clutter Suppression Method Based on the Generation-Suppression Joint Learning Framework

LIU Xiangyu¹, ZHANG Hongmin¹, CHEN Bin¹, WU Hongzhou²

(1. Information Engineering University, Zhengzhou 450001, China; 2. Unit 96471, Weinan 715400, China)

Abstract: When radar detects maritime targets, it is inevitably affected by sea clutter. When the speed of sea clutter is similar to that of low-speed targets, the processing platform cannot effectively separate and suppress the clutter, making target detection difficult. To address this issue, a fast-converging method is proposed, in which a loss function based on high-order statistics is developed on the basis of constructing a clutter model and a clutter fitting network that fits real sea-condition data, thereby effectively enabling the network to learn the amplitude distribution and correlation characteristics of real clutter. The output of the clutter fitting network is progressively input into the signal enhancement network, and the two networks form a generation-suppression joint learning framework (GSIL). Experimental results show that the clutter separation and suppression performance of the generation-suppression joint learning framework is improved. Compared with that of a CNN with the same signal enhancement network structure, the clutter suppression ratio is increased by 3 dB. And compared with that of moving target indication (MTI), the improvement factor of the signal-to-clutter ratio is increased by 0.3. Good clutter suppression effects have been achieved, proving the effectiveness of the algorithm.

Key words: generation-suppression joint learning framework; clutter suppression; joint loss function; target detection

随着雷达和电子技术的发展, 海上目标实时 监测和精确探测的需求对雷达快速、可靠地探测

收稿日期: 2025-11-26; 修回日期: 2025-12-15

作者简介: 刘翔宇(2002—), 男, 硕士, 主要研究方向为雷达智能信号处理。E-mail: xxgcdxwuyuan@163.com

通信作者: 张红敏(1984—), 女, 副教授, 博士, 主要研究方向为雷达信号分析与处理。E-mail: zhmin1206@163.com

小型机动目标的能力提出了挑战^[1]。传统雷达信号处理方法如动目标显示(Moving Target Indication, MTI)算法,利用目标的多普勒频移,分离静止杂波与运动目标回波,实现杂波抑制^[2]。MTI在探测低速目标时,若海浪与目标速度相近,会出现目标与海杂波的多普勒谱出现重叠^[3],导致海杂波难以有效分离与抑制。因此,实现海杂波有效抑制,对海上低速目标回波探测至关重要。

在杂波抑制领域,学者们做了大量研究。文献[4]设计了一种交错MTI滤波器,有效改善了传统MTI滤波器的盲速问题;文献[5-6]分别针对双基地合成孔径雷达和部分校准阵列(Partially Calibrated Array, PCA)机载雷达,提出了基于稀疏恢复的空时自适应处理(Sparse Recovered Space-Time Adaptive Processing, SR-STAP)算法,在训练样本有限的情况下有效实现海杂波抑制。上述方法对均匀海杂波模型有较好的抑制效果,但海浪速度与目标速度相近时,以上算法对杂波的分离与抑制能力较差^[5-6]。

为解决上述问题,学者们将深度学习方法引入到海杂波抑制的研究当中。文献[7]采用将回波信号组成复数形式的距离—多普勒图像的方法,通过图像神经网络实现对海杂波的抑制;文献[8-11]在卷积神经网络(Convolutional Neural Network, CNN)结构的基础上,去除了传统CNN模型中的池化层,避免高频特征丢失,保留目标信号和结构信息。文献[12-14]采用生成对抗网络,设计了一维卷积层与全连接层相结合的结构,保证信号结构的同时去除杂波。以上研究采取的处理方法能有效实现对海杂波的抑制,但大多采用仿真数据,缺少对真实海况下海杂波的抑制研究。

当前海杂波仿真方法应用最广泛的是Conte等^[15]提出的无记忆非线性变换法(Zero Memory Nonlinearity, ZMNL)和Marier^[16]提出的球不变随机过程法(Spherically Invariant Random Process, SIRP),这两种方法能够较好地拟合海杂波的统计特性,但仿真海杂波的尖峰分布较为均匀,且参数通常固定,对海杂波的相关性拟合程度有限。近年来,学者尝试将深度学习引入杂波仿真。丁斌等^[17]利用生成对抗网络,由生成器生成仿真海杂波,由判别器判断生成器输出数据与真实数据的区别。马鑫^[18]基于生成式神经网络设计了两种标签嵌入方式,实现控制韦布尔分布在不同尺度参数下的杂波生成。基于深度学习的海杂波仿真方

法尚处于起步阶段,在海杂波的幅度统计分布上实现了较好的拟合效果,但对相关性的拟合研究尚有所欠缺。

为此,本文提出生成—抑制联合学习框架(Generation-Suppression Joint Learning, GSJL),该框架在实现海杂波仿真的同时,实现带杂波信号的海杂波分离与抑制。为拟合海杂波尖峰、重尾特征和偏度等分布特性,引入高阶统计量作为损失函数,以拟合海杂波的复杂分布特性。首先对实际海况数据的高阶统计量展开分析,利用GSJL框架生成仿真杂波,扩展海杂波数据集,同时对框架中的信号增强网络进行迭代训练。相较其他网络模型,该模型通过引入联合学习框架,有效提高网络对杂波的估计与抑制能力。

1 信号模型

1.1 信号回波模型构建

不失一般性,假设雷达发射线性调频信号,忽略载频影响,信号可记作^[19]:

$$s_t(t, t_m) = \text{rect}\left(\frac{t}{T_p}\right) \exp(j\pi k_r t^2) \exp[j2\pi f_c(t + t_m)] \quad (1)$$

$$\text{rect}\left(\frac{t}{T_p}\right) = \begin{cases} 1, & |t| \leq T_p/2 \\ 0, & |t| > T_p/2 \end{cases} \quad (2)$$

式中: t 为快时间; T_p 为脉冲持续时间; $k_r = B/T_p$ 为线性调频信号的调频率, B 为发射信号带宽; f_c 代表载频; $t_m = m/f_p$ 表示慢时间变量; $m = 0, 1, \dots, M-1$ 为脉冲指数, M 为积累脉冲总数, $f_p = 1/T_r$ 为雷达脉冲重复频率, T_r 表示脉冲重复间隔。假设目标以匀速运动,目标与雷达之间的距离公式为

$$R(t_m) = R_0 + vt_m \quad (3)$$

式中: R_0 为目标起始距离; v 代表目标径向速度。

信号经过反射后返回雷达接收端,回波公式为

$$s_r(t, t_m) = A_r \text{rect}\left(\frac{t - 2R(t_m)/c}{T_p}\right) \times \exp\left\{j\pi k_r \left[t - \frac{2R(t_m)}{c}\right]^2\right\} \exp\left[\frac{-j4\pi f_c R(t_m)}{c}\right] \quad (4)$$

式中: A_r 为目标回波幅度; c 为光速。

时域雷达接收信号模型为

$$x_r(t, t_m) = s_r(t, t_m) + c_1(t, t_m) \quad (5)$$

式中: $x_r(t, t_m)$ 为雷达接收信号; $s_r(t, t_m)$ 为回波信号; $c_1(t, t_m)$ 为雷达接收的海杂波。

1.2 K分布杂波仿真方法

K分布相较瑞利、韦布尔和对数正态分布,能更好拟合海杂波的分布。ZMNL法是一种经典的K分布海杂波仿真方法,通过非线性变换将高斯过程变换为符合伽马统计特性的过程,将分别得到的局部功率和散斑分量相乘得到对应的K分布杂波^[16],公式如下:

$$z = \sqrt{X \cdot Y} \quad (6)$$

式中,将瑞利分量 X 和伽马分量 Y 相乘即可得到K分布序列 z 。不同海况下的海杂波形状和尺度参数差异较大,为选取合适的参数对不同海况的杂波分布进行仿真,本文选取文献[20]中发布的对海探测数据作为标签,采取二阶/四阶矩估计^[21],计算形状参数 v_c 和尺度参数 a 公式如下:

$$\begin{cases} v_c = \left(\frac{M_4}{2M_2^2} - 1 \right)^{-1}; \\ a = \frac{1}{2} \sqrt{\frac{M_2}{v_c}}. \end{cases} \quad (7)$$

式中: M_2 为海杂波数据的二阶矩; M_4 为海杂波数据的四阶矩,计算可得对应海况的 v_c 和 a 的均值。

对文献[20]中的不同海况真实杂波的 $\bar{a}$ 和 $\bar{v}_c$ 进行估计。根据不同海况下 $\bar{a}$ 和 $\bar{v}_c$ 的取值,采用ZMNL法生成对应海况下仿真K分布杂波,其中5级海况仿真杂波如图1,真实海杂波如图2。




图1 5级海况参数下K分布杂波仿真图




图2 真实海杂波

由图1、图2可见,真实海杂波局部突变更强,距离变化更明显,仿真海杂波不会随距离发生变化。为拟合真实海况,需要设计杂波拟合网络对仿真K分布杂波进行训练,使生成的杂波在幅度和高阶统计量上更符合真实海况,为实际训练信号增强网络提供数据集。

2 基于GSJL的低速目标海杂波抑制算法

2.1 GSJL框架

GSJL框架分为两部分,由图3所示。杂波拟合网络用于生成拟合真实海况的杂波数据集,信号增强网络用于学习杂波分布并进行抑制。杂波拟合网络以对海探测数据为标签,学习真实杂波数据的统计特性和相干性,生成拟合杂波;将带仿真杂波的回波信号投入信号增强网络中进行迭代训练,逐步提高信号增强网络的杂波分离与抑制性能。




图3 GSJL框架工作流程

2.2 杂波拟合网络

杂波拟合网络如图4所示。




图4 杂波拟合网络结构

图4中,杂波拟合网络主要由卷积块和弃置层组成。其中,卷积块由卷积层、归一化层和激活函数构成。杂波拟合网络以真实海杂波数据为标签,设输入层大小为脉冲单元数 N 和信号长度 S ,将杂波的实部与虚部分为两个通道,设输入层数据为 $X = (N, S, 2)$,输入经过归一化层的公式为

$$\hat{X} = \frac{X - \mu}{\sqrt{\sigma^2 + \nu}} \quad (8)$$

式中: $\hat{X}$ 为归一化层输出; σ 为方差; μ 为均值; ν 为很小的常数,避免分母置零。由归一化层经过 LeakyRelu 层,公式为

$$f(x) = \begin{cases} x, & x > 0; \\ \alpha x, & x \leq 0. \end{cases} \quad (9)$$

式中, α 为一个很小的值,一般取0.01,保证神经网络不会因输入负值导致无法更新参数。

数据由归一化层进入卷积层,设卷积层大小为 (a, b) ,数据经过卷积公式为

$$Y(i, j) = \sum_{s=0}^{a-1} \sum_{n=0}^{b-1} X(i+s, j+n) \cdot K(s, n) \quad (10)$$

式中: $Y(i, j)$ 为数据与卷积核在 (i, j) 的值; $X(i+s, j+n)$ 为输入数据在位置 $(i+s, j+n)$ 的值; $K(s, n)$ 为卷积核在 (s, n) 的值。为充分学习到海杂波的纹理特征,同时避免因卷积核增大导致计算量提高,本文采取扩张因子(Dilation Factor)扩大感受野的卷积,即保证卷积核取样点不变的同时,将取样点间隔拉大,公式如下:

$$Y(i, j) = \sum_{s=0}^{a-1} \sum_{n=0}^{b-1} X(i+d \cdot (s-c), j+d \cdot (n-c)) \cdot K(m, n) \quad (11)$$

式中: d 为扩张因子,当 $d=1$ 时,为正常卷积, $d>1$ 时,取样点间隔拉大; c 代表卷积核中心。

在对海杂波进行仿真时,可通过提取杂波数据的高阶统计量实现对海杂波在形状和尺度上的仿真。海杂波的原点矩定义为

$$M_{pq} = \sum_i \sum_j x(i, j)^p y(i, j)^q \quad (12)$$

式中: M_{pq} 为 $(p+q)$ 阶原点矩; i, j 分别为杂波的行、列坐标; $x(i, j)$ 、 $y(i, j)$ 为杂波的横、纵坐标; p 、 q 为原点矩的阶数。利用第1组卷积块可逐步提取杂波分布的一阶统计量,公式为

$$E_1(i, j) = \max \left(0, \sum_{m,n} w_1(m, n) \cdot x(i+m, j+n) \right) \quad (13)$$

式中: $E_1(i, j)$ 为通过第1组卷积块得到的一阶局部统计量; $w_1(m, n)$ 为 (m, n) 大小的卷积核; $x(i+m, j+n)$ 为杂波位置。

在得到一阶局部统计量的基础上,利用卷积块进一步提取二阶特征。以此类推,在多卷积块情况下经过卷积滤波可以得到杂波的近似多阶统计量,公式为

$$E_k(i, j) = \max \left(0, \sum_Z w_{k,Z} \cdot E_{k-1,Z}(i, j) \right) \quad (14)$$

式中: $E_k(i, j)$ 为通过第 k 组卷积块得到的 k 阶局部统计量; $w_{k,Z}$ 为卷积核。因此,在网络中引入4层以

上的卷积块,使网络具有提取杂波分布高阶统计量的能力。

2.3 信号增强网络

将带杂波的回波信号投入信号增强网络中。信号增强网络结构如图5所示。




图5 信号增强网络结构

图5中信号增强网络为保留信号的细微特征,删去了池化层和弃置层,避免训练过程中丢失杂波的重要特征。多卷积块设计可以提高网络的特征提取能力。卷积核大小采取对称式设计,便于信号在训练初期快速提取全局信息,减少后续处理复杂度;小卷积核可以减少计算量,避免过拟合,并且能够逐步提取细微特征;后期采取大卷积核有利于信号特征的整合,提高模型对复杂特征的提取能力,数据在信号增强网络结构中经过归一化层、激活函数和卷积层,同式(8)~式(10)。

2.4 损失函数设计

为实现输入杂波与标签在能量分布的逼近,参考式(7),本文设计了一种基于杂波高阶统计量与自相关函数的联合损失函数,公式如下:

$$L_{GNet} = \beta_1 L_{GNet1} + \beta_2 L_{GNet2} + \beta_3 L_{GNet3} \quad (15)$$

式中: L_{GNet1} 为基于高阶统计量的损失函数; L_{GNet2} 为基于空间自相关的损失函数; L_{GNet3} 为基于时间自相关的损失函数;联合损失函数为 L_{GNet} ; β_i 代表权重因子。

1)为保证网络能够提取真实杂波的分布特征,本文选取三阶和四阶统计量用于拟合网络的形状分布,公式如下:

$$L_{GNet1} = \alpha (M_{3out} - M_{3label})^2 + (1 - \alpha) (M_{4out} - M_{4label})^2 \quad (16)$$

式中: M_{3label} 、 M_{4label} 分别为输入杂波的三阶、四阶统计量; M_{3out} 、 M_{4out} 分别为经过网络训练后输出杂波的三阶、四阶统计量; α 为权重因子;下角标 out 和 label 分别代表输出杂波和作为标签的杂波。海杂波的三阶和四阶统计量分别用于描述杂波的偏斜度和重尾特征,用于拟合更真实的杂波形状,但不影响时序结构和相关性。此外,二阶统计量计算公式为

$$M_2 = E[C(t)^2] \quad (17)$$

进行自相关计算,当 τ 、 $k=0$ 时,公式为

$$R(\tau) = \frac{E[C(i,j)C(i,j)]}{\sigma_c^2} = \frac{E[C(i,j)^2]}{\sigma_c^2} \quad (18)$$

式中: $C(i,j)$ 代表在点 (i,j) 上的去均值后的杂波幅度分布; $E(\cdot)$ 为期望,用于计算平均; σ_c^2 代表杂波的方差。二阶统计量与自相关函数出现重叠,会出现二者下降方向不一致的问题,导致网络拟合效果下降。因此本文采用三阶统计量和四阶统计量作为 L_{GNet1} 的损失函数之一。

2)将输出的相关性指标 $R_{out}(k)$ 与标签 $R_{label}(k)$ 之间的差异作为损失函数参与网络训练,使网络能够学习到杂波脉冲内或者脉冲之间的相关性,实现对真实杂波相关性的拟合。公式如下:

$$\left\{ \begin{aligned} L_{GNet2} &= \frac{1}{2N+1} \sum_{k=-N}^N (R_{out}(k) - R_{label}(k))^2; \\ R_{out}(\tau) &= \frac{E[C_{out}(i,j)C_{out}(i+\tau,j)]}{\sigma_{C_{out}}^2}; \\ R_{label}(\tau) &= \frac{E[C_{label}(i,j)C_{label}(i+\tau,j)]}{\sigma_{C_{label}}^2}. \end{aligned} \right. \quad (19)$$

$$\left\{ \begin{aligned} L_{GNet3} &= \frac{1}{2S+1} \sum_{k=-S}^S (R_{out}(k) - R_{label}(k))^2; \\ R_{out}(\tau) &= \frac{E[C_{out}(i,j)C_{out}(i,j+\bar{c})]}{\sigma_{C_{out}}^2}; \\ R_{label}(\tau) &= \frac{E[C_{label}(i,j)C_{label}(i,j+\bar{c})]}{\sigma_{C_{label}}^2}. \end{aligned} \right. \quad (20)$$

式中: N 为脉冲内采取的相关点数; S 代表相邻距离单元; $\bar{c}$ 为时间方向的延迟采样点数。

3)联合损失函数 L_{GNet} 在设计中避免了梯度冲突,保证了杂波在拟合形状分布的同时,兼顾杂波的相关性。

4)信号增强网络输入为雷达回波的距离—脉冲图,本文采取MSE衡量杂波抑制程度,其损失函数如下:

$$L_{DNet} = \frac{1}{N} \sum (f_{out} - f_{in})^2 \quad (21)$$

式中: L_{DNet} 为生成器损失函数; f_{out} 为输出目标回波; f_{in} 为输入目标回波; N 为样本数量。

3 仿真结果与性能分析

3.1 实验环境

雷达回波信号和K分布杂波由MatlabR 2020a仿真生成。深度学习框架采取MatlabR 2020a的神经网络工具箱,实验数据在NVIDIA GeForce RTX 4070 Laptop GPU上进行训练和测试。

3.2 实验数据

本文生成不同特征参数和接收时间的回波信号。雷达回波信号、噪声模型和杂波模型参数设置如表1所示。

表1 参数设置

信号	参数	取值
LFM 信号	载频/MHz	9 500
	脉宽/ns	40
	带宽/MHz	25
	重频/Hz	2 000
探测目标	距离/km	5.37
	速度/(m/s)	10.29~15.44

雷达参数选取参考文献[18],雷达对海探测数据所采取的雷达载频为X波段,本文选取9 500 MHz,雷达发射时间为40 ns,带宽为25 MHz。采用目标为低速海上航行目标,目标速度为10.29~15.44 m/s。探测目标设置为距离雷达5.37 km的目标,速度在10.29~15.44 m/s之间,速度与海浪速度有所重叠。

根据以上参数生成仿真LFM信号,产生600条信号用于训练,产生200条信号用于测试。训练集由目标回波与增强后的海杂波数据混合形成,投入信号增强网络进行训练。训练结束后将测试集投入网络进行测试,观察信号增强网络的杂波抑制效果和信号失真情况。

3.3 评价指标

为确保信号在杂波抑制后保留主要特征,便于后续进行目标检测等问题的研究,本文设置杂波抑制比(Clutter Suppression Ratio, CSR)、信杂比改善因子(Signal to Clutter Ratio Improvement Factor, SCRIF)和改善信杂比(Improved Signal-to-Suppression Ratio, ISCR)作为衡量杂波抑制程度的指标。 I_{CSR} 用于评价目标回波经过信号增强网络后的杂波抑制效果; I_{SCRIF} 用于评价目标回波经过信号增强网络的信号还原效果; I_{ISCR} 用于评价真实目标回波经过网络训练后的信杂比改善情况。

I_{CSR} 为原杂波功率和经过网络训练后残余杂波功率的比值,在确定杂波功率的情况下, I_{CSR} 越大,说明杂波抑制效果越好,计算公式为

$$I_{CSR} = 10 \lg \frac{P_{cin}}{P_{sin} - P_{sout}} \quad (22)$$

式中: P_{cin} 为经过信号增强网络之前带杂波信号中的杂波功率; P_{sin} 为信号增强网络输入雷达信号功率; P_{sout} 为信号增强网络输出雷达信号功率。由于经过信号增强网络后,杂波和信号混叠都受到一

定程度的抑制,因此 $(P_{\text{sin}} - P_{\text{sout}})$ 包含残余杂波功率与信号损失的功率和,所以需要对杂波抑制后与杂波抑制前信号功率的差异进行分析,因此需要引入信杂比改善因子 I_{SCRIF} ,计算公式为:

$$I_{\text{SCRIF}} = \frac{I_{\text{SCR}_o}}{I_{\text{SCR}_i}} \quad (23)$$

$$I_{\text{SCR}_o} = 10 \lg \frac{P_{\text{sout}}}{P_c} \quad (24)$$

$$I_{\text{SCR}_i} = 10 \lg \frac{P_{\text{sin}}}{P_c} \quad (25)$$

式中: I_{SCR_o} 为通过信号增强网络后信号与通过信号增强网络之前杂波的信杂比; I_{SCR_i} 为通过信号增强网络之前的信号与杂波的信杂比。通过计算上述信杂比的比值,可以得到增强前后信号的失真程度值,越接近1,信号失真程度越小。

假设目标位置未知,需要大致计算目标回波功率,设置不依赖以上先验知识的评价指标,即改善信杂比 I_{ISCR} ,公式为

$$I_{\text{ISCR}} = 10 \lg \frac{P_s}{P_{\text{clear}}} \quad (26)$$

式中, P_s 为杂波抑制后目标回波功率,计算方法为

取目标回波峰值前后长度为 N 的范围。计算信号的平均功率,公式为

$$P_s = \frac{1}{N} \sum_{i \in \{M\}} S_i^2 \quad (27)$$

式中: $\{M\}$ 代表取杂波抑制后目标回波 N 个峰值点作为回波信号样点;每个点的功率 S_i 求和后取平均,作为杂波抑制后目标回波的功率。

P_{clear} 代表目标回波通过信号增强网络之前和信号网络之后的功率差,公式为

$$P_{\text{clear}} = P_{\text{out}} - P_{\text{in}} \quad (28)$$

式中: P_{in} 代表目标回波通过信号增强网络前的功率; P_{out} 代表目标回波通过信号增强网络后的功率。由定义可知, I_{ISCR} 越小,说明杂波抑制能力越强, P_{clear} 越大,杂波抑制效果越好。

综上,计算得到增强后信号的 I_{CSR} 、 I_{SCRIF} 和 I_{ISCR} ,用来判断信号增强网络性能,可以有效评价网络对杂波的抑制程度和目标信号失真程度。

3.4 实验参数

GSJL框架的训练参数见表2,对比实验中采取的CNN网络训练选择相同的训练参数。

表2 网络训练参数

网络参数	优化算法	MaxEpochs	MiniBatchSize	InitialLearnRate	LearnRateDropPeriod	LearnRateDropFactor	调整因子 α
信号增强网络	adam	300	600	0.01	100	0.1	
杂波拟合网络	adam	100	600				0.1

生成—抑制联合学习框架的网络结构如表3和表4所示。其中,卷积核 (N, N) 代表卷积核尺寸, N 代表卷积核数量,dil代表扩张因子。

表5为GSJL框架,采取脉冲数20、脉冲长度1000的复信号作为输入时模型参数量、FLOPs和调整运行时间的估计结果,其中调整运行时间为模型在GPU上运行1次所需时间。

表3 生成—抑制联合学习框架的杂波拟合网络结构

网络层	网络参数	通道数
输入层	ImageInputlayer	2
卷积层1	卷积核(3, 3), 64个, dil=1	2→64
Dropout	0.05	64
归一化层1	BatchNorm(BN)	64
激活函数1	LeakyRelu	64
卷积层2	卷积核(3, 3), 64个, dil=2, BN, LeakyRelu	64
卷积层3	卷积核(3, 3), 64个, dil=4, BN, LeakyRelu	64
卷积层4	卷积核(3, 3), 64个, dil=8, BN, LeakyRelu	64
卷积层5	卷积核(3, 3), 64个, dil=1, BN, LeakyRelu	64
卷积层6	卷积核(3, 3), 2个, dil=1	64→2

表4 生成—抑制联合学习框架的信号增强网络结构

网络层	网络参数	通道数
输入层	ImageInputlayer	2
卷积块1	卷积核(3, 3), 64个, BN, relu	2→64
卷积块2~3	卷积核(3, 3), 64个, BN, relu	64
卷积块4	卷积核(3, 3), 128个, BN, relu	64→128
卷积块5	卷积核(3, 3), 128个, BN, relu	128
卷积块6	卷积核(3, 3), 64个, BN, relu	128→64
卷积块7~12	卷积核(3, 3), 64个, BN, relu	64
卷积块13	卷积核(3, 3), 32个, BN, relu	64→32
卷积层14	卷积核(3, 3), 2个	32→2

表5 GSJL框架模型参数量、FLOPs和调整运行时间

网络	模型参数量	FLOPs/ 10^6 s^{-1}	调整运行时间/s
杂波抑制网络	150 722	5.98	0.004 955
信号增强网络	612 770	24.40	0.021 643

3.5 杂波特性差异度评估实验

采取杂波拟合网络生成仿真杂波,并经过1000次蒙特卡洛实验,拟合杂波与真实杂波的高阶统计量柱状图与时间和空间自相关拟合曲线如图6~图8所示。图6中,使用蒙特卡洛平均,训练仅约束 $M_3/$

M_4 。可以看出,网络生成海杂波在高阶统计量和时空自相关性上与真实杂波实现了较高水平的拟合。




图6 二阶统计量到四阶统计量比较




图7 时间与空间自相关性拟合曲线




图8 网络生成杂波

通过式(19)~式(20)计算仿真杂波和真实杂波的空间自相关系数、时间自相关系数、高阶统计量的差值,结果如表6所示。

表6 仿真杂波与真实杂波自相关系数之差

评价指标	参数
时间自相关系数差	0.077 4
空间自相关系数差	0.079 0
二阶统计量差值	0.337 8
三阶统计量差值	0.381 5
四阶统计量差值	0.192 4

由表6可知,仿真杂波与真实杂波自相关系数差经过1 000次蒙特卡洛实验后稳定在0.1以下,证明仿真杂波与真实杂波具有较好的拟合效果。

为衡量杂波拟合网络中损失函数和卷积层扩张因子在网络训练中的作用,本文设计消融实验,分别替换损失函数和扩张因子进行实验,将仿真杂波与真实杂波的时间、空间自相关系数比、二阶统计量到四阶统计量的差值作为衡量指标,结果如表7所示。

表7 消融实验结果

评价指标	删除损失函数后	删除扩张因子后
时间自相关系数差	0.044 5	0.057 5
空间自相关系数差	0.133 2	0.129 8
二阶统计量差值	0.046 1	0.261 2
三阶统计量差值	0.577 7	0.271 4
四阶统计量差值	3.117 4	0.366 7

如表7所示,把损失函数替换为均方误差后,虽然在一定程度上能够实现时间相关性和二阶统计量上的拟合,但对高阶统计量无法约束,偏离较大。删除卷积层中的扩张因子后,网络在损失函数的约束下空间自相关性拟合程度下降,其余指标与真实杂波拟合效果相差不大。消融实验证明了损失函数在网络训练中的重要性,为基于高阶统计量和相关性的损失函数合理性提供了数据支撑。此外,扩张因子作为卷积层中提取杂波纹理特征的参数,对网络的拟合结果影响远小于损失函数。

综上,网络生成的仿真海杂波可以用于后续杂波抑制的仿真实验中,为海杂波数据集的扩展和杂波抑制网络提供支撑。

3.6 不同信杂比下的算法实验

采取五级海况数据参与网络训练与测试。首先对目标回波经过归一化后将原始回波投入网络,输出杂波抑制后的脉冲回波,绘制未投入网络时仿真回波的距离—脉冲图和经过杂波抑制后的信号的距离—脉冲图,观察网络的杂波抑制效果。信杂比为-10、-20 dB的原始目标回波和杂波抑制后的目标脉冲—距离图如图9~图12所示。杂波抑制前信号分布在对应快时间轴15~20 μs 之间。

设置输入信号信杂比为-5~-20 dB,输入600批样本数据进行测试,评价指标结果如表8所示。

对比增强前和增强后的距离—脉冲图可以看出,信号增强网络对杂波整体都有很强的抑制效

果,随着信杂比的降低,信号增强网络仍能将杂波与信号分离。




图9 -10 dB原始回波脉冲—距离图




图10 -10 dB杂波抑制后脉冲—距离图




图11 -20 dB原始回波脉冲—距离图




图12 -20 dB杂波抑制后脉冲—距离图

表8 GSJL框架增强结果评价指标

信杂比/dB	CSR/dB	SCRIF(均值)	ISCR/dB
-5	31.482 0	1.002 8	-5.023 0
-10	31.307 2	1.005 1	-10.017 9
-15	28.982 0	1.014 1	-15.064 7
-20	28.004 8	1.040 1	-20.066 4

3.7 与其他算法性能对比

为评估GSJL框架对杂波抑制的效果,本文采取表7中的评价指标作为参考,与文献[4]、文献[6]和文献[10]中的CNN、SR-STAP和MTI杂波抑制算法进行对比,随机选取200条样本,调整不同信杂比大小的真实海杂波数据对算法效果和运行时间进行测试,测试结果如表9~表12所示。由于MTI算法会进行脉冲对消,导致信号功率降低,因此不采取CSR衡量MTI算法的性能。

表9 信号增强算法CSR对比 单位: dB

信杂比	GSJL	CNN	SR-STAP
-5	31.482 0	25.994 2	9.819 7
-10	31.307 2	26.331 0	14.858 2
-15	28.982 0	26.518 0	17.238 8
-20	28.004 8	26.524 0	17.236 6

表10 信号增强算法SCRIF对比

信杂比/dB	GSJL	CNN	SR-STAP	MTI
-5	1.002 8	1.059 5	3.311 8	1.045 2
-10	1.005 1	1.059 4	1.688 7	1.066 6
-15	1.014 1	1.059 4	1.123 3	1.074 5
-20	1.040 1	1.060 3	0.848 2	1.077 0

表11 信号增强算法ISCR对比 单位: dB

信杂比	GSJL	CNN	SR-STAP	MTI
-5	-5.023 0	-5.046 6	-9.210 8	6.683 5
-10	-10.071 4	-10.159 8	-9.215 4	2.189 8
-15	-15.234 9	-15.326 0	-9.072 7	-0.041 4
-20	-20.114 9	-20.857 0	-8.899 1	-1.242 7

表12 信号增强算法运行速度对比

算法	运行时间/s
GSJL	0.104 1
CNN	0.159 3
SR-STAP	0.000 5
MTI	0.002 1

从表9中可以看出,GSJL框架的杂波抑制能力稳定,相比CNN网络的杂波抑制能力平均高约3 dB,与SR-STAP算法相比,杂波抑制能力提高约10 dB。从表10可以看出,GSJL框架的信号还原能力最好,信号失真度最低,相较CNN网络优化接近0.04。从表11可以看出,GSJL框架的 I_{ISCR} 与CNN网络较为接近,随着信杂比降低, I_{ISCR} 越低,杂波抑制效果较好。在高信杂比情况下,SR-STAP算法的 I_{ISCR} 较低,杂波抑制效果较好,随着信杂比下降,

I_{ISCR} 变化程度不大, SR-STAP 算法在低信杂比情况下杂波抑制能力较差。相较 GSJL 及 CNNMTI 算法的 I_{ISCR} 在信杂比降低时下降幅度缓慢。GSJL 框架与 MTI 算法相比, 信杂比改善效果明显更优。参考指标 I_{CSR} 和 I_{ISCR} , GSJL 框架的目标回波抑制程度优于 CNN 网络, 且 GSJL 框架的信号还原程度较好。表 12 为随机一条样本的杂波抑制算法运算时间, GSJL 框架的运行时间相较传统算法时间较长, 但相较 CNN 网络运行速度有明显提高。

综上, GSJL 框架相较其他 3 种算法, 杂波抑制能力好, 信杂比改善程度高, 相较 CNN 网络, 提高了信号处理速度。以上实验结果体现出了 GSJL 框架在处理杂波问题上具有处理能力的优势。

对以上 4 种算法进行检测性能分析, 进行 500 次蒙特卡罗实验, 检测概率为 90% 时算法所需的最低信杂比, 结果如表 13 所示。

表 13 检测概率为 90% 时各算法最低信杂比

算法	信杂比/dB
GSJL	-33
CNN	-32
SR-STAP	-9
MTI	2

由表 13 可知, 经过 GSJL 框架实现杂波抑制后的信号检测所需信杂比较低, 与 CNN 网络检测概率相近; 相较 SR-STAP 算法和 MTI 算法, GSJL 框架对海杂波抑制效果较好, 还原信号较为明显。

4 结束语

针对复杂海况下海杂波频谱扩展严重、杂波难以有效抑制, 导致低速目标检测困难的问题, 本文设计 GSJL 框架以综合学者们提出的海杂波抑制“图像到图像”的处理方法与生成对抗网络中的对抗学习机制, 使网络具备 CNN 网络的杂波抑制能力和优于 CNN 网络的稳定性, 为海杂波抑制问题提供了一种有效的算法。相较于传统算法, 该网络在信杂比较低的情况下仍能保证良好的杂波抑制效果, 具有良好的工程应用价值。该框架下生成的仿真杂波与真实杂波有较好的拟合效果, 为海杂波仿真提供了新思路。后续研究中可进一步开展对杂波抑制网络的约束设计, 以及在多目标

情况下对海杂波抑制效果的研究, 提高网络对不同目标模型的识别能力, 提高网络的泛用性。

参考文献:

- [1] JIANG Q, WU Y T, LIU W J, et al. Subspace-based distributed target detection in compound-Gaussian clutter[J]. Digital Signal Processing, 2023, 140: No.104141.
- [2] DAUM F. Radar handbook, 3rd edition (M.I. skolnik, Ed; 2008)(book review)[J]. IEEE Aerospace and Electronic Systems Magazine, 2008, 23(5): No.41.
- [3] 高增增. 海杂波仿真及抑制技术研究[D]. 西安电子科技大学, 2024: 1-105.
- [4] XING W G, LIU M C, GUI Y L, et al. Research on speed measurement in MTI radars[C]//Proceedings of the 2022 2nd International Conference on Computer Science, Electronic Information Engineering and Intelligent Control Technology. Piscataway, USA: IEEE, 2022: 237-241.
- [5] LI J N, LI Z Y, YANG Q, et al. Efficient matrix sparse recovery STAP method based on kronecker transform for BiSAR sea clutter suppression[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: No.5103218.
- [6] CUI W C, WANG T, WANG D G, et al. Robust SR-STAP algorithms in partly calibrated arrays for airborne radar[J]. Signal Processing, 2024, 219: No.109389.
- [7] QU Q Z, CHEN H, LIU W J, et al. Data-driven sea clutter suppression via an image-to-image neural network and consistency loss[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(3): 2819-2832.
- [8] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [9] FAN Y F, LI C X, LI D T, et al. A novel sea clutter suppression method based on neural network[C]//Proceedings of the 2021 IEEE 4th International Conference on Electronic Information and Communication Technology. Piscataway, USA: IEEE, 2021: 437-440.
- [10] ZHOU H Q, FENG X, DONG Z J, et al. Application of denoising CNN for noise suppression and weak signal extraction of lunar penetrating radar data[J]. Remote Sensing, 2021, 13(4): No.779.
- [11] 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.
- [12] 曹鹏宇, 杨承志, 石礼盟, 等. 基于 DAE-GAN 网络的 LPI 雷达信号增强[J]. 系统工程与电子技术, 2021, 43(9): 2493-2500.