

基于残差单元与注意力门的非对称编解码 海杂波抑制网络

陈胜垚¹, 胡晨康¹, 程智勇², 席 峰¹, 刘 中¹

(1. 南京理工大学电子工程与光电技术学院, 江苏南京 210094; 2. 巢湖学院计算机与人工智能学院, 安徽合肥 238024)

摘 要: 针对非均匀海杂波环境下弱小目标检测困难的问题, 本文基于复值残差单元和注意力门机制, 提出一种用于海杂波抑制的非对称编解码网络 (Asymmetric Encoder-Decoder Network, AED-Net)。该网络以雷达回波经匹配滤波后得到的复值信号为输入, 利用复值残差单元取代常规卷积单元进行弱小目标和海杂波特征的提取, 增强网络特征提取能力的同时避免特征信息退化。然后采用注意力门模块将编码路径各模块提取的特征信息分别送入到解码路径对应的模块。最终输出海杂波抑制后的复值信号。由于各注意力门的输入和输出维度可根据网络结构自主选择, 该网络设计是一种非对称编解码结构。与典型对称编解码网络 UNet 相比, 复值残差单元与注意力门的引入显著降低了特征信息的冗余度, 增强特征信息的提取与传递, 提升了海杂波抑制性能。与此同时, 复值残差单元的参数规模远小于卷积单元, 而注意力门的引入也有效减少了解码路径单元的数量, 整个网络的参数规模显著减小。基于海杂波实测数据的实验结果表明, 与典型复值 UNet (Complex Value-UNet, CV-UNet) 网络相比, AED-Net 的输出信杂比平均提升 9 dB, 有效工作的最低信杂比降低了 3 dB, 模型参数数量和计算量分别减少 57.8%、50%。

关键词: 海杂波抑制; 编解码网络; 残差结构; 注意力门; 复值信号

基金项目: 国家自然科学基金 (No.62171224)

中图分类号: TN957.51

文献标识码: A

文章编号: 0372-2112(2024)08-2628-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20231070

Residual Units and Attention Gates-Based Asymmetric Encoder-Decoder Network for Sea Clutter Suppression

CHEN Sheng-yao¹, HU Chen-kang¹, CHENG Zhi-yong², XI Feng¹, LIU Zhong¹

(1. School of Electronic and Optical Engineering, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;

2. School of Computer Science and Artificial Intelligence, University of Chaochu, Hefei, Anhui 238024, China)

Abstract: To address the challenge of weak target detection in nonhomogeneous sea clutter environments, this paper proposes an asymmetric encoder-decoder network (AED-Net) for sea clutter suppression based on complex-valued residual units and attention gates. The network takes the complex-valued signal generated by radar echoes passing through the matched filter as input. First, it replaces conventional convolutional units with complex-valued residual units to extract features of weak targets and sea clutter, enhancing the network's capability of feature extraction while avoiding feature degradation. Then, attention gate modules are employed to selectively propagate the feature information extracted by each module in the encoding path to the corresponding modules in the decoding path. Finally, it yields the complex signal after sea clutter suppression as output. Due to the capability of independently selecting the input and output dimensions of each attention gate according to the network structure, the proposed network has an asymmetric encoder-decoder structure. Compared to typical symmetric encoder-decoder network, UNet, the introduction of complex-valued residual units and attention gates significantly reduces the redundancy of feature information, enhances feature extraction and transmission, and thus improves the sea clutter suppression performance. Meanwhile, complex-valued residual units have much smaller parameter size than convolutional units and the introduced attention gates greatly reduce the number of units in the decoding path, resulting in a significant reduction of total network parameters. Experimental results based on real sea clutter data demonstrate that compared to the complex value-UNet (CV-UNet) network, AED-Net achieves an average improvement of 9 dB in the

output signal-to-clutter ratio (SCR) and can effectively operate at a minimum SCR reduction of 3 dB. Moreover, the number of parameters and the computational cost are reduced by 57.8% and 50%, respectively.

Key words: sea clutter suppression; encoder-decoder network; residual unit; attention gate; complex-valued signal
Foundation Item(s): National Natural Science Foundation of China (No.62171224)

1 引言

海杂波是雷达电磁波照射到海洋表面时接收到的海表面后向散射回波,具有较强的时间相关性,且呈现出复杂的“三非”特性(非平稳、非线性、非高斯)^[1].在雷达海面探测中,弱小海面目标很容易被海杂波淹没,导致其检测性能下降^[2].因此,如何有效抑制海杂波,提高弱小目标的探测性能,是雷达海面目标探测中亟待解决的问题.

在早期研究中,学者们聚焦于海杂波的变化规律,通过拟合海杂波数据建立统计模型,并设计相应的海杂波抑制方法.代表方法有奇异值分解^[3]、协方差矩阵估计^[4]、自适应匹配滤波器(Adaptive Matched Filter, AMF)^[5]等.这些方法的性能依赖于统计模型的准确性,而海杂波复杂多变的特点导致其统计模型与实际数据极易失配^[6],此时海杂波抑制效果急剧下降.基于时频变换和稀疏表示的海杂波抑制方法通过时频变换进行目标能量积累,提高目标的信杂比,并将杂波抑制问题转化为数学优化或稀疏重构,从而将目标与海杂波分离,代表方法有短时稀疏分数傅里叶变换(Short-Time Sparse FRactional Fourier Transform, ST-SFRFT)^[7]、可调 Q 因子小波变换(Tunable Q-factor Wavelet Transform, TQWT)^[8]、经验模态分解(Empirical Mode Decomposition, EMD)^[9]等.这些方法有效改善了海杂波环境下目标检测的准确度和稳定性,但在计算复杂度及实际工程应用方面有待进一步研究.

随着机器学习理论的快速发展,各类机器学习方法在雷达中得到广泛应用^[10].Callaghan 等人^[11]将海杂波抑制表示为海杂波及目标之间的分类问题,采用支持向量机(Support Vector Machine, SVM)和 k-最近邻算法有效解决该问题.Deng 等人^[12]根据海杂波和目标的特征差异,提出使用分层决策树结构判定海杂波子空间与目标子空间的超平面边界,实现对海杂波的抑制.这些方法属于浅层学习模型,其共同优点是结构简单,但表示能力有限,难以准确描述复杂时间序列形式的海杂波.

近年来,深度学习凭借强大的特征学习能力,可以从实际数据中直接学习,准确描述海杂波特征信息,被广泛用于雷达海面目标检测及其他相关领域.Wang 等人^[13]采用深度神经网络(Deep Neural Networks, DNN)检测器代替传统恒虚警率(Constant False-Alarm Rate, CFAR)检测器,获得了更好的目标检测性能.但该方法对目标信噪比(Signal-to-Noise Ratio, SNR)要求较高,且

未经过实际数据验证.苏宁远等人^[14]将雷达回波二维时频图输入卷积神经网络(Convolutional Neural Networks, CNN),有效实现目标和海杂波的分离,但在杂波多普勒较宽、信杂比(Signal-to-Clutter Ratio, SCR)较低时性能有待提高.Ding 等人^[15]基于回声状态网络(Echo State Network, ESN)构建了一种知识辅助的频域海杂波抑制方法,实现了慢速小目标的多普勒谱提取,但需要较多脉冲回波,且泛化性能有待检验.Wang 等人^[16]将复值信号引入到 UNet 中,提出复值 UNet(Complex Value-UNet, CV-UNet)网络来提取目标和海杂波的复信号特征,从而在高维特征空间区分两者,实现海杂波的抑制.针对雷达图像杂波抑制问题,牟效乾等人^[17]提出基于 INet 网络的导航雷达图像杂波抑制和海面目标检测方法,在检测概率方面取得提升.Hua 等人^[18]针对海杂波对 SAR 图像的影响,使用复值 UNet++(Complex Value-UNet++, CV-UNet++)网络提取 SAR 图像的幅度和相位信息,在充分保留目标信息的前提下提高海杂波抑制性能.

CV-UNet 和 CV-UNet++网络在海杂波抑制方面有明显的性能优势.但二者在低信杂比条件下的海杂波抑制性能依然不足,且网络结构存在冗余,参数规模和计算量均较大.本文针对 CV-UNet 网络在低信杂比条件下海杂波抑制性能下降、网络规模较大的问题,利用复值残差单元与注意力门机制对 CV-UNet 网络进行改造,提出一种非对称编解码网络(Asymmetric Encoder-Decoder Network, AED-Net).该网络的输入为海面目标雷达回波经匹配滤波后的信号,输出为海杂波抑制后的匹配滤波信号.与 CV-UNet 网络相比, AED-Net 使用复值残差单元取代普通卷积单元作为基础构成模块,利用注意力门处理编码路径提取的各浅层特征信息,注入到对应的解码路径单元.通过编、解码路径及跳跃连接路径可融合各复值残差单元提取的多层次特征,在高维特征空间中区分目标与海杂波,实现对海杂波的抑制.得益于注意力门输入和输出的可设计特性, AED-Net 编解码路径设计的自由度更大,突破了常规 UNet 结构中编解码路径对称的约束,呈现为非对称结构.在 AED-Net 中,复值残差单元将促进目标特征信息的提取与传递,而注意力门可对编码阶段浅层特征中的非目标信息进行有效抑制,二者共同作用,显著提升了网络的海杂波抑制性能.与此同时,残差结构允许输入数据有选择性地跳过部分层,减少基本网络单元的

参数量,而非对称网络结构减少了解码路径上的单元数.因此,AED-Net的参数规模相比于CV-UNet显著下降.本文基于实测海杂波数据,从SCR改善因子、消融实验、目标检测概率、真实目标回波海杂波抑制等方面开展实验,以检验AED-Net网络的海杂波抑制性能,通过泛化能力实验进一步验证网络的有效性,并分析了网络的时空规模.

2 海杂波抑制网络设计

本节基于复值残差单元和注意力门机制,提出一种如图1所示的非对称编解码网络,用于对海面雷达回

波匹配滤波后的数据进行海杂波抑制.该网络由编码路径和解码路径2部分组成,其中,注意力门左边部分网络为编码路径,右边部分网络为解码路径.AED-Net网络各层参数如表1所示,复值残差单元作为网络基本构成模块用于提取特征信息,增强网络的信息传递能力,保证网络训练不退化.注意力门对编码阶段浅层特征中的无关信息进行抑制,将其输入到对应的解码路径,在保留目标信息的同时有效抑制海杂波.复值残差单元与注意力门共同作用,可实现对海杂波抑制性能的提升,而残差单元本身的低参数量特性与AED-Net网络的非对称结构,可有效减小网络规模及参数量.

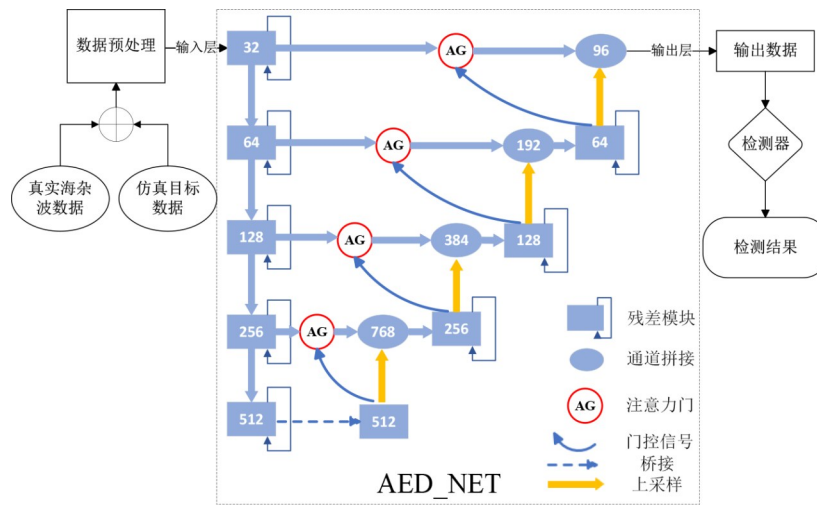


图1 AED-Net海杂波抑制网络

表1 训练参数网络各层参数及输出大小

层名称	复值残差单元	组成	输入通道,输出通道,卷积核大小,步长	输出大小(批次大小,通道数,信号长度)
输入层	—	—	—	8×1×10 500
编码路径	Res1	CV-Conv1	8, 32, 3, 1	8×32×10 500
		CV-Conv2	32, 32, 3, 1	8×32×10 500
	Res2	CV-Conv1	32, 64, 3, 2	8×64×5 250
		CV-Conv2	64, 64, 3, 1	8×64×5 250
	Res3	CV-Conv1	64, 128, 3, 2	8×128×2 626
		CV-Conv2	128, 128, 3, 1	8×128×2 626
	Res4	CV-Conv1	128, 256, 3, 2	8×256×1 314
		CV-Conv2	256, 256, 3, 1	8×256×1 314
	Res5	CV-Conv1	256, 512, 3, 2	8×512×658
		CV-Conv2	512, 512, 3, 1	8×512×658
桥接	上采样	—	—	8×512×1 314
解码路径	Res6	CV-Conv1	768, 256, 3, 1	8×256×1 314
		CV-Conv2	768, 256, 3, 1	8×256×1 314
	Res7	CV-Conv1	384, 128, 3, 1	8×128×2 626
		CV-Conv2	384, 128, 3, 1	8×128×2 626
	Res8	CV-Conv1	192, 64, 3, 1	8×64×5 250
		CV-Conv2	192, 64, 3, 1	8×64×5 250
输出层	Res9	CV-Conv1	96, 32, 3, 1	8×32×10 500
		CV-Conv2	32, 1, 3, 1	8×1×10 500

2.1 复值残差单元

随着网络中编码路径和解码路径的深入,常规卷积单元在提取特征信息过程中极易造成梯度消失,导致网络退化.为提升网络海杂波抑制性能,本文使用复值残差单元替代网络中的普通卷积单元来构建残差编解码网络.残差单元在网络中能在解决梯度消失问题的同时保留原始特征信息,这两者共同作用促进了特征信息的有效传递,增强网络的特征提取与表达能力^[19].

为克服随着网络加深带来的阻碍训练和特征退化,He 等人^[20]提出残差神经网络,由一系列堆叠的残差单元构成,每个残差单元一般表示为

$$y_l = h(x_l) + F(x_l, W_l) \quad (1)$$

$$x_{l+1} = f(y_l)$$

其中, x_l 和 x_{l+1} 是第 l 个残差单元的输入和输出; $F(\cdot)$ 和 $f(y_l)$ 分别是残差函数和激活函数,残差函数通常由多个卷积层组成,激活函数可设置为 Sigmoid、ReLU (Rectified Linear Unit) 函数等; $h(x_l)$ 是恒等映射函数,其表达式为

$$h(x_l) = x_l \quad (2)$$

图 2 给出了常规卷积单元和带有映射的复值残差单元的基本结构. CV-UNet 海杂波抑制网络采用图 2(a) 所示的常规卷积单元结构^[16]. 考虑实际接收到的目标回波为复值信号,海杂波和目标相位等特征的差异,本文将残差单元内的各构成部分进行复值化,构造的复值残差单元块包含多个复值批归一化 (Complex Value Batch Normalization, CV-BN)、复值 ReLU 激活函数和复数卷积层组合.

(1) 复值卷积

若复值卷积 (Complex Value Convolution, CV-Conv) 的输入复值数据为 \mathbf{P} , 则复值卷积的输出数据 \mathbf{O} 表示为

$$\begin{aligned} \mathbf{O} &= \mathbf{P} * \mathbf{W} \\ &= (\mathbf{R}(\mathbf{P}) * \mathbf{R}(\mathbf{W}) - \mathbf{I}(\mathbf{P}) * \mathbf{I}(\mathbf{W})) \\ &\quad + \mathbf{j}(\mathbf{R}(\mathbf{P}) * \mathbf{I}(\mathbf{W}) + \mathbf{I}(\mathbf{P}) * \mathbf{R}(\mathbf{W})) \end{aligned} \quad (3)$$

其中, \mathbf{W} 为复值卷积核, $*$ 为卷积运算, $\mathbf{R}(\cdot)$ 和 $\mathbf{I}(\cdot)$ 分别表示矩阵的实部和虚部.

(2) 复值批归一化算法

批归一化 (Batch Normalization, BN) 作为正则化方法,有效提高了网络收敛性并加快训练.首先通过归一化操作对输入数据 \mathbf{x} 进行处理,使输出数据 $\hat{\mathbf{x}}$ 具有标准正态分布^[21],即

$$\hat{\mathbf{x}} = \mathbf{V}^{-\frac{1}{2}} \left\{ \mathbf{x} - \left[(\mathbf{R}(\mathbf{x}) - E_r) + \mathbf{j}(\mathbf{I}(\mathbf{x}) - E_i) \right] \right\} \quad (4)$$

其中, E_r 和 E_i 分别是 \mathbf{x} 实部与虚部的均值, \mathbf{V} 是 \mathbf{x} 的协方差矩阵,定义如下:

$$\begin{aligned} \mathbf{V} &= \begin{bmatrix} \mathbf{V}_{rr} & \mathbf{V}_{ri} \\ \mathbf{V}_{ir} & \mathbf{V}_{ii} \end{bmatrix} \\ &= \begin{bmatrix} \text{Cov}(\mathbf{R}(\mathbf{x}), \mathbf{R}(\mathbf{x})) & \text{Cov}(\mathbf{R}(\mathbf{x}), \mathbf{I}(\mathbf{x})) \\ \text{Cov}(\mathbf{I}(\mathbf{x}), \mathbf{R}(\mathbf{x})) & \text{Cov}(\mathbf{I}(\mathbf{x}), \mathbf{I}(\mathbf{x})) \end{bmatrix} \end{aligned} \quad (5)$$

其中, $\text{Cov}(\cdot, \cdot)$ 为协方差函数.复值 BN 运算的输出为

$$\begin{bmatrix} \mathbf{R}(\hat{\mathbf{x}}) \\ \mathbf{I}(\hat{\mathbf{x}}) \end{bmatrix} = \gamma \begin{bmatrix} \mathbf{R}(\hat{\mathbf{x}}) \\ \mathbf{I}(\hat{\mathbf{x}}) \end{bmatrix} + \begin{bmatrix} \boldsymbol{\beta}_r \\ \boldsymbol{\beta}_i \end{bmatrix} \quad (6)$$

其中, $\boldsymbol{\beta}$ 是可训练的参数, γ 是含有 3 个可训练分量的半正定矩阵,可表示为

$$\gamma = \begin{bmatrix} \gamma_{rr} & \gamma_{ri} \\ \gamma_{ir} & \gamma_{ii} \end{bmatrix} \quad (7)$$

在网络训练时,将 γ_{rr} 和 γ_{ii} 初始化为 $\sqrt{2}/2$ 并设置 γ_{ri} 及 $\boldsymbol{\beta}$ 为 $\mathbf{0}$, 保证归一化后的方差模为 1.

(3) 复值激活函数

将复值 ReLU (Complex Value ReLU, CV-ReLU) 激活函数定义为分别将 ReLU 函数应用于参数的实部和虚部. CV-ReLU 激活函数可为网络提供更好的非线性映射能力,其定义为

$$\text{CV-ReLU}(\hat{\boldsymbol{\theta}}) = \text{ReLU}(\mathbf{R}(\hat{\boldsymbol{\theta}})) + \mathbf{j}\text{ReLU}(\mathbf{I}(\hat{\boldsymbol{\theta}})) \quad (8)$$

其中, $\text{ReLU}(\cdot)$ 为线性整流单元函数.

AED-Net 使用的复值残差单元由 2 个复值卷积块和 1 个恒等映射构成.每个卷积块包括复值 BN 层、复值 ReLU 激活层和复值卷积层,且单位映射连接单元的输入和输出.在前向传播中,残差结构的存在使浅层输出足够成熟,深层网络后续层实现恒等映射,允许网络学习到更复杂的特征,同时保持对特征信息的有效传递,解决传递过程中特征退化问题.其次,后向传播过程中引入残差映射后,网络对输出变化更敏感,当梯度

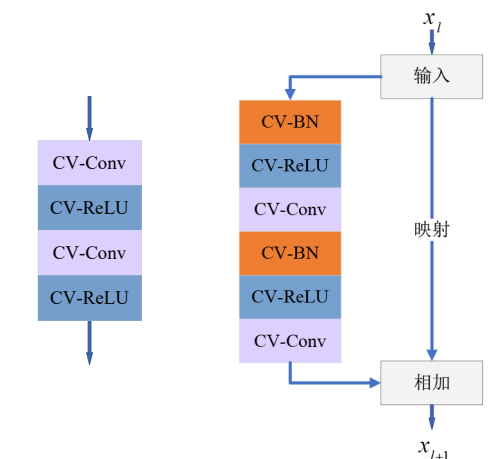


图 2 构建海杂波抑制深度神经网络的典型模块

图 2 构建海杂波抑制深度神经网络的典型模块

反向传播不仅能通过主路径传播,还能通过残差路径进行流动,缓解梯度消失和梯度爆炸问题,促进了网络训练.因此,残差结构对权重调整起到更大作用,有效提升网络性能.此外,残差结构使输入信息通过恒等映射有选择性跳过部分网络层,网络参数得以减少.

2.2 注意力门

2.1节中引入的复值残差单元可增强编码和解码路径中每层的特征提取能力,而残差传播与反馈只工作在层残差单元内,层间的每个解码和编码层只是简单相加,存在大量冗余信息.这些冗余特征信息并不能很好表示目标信号和海杂波之间的差异,为解决上述问题,本文在编码路径与解码路径之间的跳跃连接中引入了注意力门^[22],其原理如图3所示.注意力机制可以在网络的整体架构中结合上下文信息的机制,根据输入的全部特征对特征通道进行重新分配权重^[23].注意力机制的工作本质是通过附加权重实现对网络特征信息关注度的区分.

在图3中,门控信号 \mathbf{g} 包含编码阶段浅层网络的特征,输入信号 \mathbf{x} 包含解码阶段上1层采样后的特征,两者共同输入注意力门进行计算.注意力门根据输入信号 \mathbf{g} 和 \mathbf{x} 产生注意力系数 α (α 的每个元素在 $[0, 1]$ 范围内),并利用 α 对输入特征信号 \mathbf{x} 进行缩放,得到最终与目标相关的特征信号 $\tilde{\mathbf{x}}$. q_{att} 和 α 的计算如式(9)^[24]




图3 注意力门原理示意图

在AED-Net中,每个注意力门以同层编码路径信号作为输入,以深层解码路径信号作为门控信号.因此,每个注意力门汇集了多个尺度的特征信息,可自适应地提升目标潜在区域的网格分辨率,增强目标特征信息的提取和非目标区域的海杂波抑制.

2.3 网络结构

本文采用1个5层的编-解码架构进行非均匀海杂波抑制,如图1所示.该网络由编码、桥接和解码3部分构成,其中,编码和解码部分实现输入信号特征提取与海杂波抑制,桥接部分是连接编码和解码路径的桥梁.最后,网络通过解码路径输出恢复信号,编码和解码部分均由复值残差单元构建.

编码路径包含5个复值残差单元,在每个单元中,不使用池化操作来降低特征图的大小,而是在复值残差单元第1个卷积块上设置步长减少特征图尺寸.编码路径通过桥接路径通往解码路径,桥接路径采用复

所示:

$$q_{\text{att}} = \psi^T \left(\text{CV-ReLU} \left(\mathbf{W}_x^T \mathbf{x} + \mathbf{W}_g^T \mathbf{g} + b_g \right) \right) + b_\psi \quad (9)$$

$$\alpha = \text{Sigmoid} \left(q_{\text{att}} \right)$$

其中, ψ 、 \mathbf{W}_x 、 \mathbf{W}_g 为复值卷积单元; b_g 和 b_ψ 为卷积运算中的偏置项参数,卷积运算中引入的偏置项能够作为可调整的参数提供额外的学习自由度.由于输入信号 \mathbf{x} 和门控信号 \mathbf{g} 分别来自解码路径和对应编码路径的跳跃连接,二者的通道数通常不一致.利用 \mathbf{W}_x 和 \mathbf{W}_g 将 \mathbf{g} 和 \mathbf{x} 的通道数统一,实现特征信息的融合.通过CV-ReLU单元增加注意力门的非线性特性,可增强网络的表达能力,利用复值卷积单元 ψ 将信号通道数降为1,生成 q_{att} .最后,通过Sigmoid函数将 q_{att} 映射至 $[0, 1]$ 范围内,得到注意力系数 α .Sigmoid函数的具体表达式为

$$\text{Sigmoid} (q) = \frac{1}{1 + \exp(-q)} \quad (10)$$

在浅层特征中并非所有信息都对网络任务有贡献.由于浅层特征信号中非目标区域的海杂波信息过多,注意力门通过分析输入的门控信号 \mathbf{g} 和上下层信息筛选出目标可能存在的区域,减少非目标区域的海杂波特征信息.将注意力系数 α 与输入的 \mathbf{x} 相乘得到新的 $\tilde{\mathbf{x}}$,仅需增加少量计算量即可减轻解码路径中的海杂波抑制负担.

值残差单元对信号尺寸进行上采样.网络右侧解码路径由3个复值残差单元构成,在每个单元之前,来自编码路径的特征信息通过注意力门与来自较低层次特征信息的上采样相连接.在最后一级解码路径后,输出层采用复值残差单元将信号通道数降为1,将信号还原.

跳跃连接中引入的注意力门其输入和输出维度可根据网络结构自主设定,跳跃连接2端的通道数无须相等,因此,AED-Net网络呈现为非对称结构.跳跃连接右侧对应的编码路径单元数得以减少,降低了网络参数规模.

AED-Net结合了编解码网络和残差神经网络的优点,引进注意力门模块.这样的组合带来2个好处:(1)复值残差单元内部的映射连接与网络编解码路径之间融合注意力门的跳跃连接可共同促进信号特征信息的提取与传递效率,显著提升网络海杂波抑制性能;

(2) 非对称结构和复值残差单元有效减少了模型参数量,且复值残差单元允许跨层直接传递信息,有助于加速训练收敛,简化网络训练。

3 实验与分析

本节对所设计的 AED-Net 进行性能验证。首先介绍数据集构建方式、网络训练方法和性能评价指标,基于实际海杂波数据对所提出的 AED-Net 网络的海杂波抑制性能进行验证,并与典型海杂波抑制网络进行对比。最后,开展消融实验及鲁棒性实验评估网络有效性,分析网络的时空规模。

检测性能实验中 AED-Net 输出后添加的检测器使用单元平均 CFAR (Cell Averaging-CFAR, CA-CFAR)^[25],雷达信号的检测性能由其检测概率 P_d 和虚警概率 P_f 来描述。当雷达回波匹配滤波后的数据为 $x_1, \dots, x_p, \dots, x_K$,通过门限比较判断待测单元 x_i 是否含有目标,过程如下:

选取目标单元附近的 P 个参考单元,根据 P 个参考单元估计背景功率:

$$1/P \sum_{p=1}^P |x_p|^2 \quad (11)$$

计算检测门限 η :

$$\eta = (P_f^{-1/P} - 1) \sum_{p=1}^P |x_p|^2 \quad (12)$$

其中, P_f 为预设的虚警概率。

将目标单元 x_i 与检测门限进行比较,超过门限判定为有目标 (H_1),否则判定为无目标 (H_0)。

3.1 数据集构建

深度学习模型的性能和有效性依赖于训练样本的数量和质量,因此,本文直接采用实测海杂波数据进行网络训练和测试。针对雷达照射区域内难以获得大量具有标签的合作目标样本问题,本文通过在实测海杂波中加入不同 SCR 的仿真目标构造训练集和测试集,其中,SCR 是指雷达回波经脉冲压缩后的 SCR。

本文采用海军航空大学刘宁波等人^[26-28]发起的“雷达对海探测数据共享计划”,利用 X 波段固态全相参雷达采集的对海探测数据集,获取的实测海杂波数据的雷达参数如表 2 所示,模拟目标信号的参数与雷达参数相同。选取 2019 年采集的扫描雷达纯海杂波“20191012110708_02_scanning”作为背景海杂波数据集,由于实测回波数据存在地杂波干扰,在对回波数据进行角度屏蔽处理后将仿真目标信号随机添加到每个脉冲中,共构成 4 076 个训练样本。SCR 的具体定义如下:

$$SCR = 10 \log_{10} \frac{P_t}{P_c} \quad (13)$$

其中, P_t 表示目标信号的功率, P_c 表示海杂波信号的功率。本文中海杂波功率 P_c 计算参考目标所在的距离单元附近的海杂波平均功率。对于 1 个目标所在的距离单元,设置其保护单元为 4,参考单元为 24,计算参考单元的海杂波平均功率。

表 2 X 波段雷达参数

技术参数	属性值
频率范围/GHz	9.3~9.5
扫描带宽/MHz	25
脉冲重复频率/kHz	1.6, 3, 5, 10
发射峰值功率/W	50
距离分辨率/m	6
天线工作模式	凝视、圆周扫视

在训练集构建时,本文将脉冲压缩后 SCR 为 5~14 dB 的模拟目标加入到 4 076 个脉冲中,在每个脉冲中随机选择模拟目标的位置。由该数据集训练的模型可以学习不同方位、距离单元下目标与海杂波特性的差异。测试集使用与训练集数据同一批次不同扫描圈数的编号“20191012110757_19_scanning”数据构建。测试集所用雷达回波数据集的距离-方位二维图如图 4(a) 所示,输入数据示例如图 4(b) 所示。

对于训练集数据的标签设计,本文没有采用基于二分类的“0-1”标签,而是采用理想情况下目标脉压后数据作为训练标签,因为二分类标签更适合目标定位情形,而实际脉压数据作为标签训练可以更好地分析模型海杂波抑制能力。1 个实例标签数据如图 4(c) 所示,图 4(d) 展示了经过海杂波抑制后输出信号的归一化幅度图。

3.2 模型训练

本文模型基于 Pytorch 框架实现,所有实验在 1 台搭载 GeForce GTX3090 (24 GB) 显卡的工作站上进行。其余各项训练及仿真实验的相关参数如表 3 所示。

网络采用交叉熵损失函数 (cross entropy loss) 作为训练的损失函数,并采用 Adam 优化器来优化训练。Adam 优化器结合了动量梯度下降和自适应学习率的特点,可有效加速模型收敛并提高训练效率。

对于单个训练脉冲数据 D ,本文采用式 (14) 对其进行归一化预处理,由此将所有训练数据归一化至统一幅度范围,随后送入网络进行训练:

$$d_i = \frac{d_i - \min(D)}{\max(D) - \min(D)} \quad (14)$$

其中, d_i 为 D 中第 i 个距离单元的幅度值, $\max(D)$ 和 $\min(D)$ 分别为 D 中最大幅度值和最小幅度值。

3.3 评价指标

为了验证网络模型对海杂波抑制性能,本文提出

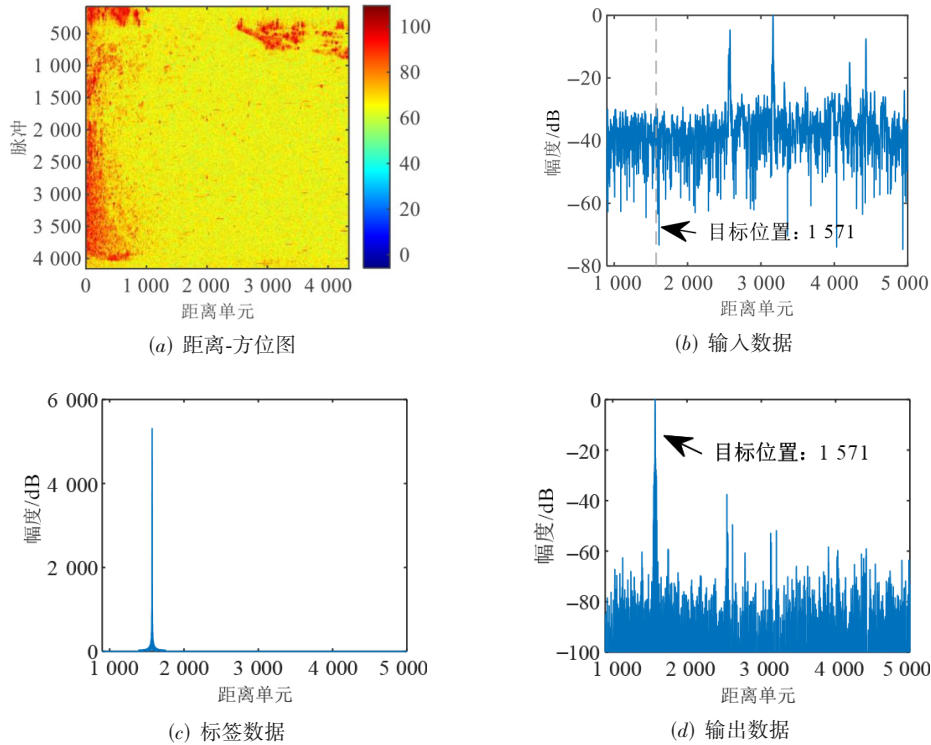


图4 测试集和测试样本示意图

表3 训练参数

相关参数	具体值
训练轮次	100
初始学习率	0.01
优化器及相应参数	Adam(0.9, 0.99, 1×10^{-8})
训练批次大小	16

平均信杂比改善因子 α_{SCR} , 其定义为

$$\alpha_{SCR} = \frac{\sum_{i=1}^N SCR_{out,i} - SCR_{in,i}}{N} \quad (15)$$

其中, N 为海杂波抑制实验次数, $SCR_{in,i}$ 和 $SCR_{out,i}$ 分别为第 i 次实验中原始输入数据及网络输出数据的信杂比. 将信杂比改善因子作为网络模型抑制海杂波性能的直观指标.

3.4 实验结果

3.4.1 信杂比改善实验

为了验证 AED-Net 网络模型的海杂波抑制性能, 将 AED-Net 与 CV-UNet^[16] 及 CV-UNet++^[18] 进行性能对比实验. 在不同输入 SCR 情形下测试 3 种网络的海杂波抑制性能, 每轮实验选取 1 000 个方位回波数据输入网络模型, 3 个网络的训练数据和初始参数均设置相同.

图 5(a) 给出了不同网络的 SCR 改善因子随 SCR 的

变化情况. 可以看出, AED-Net 显著提升了海杂波抑制性能. 在 SCR=2 dB 时, 与 CV-UNet 和 CV-UNet++ 相比, AED-Net 的信杂比改善因子分别提升了 33.5% 和 19%. 在 SCR \in [-6, 10] dB 范围内, 与 CV-UNet 和 CV-UNet++ 相比, AED-Net 的 SCR 改善因子分别平均提升 9 dB 和 7 dB 以上.

在 SCR=0 dB 时, CV-UNet 和 CV-UNet++ 的 SCR 改善因子仍然有 20 dB 左右, 但此时输出数据中目标的距离单元发生偏移, 目标位置估计不正确, 此时可认为网络失效. 如图 5(c) 和图 5(d) 所示, SCR=0 dB 时真实目标位于第 1 301 距离单元, 而 CV-UNet 和 CV-UNet++ 的输出结果中目标分别偏移至第 1 303 和第 1 304 距离单元. 在图 5(b) 给出的 AED-Net 输出结果中, 目标依然位于第 1 301 距离单元. 表 4 给出了不同输入 SCR 下各网络输出中目标位于真实距离单元位置处的准确率, 即网络有效工作的概率. 可以看出, 当 SCR \leq 0 dB 时, CV-UNet 和 CV-UNet++ 网络的目标位置估计准确率显著下降, 即网络开始失效. 而当 SCR \leq -3 dB 时, AED-Net 网络才开始失效. 与 CV-UNet 相比, AED-Net 能够有效工作的最低 SCR 降低了 3 dB. 显然, AED-Net 在低 SCR 场景下的海杂波抑制性能优于 CV-UNet 和 CV-UNet++ 网络.

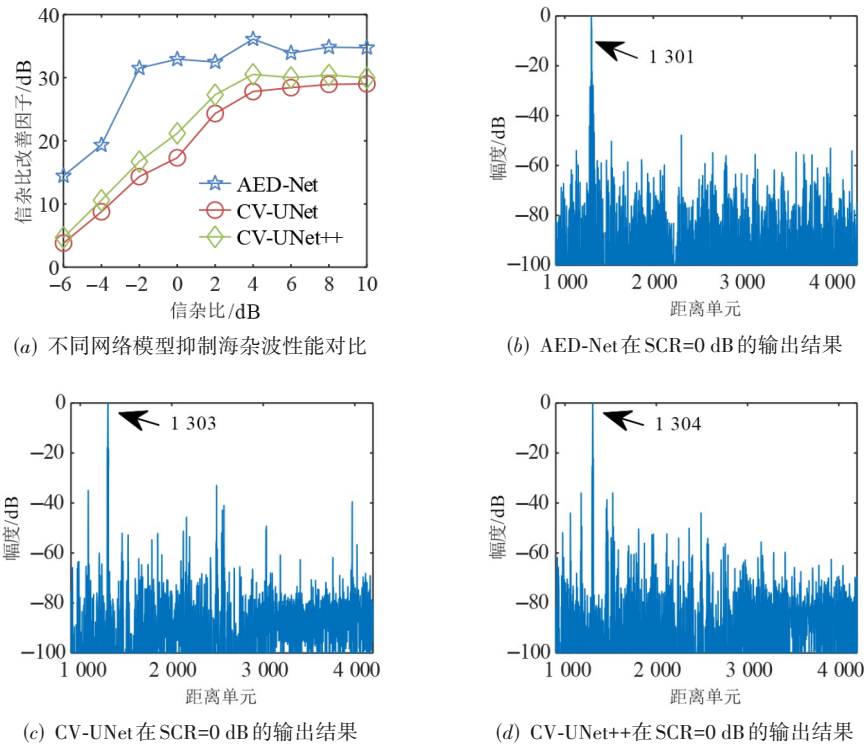


图5 信杂比改善实验

表4 各网络输出目标距离单元估计准确率

单位:%

输入 SCR 网络名称	-5 dB	-4 dB	-3 dB	-2 dB	-1 dB	0 dB	1 dB	2 dB
AED-Net	54	67	81	98	100	100	100	100
CV-UNet	24	41	55	70	77	91	96	99
CV-UNet++	26	44	61	75	80	93	98	100

3.4.2 消融实验

为了验证 AED-Net 的有效性及其合理性,设计消融实验进行验证. 在 AED-Net 基础上分别只保留复值残差单元模块和注意力门模块,与 CV-UNet、CV-UNet++ 及 AED-Net 进行性能参照对比. 由图 6 可知,复值残差单元的引入大幅度提升了网络的海杂波抑制性能,而注意力门模块对性能提升的作用相对较小. 该结果表明,引入复值残差单元增强 AED-Net 的特征提取与表达能力,从而提升其海杂波抑制性能的思路是正确的. 当 SCR=2 dB,与 CV-UNet 相比,网络分别只保留复值残差单元和注意力门模块时,SCR 改善因子分别提升了 23.4% 和 13.5%;而网络同时使用 2 个模块时,SCR 改善因子提升了 33.5%. 在 AED-Net 中,每个模块的引入都对海杂波抑制性能的提升有所帮助,两者共同作用提供了更好的性能.

3.4.3 目标检测概率实验

将 AED-Net 与 CV-UNet^[16]、DNN^[13]、分数阶 Fourier 变换方法(Fractional Fourier Transform, FRFT)^[29]以及经典 CA-CFAR 检测器^[25]进行比较以进一步验证 AED-Net 的目标检测性能,结果如图 7 所示. 其中,CA-CFAR 检

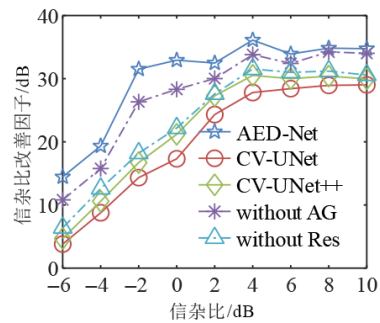
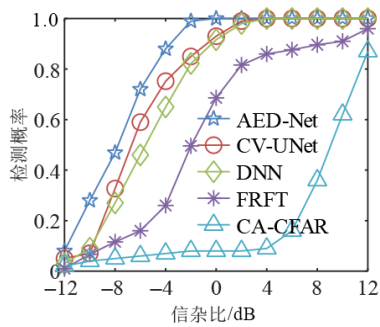


图6 消融实验结果图

测器的实验结果作为未对输入信号进行海杂波抑制的检测性能对照. 对于各海杂波抑制方法,选取输出信号中目标单元附近的参考单元并估计背景功率,将实验所设虚警概率代入式(12)得到检测门限. 与其他方法相比,在 SCR ≤ 0 dB 时,AED-Net 显著提升了目标的检测性能. 当 SCR = -2 dB 时,AED-Net 的检测概率为 99.3%,与 CV-UNet 相比,AED-Net 的检测概率提升了 16.5%.

3.4.4 真实目标实验

本小节首先选取海军航空大学于 2021 年获取的凝

图7 虚警概率为 10^{-4} 时检测概率对比图

视模式下海杂波加目标数据“20210104163843_01_starting”作为实验数据,测试 AED-Net 对真实目标的海杂波抑制效果. 根据海军航空大学发布的描述信息,该编号数据采集于 2 级海况条件下,包含 1 个合作目标的回波,即 3.86 km 处有 1 个目标(船),大致位于第 1 400 距

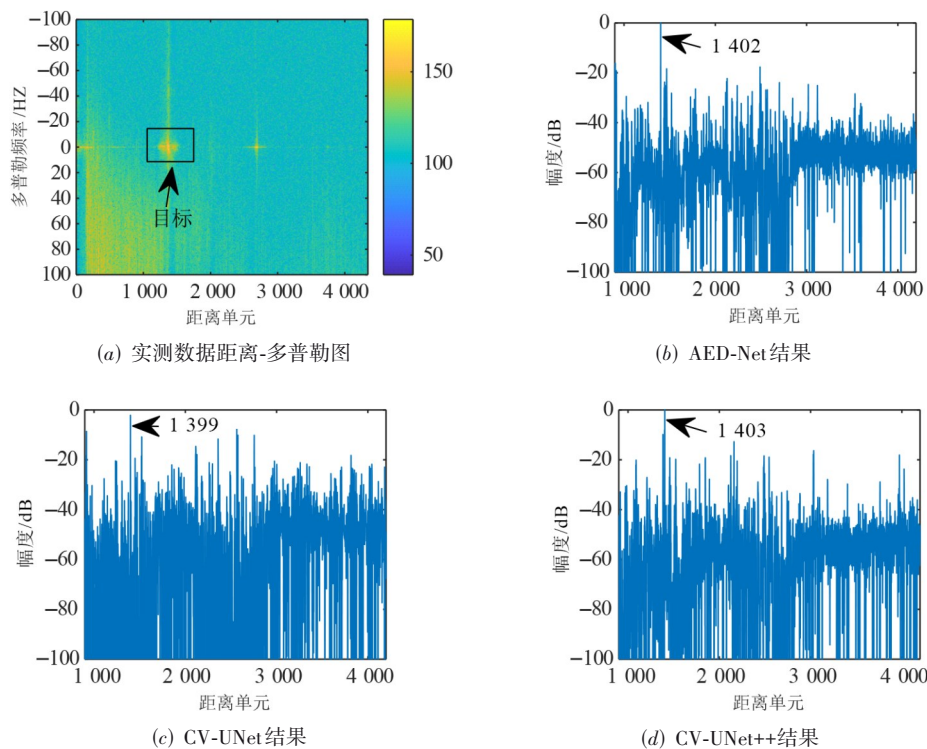


图8 实测目标数据实验结果

在真实海洋环境中,海况是持续变化的. 为了评估 AED-Net 在不同海况下对实测数据中合作目标海杂波的抑制效果,本节接下来采用了“20210106172511_02_starting”数据集进行海况条件变化下的对比试验. 这批数据同样包括海杂波和目标信号,根据其描述信息,该数据采集于更高的 3~4 级海况条件下,其中记录了 2 个合作目标的回波信号:分

别位于 2.81 km 和 4.16 km 处的 2 艘船只,且 5.5 km 后为岛屿回波.

图 8(a) 给出了该编号数据的距离-多普勒图及目标位置,图 8(b)~(d) 分别展示了 AED-Net、CV-UNet 和 CV-UNet++ 处理该实际目标 1 个脉冲雷达回波数据后的输出. 可以看出, AED-Net 有效抑制了目标周围的海杂波,而 CV-UNet 和 CV-UNet++ 的输出结果中目标周围仍然剩余较多的海杂波. 利用 3 个网络对多个脉冲的输出数据进行目标检测,当虚警概率为 10^{-4} 时,检测概率分别为 95%、79% 和 86%. 应当指出,真实目标经 AED-Net 抑制海杂波后目标位置发生了一定偏移,这主要是因为目标散射特性与理想点目标存在较大误差. 因此,需要让 AED-Net 网络学习实际目标的散射特性信息,使用更多实际目标回波数据进行网络训练,避免真实目标位置发生偏移.

图 9(a) 展示了该编号数据的距离-多普勒图,并标出了目标位置,图 9(b)~(d) 依次展示了 AED-Net、CV-UNet 和 CV-UNet++ 进行海杂波抑制后的输出. 利用 3 个网络对多个脉冲的输出数据进行目标检测,当虚警概率为 10^{-4} 时,检测概率分别为 89%、72% 和 80%. 观察结

果表明,随着海况的增强,各网络输出中的海杂波强度相应提升,这对雷达的检测性能产生了明显影响.但在

更高海况下,AED-Net 依然表现出很好的海杂波抑制能力.

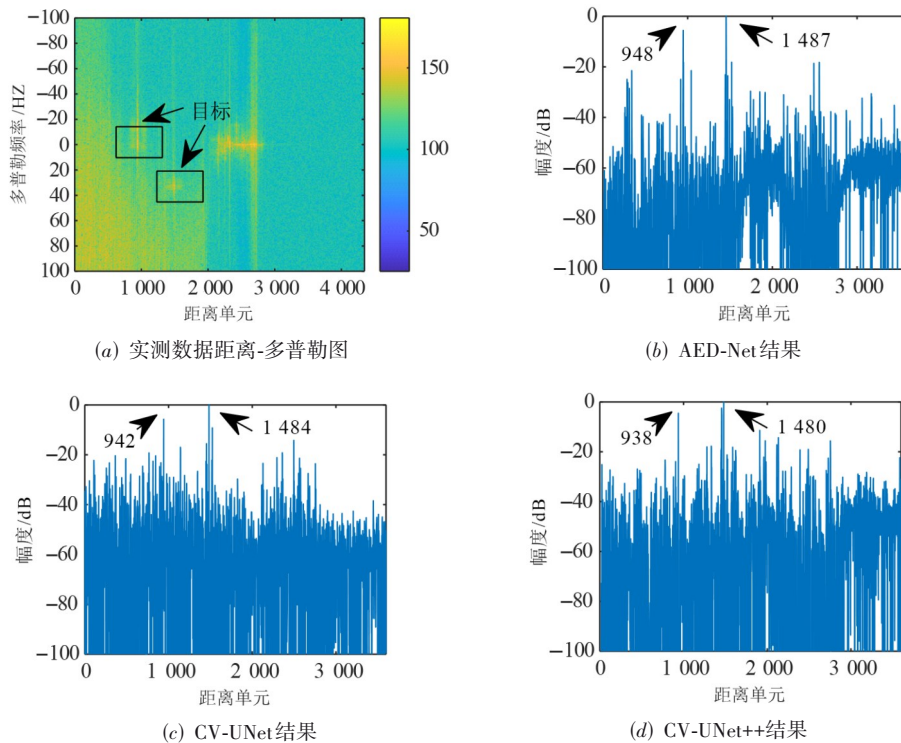


图9 高海况下实测目标数据实验结果

3.4.5 泛化能力实验

本节测试 AED-Net 的泛化性能,基于本文网络训练所使用的单目标回波数据对多目标情形下海杂波抑制效果进行实验.如图 10(a)所示,实验过程中在随机选取的单雷达脉冲海杂波数据中加入 4 个雷达目标,每个目标所在距离单元通过均匀分布随机生成,对应的距离单元分别为 1 013、2 021、3 432 和 4 267,4 个目标的 SCR 按照由近到远的顺序分别设置为 1 dB、

2 dB、3 dB 和 4 dB. 将多目标回波数据输入 AED-Net,获得输出抑制结果如图 10(b)所示.可以看出,4 个目标均在正确的距离单元位置处显示出来,对应的目标归一化幅度分别为 -0.106 dB、0、-0.013 dB 和 -0.086 dB.但由于 AED-Net 的非线性处理特征,不同目标之间的相对幅度关系无法保留.显然,当多个目标存在时,AED-Net 仍然展现出明显的杂波抑制效果,表明 AED-Net 网络具有良好泛化能力.通过 100 次独立实验发现,4 个目标的 SCR 可平均增强达 34 dB.




图10 多个目标情形 AED-Net 网络泛化能力实验结果

3.4.6 网络参数量及FLOPs对比

表5为3种网络模型的参数量、浮点运算次数(Floating-point Operations, FLOPs)及训练时间的对比. 参数量是指模型训练中需要训练的参数总数,其大小直接体现了模型的大小及计算空间复杂度,浮点运算次数可用来衡量网络模型的计算时间复杂度. 对于单一网络模型,参数量与模型的输入无关,只取决于网络结构,而计算量则与输入数据的大小有关. 表5中的参数量和计算量均由PyTorch-OpCounter工具包测量得到. 当输入数据大小相同时,AED-Net参数量比CV-UNet减少了57.8%,浮点运算次数减少了约50%,训练时间也有一定减少. 实验结果表明,得益于残差单元允许跨层传递信息等特性以及网络的非对称结构,AED-Net显著简化了网络规模,网络计算量也大大降低.

表5 不同网络模型的参数量与计算量

网络参数	参数量/MB	计算量/FLOPs	平均每轮训练时间/s
CV-UNet	20.95	204 181.68 M	117
CV-UNet++	25.95	305 671.66 M	139
AED-Net	8.65	98 002.57 M	96

4 结论

针对CV-UNet海杂波抑制网络在低信杂比场景下性能不佳和网络参数规模大的问题,本文基于复值残差单元和注意力门机制,提出非对称编解码AED-Net网络. 该网络以雷达回波匹配滤波后的复值信号作为输入数据,引入复值残差单元促进网络的特征提取与传递,显著提升了海杂波抑制性能,通过在跳跃连接中引入注意力门抑制了浅层特征中的冗余信息,并有效减少网络参数规模. 基于实测海杂波数据的各项实验结果表明,与CV-UNet相比,本文提出AED-Net的SCR改善因子平均提升9 dB,网络可有效进行海杂波抑制的最小输入SCR降低3 dB,模型参数量减少57.8%,计算量减少50%,训练时间也相应减少,且显示了良好的泛化能力. 后续工作将加入更多不同类型的真实目标数据进行训练,以减小目标散射特性对海杂波抑制性能的影响. 网络设计中引入目标散射特性模型先验知识,基于深层展开或即插即用网络等技术,发展模型与数据混合驱动的海杂波抑制网络. 另一方面,将进一步探索网络结构的优化设计,以获得更好的非均匀海杂波抑制性能和轻量化网络,消除网络输入信号的归一化预处理限制,体现目标信号强度对海杂波抑制性能的影响.

参考文献

- [1] 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.
DING H, DONG Y L, LIU N B, et al. Overview and prospects of research on sea clutter property cognition[J]. Journal of Radars, 2016, 5(5): 499-516. (in Chinese)
- [2] ZHAO W J, JIN M L, CUI G L, et al. Eigenvalues-based detector design for radar small floating target detection in sea clutter[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 3509105.
- [3] SUN Z, CHEN H X, LI X L, et al. Airborne radar coherent integration and sea-clutter suppression method for marine moving target via TSLRT-MFP-SVD[C]//IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2022: 3724-3727.
- [4] XU S W, WANG Z X, BAI X H, et al. Optimum and near-optimum coherent CFAR detection of radar targets in compound-gaussian clutter with generalized inverse Gaussian texture[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(3): 1692-1706.
- [5] ROBEY F C, FUHRMANN D R, KELLY E J, et al. A CFAR adaptive matched filter detector[J]. IEEE Transactions on Aerospace and Electronic Systems, 1992, 28(1): 208-216.
- [6] XUE J, XU S W, LIU J. Persymmetric detection of radar targets in nonhomogeneous and non-gaussian sea clutter[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5103709.
- [7] 陈小龙,关键,于晓涵,等. 雷达动目标短时稀疏分数阶傅里叶变换域检测方法[J]. 电子学报, 2017, 45(12): 3030-3036.
CHEN X L, GUAN J, YU X H, et al. Radar detection for moving target in short-time sparse fractional Fourier transform domain[J]. Acta Electronica Sinica, 2017, 45(12): 3030-3036. (in Chinese)
- [8] PAN M Y, SUN J, YANG Y H, et al. Improved TQWT for marine moving target detection[J]. Journal of Systems Engineering and Electronics, 2020, 31(3): 470-481.
- [9] ZHANG K Y, HE W, LIU L N, et al. Sea clutter denoising based on complete ensemble empirical mode decomposition[C]//2022 4th International Conference on Natural Language Processing (ICNLP). Piscataway: IEEE, 2022: 282-286.
- [10] MOUNTRAKIS G, IM J, OGOLE C. Support vector ma-

- chines in remote sensing: A review[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011, 66(3): 247-259.
- [11] CALLAGHAN D, BURGER J, MISHRA A K. A machine learning approach to radar sea clutter suppression[C]//2017 IEEE Radar Conference (RadarConf). Piscataway: IEEE, 2017: 1222-1227.
- [12] DENG H, GENG Z, HIMED B. Radar target detection using target features and artificial intelligence[C]//2018 International Conference on Radar. Piscataway: IEEE, 2018: 1-4.
- [13] WANG L, TANG J, LIAO Q M. A study on radar target detection based on deep neural networks[J]. *IEEE Sensors Letters*, 2019, 3(3): 7000504.
- [14] 苏宁远, 陈小龙, 关键, 等. 基于卷积神经网络的海上微动目标检测与分类方法[J]. *雷达学报*, 2018, 7(5): 565-574.
SU N Y, CHEN X L, GUAN J, et al. Detection and classification of maritime target with micro-motion based on CNNs[J]. *Journal of Radars*, 2018, 7(5): 565-574. (in Chinese)
- [15] DING J F, WU H Q, WANG Z H, et al. Knowledge-aided sea clutter suppression based on echo state network[C]//2023 IEEE Radar Conference (RadarConf23). Piscataway: IEEE, 2023: 1-6.
- [16] WANG Y M, ZHAO W J, WANG X, et al. Nonhomogeneous sea clutter suppression using complex-valued U-net model[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4027705.
- [17] 牟效乾, 陈小龙, 关键, 等. 基于INet的雷达图像杂波抑制和目标检测方法[J]. *雷达学报*, 2020, 9(4): 640-653.
MOU X Q, CHEN X L, GUAN J, et al. Clutter suppression and marine target detection for radar images based on INet[J]. *Journal of Radars*, 2020, 9(4): 640-653. (in Chinese)
- [18] HUA Q L, YUN Z, MU H L, et al. An approach of sea clutter suppression for SAR images by self-supervised complex-valued deep learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4512505.
- [19] 周涛, 霍兵强, 陆惠玲, 等. 残差神经网络及其在医学图像处理中的应用研究[J]. *电子学报*, 2020, 48(7): 1436-1447.
ZHOU T, HUO B Q, LU H L, et al. Research on residual neural network and its application on medical image processing[J]. *Acta Electronica Sinica*, 2020, 48(7): 1436-1447. (in Chinese)
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.
- [21] TRABELSI C, BILANIUK O, ZHANG Y, et al. Deep complex networks[EB/OL]. (2017-05-27) [2023-10-11]. <http://arxiv.org/abs/1705.09792>.
- [22] JIANG W T, LI X Y, HU H F, et al. Multi-gate attention network for image captioning[J]. *IEEE Access*, 2021, 9: 69700-69709.
- [23] ZHU Y, LI R, TENG S H, et al. Multi-attention gate based U-net for retinal vessel segmentation[C]//2022 12th International Conference on Information Technology in Medicine and Education (ITME). Piscataway: IEEE, 2022: 302-306.
- [24] OKTAY O, SCHLEMPER J, LE FOLGOC L, et al. Attention U-net: Learning where to look for the pancreas[EB/OL]. (2018-04-11)[2023-10-11]. <http://arxiv.org/abs/1804.03999>.
- [25] 何友. 雷达目标检测与恒虚警处理(3版)[M]. 北京: 清华大学出版社, 2023.
HE Y. Radar target detection and CFAR processing (3rd)[M]. Beijing: Tsinghua University Press, 2023. (in Chinese)
- [26] 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. Sea-detecting X-band radar and data acquisition program[J]. *Journal of Radars*, 2019, 8(5): 656-667. (in Chinese)
- [27] 刘宁波, 丁昊, 黄勇, 等. X波段雷达对海探测试验与数据获取年度进展[J]. *雷达学报*, 2021, 10(1): 173-182.
LIU N B, DING H, HUANG Y, et al. Annual progress of the sea-detecting X-band radar and data acquisition program[J]. *Journal of Radars*, 2021, 10(1): 173-182. (in Chinese)
- [28] 关键, 刘宁波, 王国庆, 等. 雷达对海探测试验与目标特性数据获取: 海上目标双极化多海况散射特性数据集[J]. *雷达学报*, 2023, 12(2): 456-469.
GUAN J, LIU N B, WANG G Q, et al. Sea-detecting radar experiment and target feature data acquisition for dual polarization multistate scattering dataset of marine targets[J]. *Journal of Radars*, 2023, 12(2): 456-469. (in Chinese)
- [29] BI X W, GUO S L, YANG Y X, et al. Adaptive target ex-

traction method in sea clutter based on fractional Fourier filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5115609.

作者简介



陈胜焱 男,1985年10月生,安徽庐江人.南京理工大学副教授、硕士生导师.主要研究方向为雷达信号处理、阵列信号处理、压缩感知、凸优化和可重构智能超表面.
E-mail: chenshengyao@njjust.edu.cn



胡晨康 男,1999年10月生,安徽当涂人.南京理工大学电子工程与光电技术学院硕士研究生.主要研究方向为雷达信号处理、深度学习.
E-mail: huchenkang@njjust.edu.cn



程智勇 男,1989年10月生,山东济宁人.巢湖学院计算机与人工智能学院讲师.主要研究方向为阵列信号处理、雷达信号处理和非线性优化.
E-mail: chengzhiyong@njjust.edu.cn



席峰 男,1980年11月生,江苏宜兴人.南京理工大学副教授、硕士生导师.主要研究方向为雷达信号处理、统计和阵列信号处理、压缩感知、凸优化.
E-mail: xifeng@njjust.edu.cn



刘中 男,1963年8月生,安徽灵璧人.南京理工大学教授、博士生导师.主要研究方向为信号采样与处理、雷达信号处理、深度学习等.中国电子学会会员编号:E190011293S.
E-mail: eezliu@njjust.edu.cn