

基于最小熵准则与生成对抗网络的 SAR 三维 转动舰船目标重聚焦方法

化青龙, 张 云*, 任 航, 姜义成, 徐 丹

(哈尔滨工业大学电子与信息工程学院, 黑龙江哈尔滨 150001)

摘 要: 在合成孔径雷达(Synthetic Aperture Radar, SAR)系统中, 舰船目标在中高海情下的三维转动会导致多普勒频谱时变和图像散焦, 并对后续 SAR 舰船目标的信息解释造成不利影响. 针对三维转动舰船目标的重聚焦问题, 本文提出一种基于最小熵准则与生成对抗网络的 SAR 三维转动舰船目标重聚焦方法, 设计了生成器和判别器的网络结构. 生成器将散焦 SAR 舰船复图像变换到距离-多普勒域, 利用相位误差系数估计网络逐距离单元估计相位误差系数, 并实现对多阶次相位误差的补偿. 判别器由一个复数域卷积神经网络构成, 其所有元素, 包括卷积层、激活函数、特征图和网络参数, 均被扩展到复数域. 损失函数中引入最小熵准则和对抗损失进行无监督训练, 避免非合作舰船目标标注样本难以获取的问题. 在仿真数据和高分三号 SAR 数据上的实验表明, 该方法在重聚焦精度和效率上均有显著提升.

关键词: 合成孔径雷达; 生成对抗网络; 舰船目标; 重聚焦; 最小熵准则

基金项目: 国家自然科学基金(No.61971163); 中央高校基本科研业务费专项资金资助项目(No.HIT.DZJJ.2023032)

中图分类号: TP751

文献标识码: A

文章编号: 0372-2112(2024)08-2900-13

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

DOI: 10.12263/DZXB.20230465

Refocusing for Three-Dimensional Rotating Ship Targets in SAR Images Based on Minimum Entropy Criteria and Generative Adversarial Network

HUA Qing-long, ZHANG Yun*, REN Hang, JIANG Yi-cheng, XU Dan

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China)

Abstract: In synthetic aperture radar (SAR) system, the three-dimensional rotation of ship targets in the presence of a medium and high sea state would lead to time-varying Doppler spectrum and image defocusing, which will adversely affect the subsequent information interpretation of ship targets in SAR images. Aiming at the refocusing problem of three-dimensional rotating ship targets, this paper proposes a SAR refocusing method for three-dimensional rotating ship target based on minimum entropy criterion and generative adversarial network, and designs the network structure of generator and discriminator. The generator transforms the defocused complex SAR ship image into range-Doppler domain, and estimates the phase error coefficient by range unit using phase error coefficient estimation network, and realizes the compensation of multi-order phase errors. The discriminator is composed of a complex-valued convolutional neural network, and all its elements, including convolution layer, activation function, feature mapping and parameters, are extended to the complex domain. The minimum entropy criterion and adversarial loss are introduced into the loss function to achieve unsupervised training and avoid the problem that it is difficult to obtain the target labeling samples of non-cooperative ships. Experiments on simulated data and Gaofen-3 data show that the proposed method achieves significant improvements in both refocusing accuracy and efficiency.

Key words: synthetic aperture radar (SAR); generative adversarial network; ship targets; refocusing; minimum entropy criteria

Foundation Item(s): National Natural Science Foundation of China (No.61971163); Fundamental Research Funds for the Central Universities (No.HIT.DZJJ.2023032)

1 引言

合成孔径雷达(Synthetic Aperture Radar, SAR)具有全天时、全天候、远距离、高分辨对地观测的优势,在海洋监测、海事管理、军事侦察等诸多军事和民用领域得到了广泛的应用^[1]. 传统的 SAR 成像算法一般假设目标场景是静止的,并对静止场景具有较好的成像效果. 在对海观测条件下, SAR 图像中存在许多复杂运动的舰船目标. 这类目标受到风场、浪场的影响产生三维转动,直接采用传统 SAR 成像算法进行处理会产生散焦现象^[2]. 图像散焦问题加剧了舰船目标信息解译的难度. 因此,研究三维转动舰船目标的重聚焦已变得十分迫切.

近几十年来,许多方法被提出用于 SAR 图像的聚焦处理. 这些方法可主要被分为基于子孔径的方法、基于滤波的方法、基于优化的方法和基于 SAR/ISAR 混合成像的方法. 基于子孔径的方法以子孔径相关自聚焦法(Map Drift Autofocus, MDA)^[3]为代表,通过求解子孔径图像之间的互相关关系来估计多普勒调频率,进而实现对 SAR 图像的重聚焦. Ran 等学者^[4]在 MDA 的基础上进一步扩展,提出一种斜视距离相关的 MDA 估计剩余随距离变化的相位误差. Huang 等学者^[5]提出一种改进子孔径相关算法用于无人机载 SAR 图像自聚焦. 基于子孔径的方法主要用于二阶相位误差的补偿,受可划分子孔径数量的限制,难以有效补偿高阶相位误差. 相位梯度自聚焦算法(Phase Gradient Autofocus, PGA)^[6]是一种应用广泛的基于滤波的 SAR 图像聚焦方法,通过迭代逐步进行相位误差校正,具有估计高阶相位误差的优点,但对特征点的选择、窗口大小和迭代次数较为敏感. Li 等学者^[7]提出一种卡尔曼滤波约束的 PGA 算法,将卡尔曼滤波器的预测结果应用到子孔径数据后再进行相位估计,以减少算法的收敛时间. 在 PGA 算法的基础上,还衍生出了 WPGA^[8]和 QPGA^[9]等 SAR 聚焦算法. 基于优化的方法通过最小化图像熵^[10-12]、最大化对比度^[13]等度量优化方式估计未知相位误差. 最常用的基于优化的 SAR 聚焦方法是基于最小熵的自聚焦方法(Minimum Entropy Autofocus, MEA). 这类方法不受成像场景和成像模式的限制,不依赖特显点的选取,即使对被观测目标没有已知条件或先验知识也能够实现对高阶相位误差的估计,在低图像对比度和相干斑噪声干扰等条件下具有更强的鲁棒性. 然而,基于优化的方法计算复杂度较高,需要大量迭代才能收敛. 基于 SAR/ISAR 混合成像的方法利用 SAR 成像方法获取散焦舰船目标切片,再通过逆变换获取仿

回波,然后利用 ISAR 成像方法获取聚焦舰船目标像. 在此类方法中, Itoh 等学者^[14]提出一种目标径向运动的补偿方法,称为多普勒中心跟踪法(Doppler Centroid Tracking, DCT),能够处理目标散射点连片情况,具有较好的稳定性. 王勇等学者^[15]提出了一种积广义三次相位函数(Product Generalized Cubic Phase Function, PGCPF)算法,用于估计多分量三次相位信号的参数并获得高质量的瞬时图像. SAR/ISAR 混合成像需要针对不同散焦情况进行具体分析,且复杂度较高,一定程度上限制了该方法在实际场景中的应用.

深度神经网络在图像处理领域表现出优异的性能,并已用于 SAR 重聚焦处理. Pu 等学者^[16]将基于迭代的稀疏成像方法展开为深度网络架构,并提出一种稀疏自编码器网络,可同时实现 SAR 成像与自聚焦. Liu 等学者^[17]基于深度神经网络提出两种自聚焦网络架构,并通过实测 SAR 数据实验验证所提网络的有效性. Li 等学者^[18]提出一种用于 SAR 自聚焦成像的深度神经网络,通过交替执行图像重建和相位误差估计实现 SAR 图像自聚焦. SAR 图像是带有相位信息的复数数据,而上述基于深度学习的自聚焦方法仅考虑 SAR 图像的幅度信息,缺乏对 SAR 图像相位信息的感知能力. 基于此, Hua 等学者^[19]提出复数域卷积门控循环单元和复数域 SAR 舰船目标重聚焦网络,以数据驱动的方式实现 SAR 图像重聚焦. 由于深度学习的特征自主学习能力,可突破传统 SAR 图像重聚焦方法对信号建模带来的性能限制,为 SAR 三维转动舰船目标重聚焦提供了新的研究思路.

针对 SAR 三维转动舰船目标的重聚焦问题,本文提出一种基于最小熵准则与生成对抗网络(Generative Adversarial Network, GAN)的 SAR 三维转动舰船目标重聚焦方法,从大量样本中以无监督的方式学习散焦 SAR 舰船目标多普勒频谱到相位误差的映射,实现对不同阶次相位误差系数的估计,克服传统自聚焦算法迭代次数多和计算量大的缺点,并通过逐距离单元估计相位误差系数进一步降低重聚焦问题的复杂度,提高了估计精度和图像聚焦质量. 通过与传统 SAR 聚焦方法进行性能比较,验证了所提方法对 SAR 三维转动舰船目标重聚焦的有效性.

2 SAR 三维转动舰船目标信号模型

SAR 三维转动舰船目标成像场景的几何构型如图 1 所示. 在成像场景中建立空间坐标系 $O-X_c Y_c Z_c$. X_c 轴垂直于雷达平台运动方向, Z 轴与海平面垂直. 假设舰船

的质心位于 O - XYZ 坐标系的原点, X 轴与船舶方向相同. O - XYZ 可以通过沿 Z 轴顺时针旋转 θ_0 与 O - $X_e Y_e Z$ 重合.




图1 SAR 三维转动舰船目标成像几何构型

星载或机载平台上的 SAR 系统沿预定的飞行轨迹 Y_e 轴以速度 V 匀速运动, 飞行高度为 H , 下视角为 η , 舰船质心与雷达的最小距离为 R_c . 舰船与雷达的瞬时距离可表示为

$$R_c(t) = \sqrt{R_c^2 + (Vt)^2} \approx R_c + \frac{V^2}{2R_c} t^2 \quad (1)$$

其中, t 代表慢时间.

雷达在 O - $X_e Y_e Z$ 坐标系中的坐标为 $[Vt, R_c \sin \eta, H]^T$. 因此, 通过坐标变换, 雷达在 O - XYZ 坐标系中的瞬时坐标为

$$\begin{bmatrix} x_r(t) \\ y_r(t) \\ z_r(t) \end{bmatrix} = \begin{bmatrix} Vt \cos \theta_0 - R_c \sin \eta \sin \theta_0 \\ Vt \sin \theta_0 + R_c \sin \eta \cos \theta_0 \\ H \end{bmatrix} \quad (2)$$

舰船在海面上由于风场和海浪的作用, 在侧摆、俯仰和偏航三个方向上都存在转动. 该转动可以表示为

$$\theta_\zeta(t) = A_\zeta \cos\left(\frac{2\pi}{\tau_\zeta} t + \phi_\zeta\right), \zeta = r, p, y \quad (3)$$

其中, A_ζ 为转动振幅, τ_ζ 为转动周期, ϕ_ζ 为初始相位, r, p, y 分别代表侧摆、俯仰和偏航. $\theta_\zeta(t)$ 与海况、舰船类型和舰船航速有关.

假设 P 是舰船上的任意一点, 其在 O - XYZ 坐标系中的初始坐标是 $[x, y, z]^T$, 则 P 在 t 时刻的坐标可以表示为

$$[x(t), y(t), z(t)]^T = \mathbf{\Omega}(t)[x, y, z]^T \quad (4)$$

其中 $\mathbf{\Omega}(t)$ 为与 $\theta_\zeta(t)$ 相关的旋转矩阵^[20].

因此, 在 t 时刻, 雷达到点 P 的距离为

$$R(t) \approx R_c(t) - \frac{x(t)x_r(t) + y(t)y_r(t) + z(t)z_r(t)}{R_c(t)} - \frac{(x(t)x_r(t) + y(t)y_r(t) + z(t)z_r(t))^2}{2R_c(t)^3} \quad (5)$$

根据式(1), $R(t)$ 可以改写为

$$R(t) = \rho_2 t^2 + \rho_1 t + \rho_0 \quad (6)$$

其中, $\rho_i (i=1, 2, 3)$ 代表距离参数. ρ_i 可以表示为 $\rho_i = \tilde{\rho}_i + \Delta\rho_i$, $\tilde{\rho}_2 = v_r^2/2R_c$, $\tilde{\rho}_1 = 0$, $\tilde{\rho}_0 = R_c$. $\Delta\rho_i$ 与舰船目标的三维转动有关.

基于距离参数 ρ_i , 利用级数反演法可以推导出信号在距离-多普勒 (Range-Doppler, RD) 域二阶以内的相位误差为^[21, 22]

$$\phi_{\text{res}}(f_r, f_a) = \phi_{\text{res},2}(f_a) + \phi_{\text{res},1}(f_a) + \phi_{\text{res},0}(f_a) \quad (7)$$

其中, f_r 为快时间对应频率, f_a 为多普勒频率. $\phi_{\text{res},2}(f_a)$ 、 $\phi_{\text{res},1}(f_a)$ 和 $\phi_{\text{res},0}(f_a)$ 可以分别表示为

$$\phi_{\text{res},2}(f_a) = -\frac{\pi\lambda\Delta\rho_2}{4\tilde{\rho}_2(\tilde{\rho}_2 + \Delta\rho_2)} f_a^2 \quad (8)$$

$$\phi_{\text{res},1}(f_a) = \left(\frac{2\Delta\rho_1}{\tilde{\rho}_2 + \Delta\rho_2} - \frac{\pi\tilde{\rho}_1\Delta\rho_2}{\tilde{\rho}_2(\tilde{\rho}_2 + \Delta\rho_2)} \right) f_a \quad (9)$$

$$\begin{aligned} \phi_{\text{res},0}(f_a) = & \frac{2\pi}{\lambda} \left(\frac{-\tilde{\rho}_1^2\Delta\rho_2 + \tilde{\rho}_1 2\Delta\rho_1\tilde{\rho}_2}{2\tilde{\rho}_2(\tilde{\rho}_2 + \Delta\rho_2)} \right. \\ & \left. + \frac{\Delta\rho_1^2}{2(\tilde{\rho}_2 + \Delta\rho_2)} - 2\Delta\rho_0 \right) \end{aligned} \quad (10)$$

其中, f_0 为载频, $\lambda = c/f_0$ 为波长, c 为光速.

根据式(7)~(10), 在距离-多普勒域, 包含相位误差的回波信号可以建模为

$$s(\hat{t}, f_a) = s_0(\hat{t}, f_a) \exp(-j \cdot \phi(f_a)) \quad (11)$$

其中, j 是虚数单位, $s_0(\hat{t}, f_a)$ 为不含相位误差的距离-多普勒域回波信号, \hat{t} 表示距离向时间, $\phi(f_a)$ 表示相位误差分量. 由于一阶线性相位误差只是造成图像的整体平移, 对舰船目标图像结构没有影响, 因此距离-多普勒域的回波信号相位误差模型可合理假设为

$$\phi(f_a) = \sum_{i=2}^{\infty} \alpha_i f_a^i \quad (12)$$

其中, α_i 为第 i 阶相位误差系数. 舰船目标重聚焦的本质就是补偿相位误差 $\phi(f_a)$. 为了进一步分析不同阶次相位误差对 SAR 成像结果的影响, 对点目标方位向回波信号添加不同阶次相位误差, 并进行了方位压缩仿真实验, 结果如图 2 所示. 从图 2 可以看出, 一阶相位误差会造成信号产生明显的偏移; 三阶及以上奇数阶相位误差会造成明显的不对称旁瓣; 偶数阶相位误差会造成主瓣展宽, 峰值降低, 旁瓣电平升高.

3 基于最小熵准则与生成对抗网络的重聚焦方法

本节提出的重聚焦方法参考生成对抗网络的思想

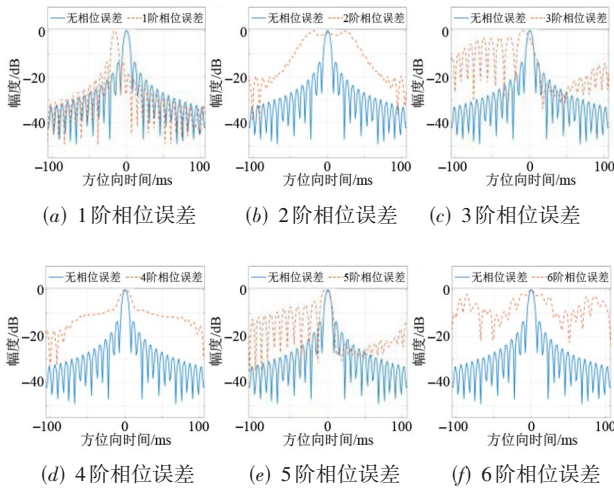


图2 不同阶次相位误差时方位回波信号压缩结果

进行设计,包含生成器、判别器和损失函数三部分,算法整体流程图如图3所示.这里,令 g_{θ_1} 表示生成器, θ_1 为生成器可学习参数,令 d_{θ_2} 表示判别器, θ_2 为判别器可学习参数.所提重聚焦方法基本思想如下:首先,对于输入散焦舰船目标图像 \mathbf{S} ,在生成器中利用相位误差系数估计网络(Phase Error Coefficient Estimation Network, PECE-Net)估计每个距离单元的多阶相位误差系数,实现对相位误差的矫正,并得到聚焦的舰船目标图像 $g_{\theta_1}(\mathbf{S})$;其次,随机选取一个参考聚焦舰船目标图像,并连同生成器输出的聚焦图像一并输入到判别器中;然后,根据判别器输出结果计算对抗损失 $\mathcal{L}_{\text{WGAN}}$,根据生成器输出的聚焦图像 $g_{\theta_1}(\mathbf{S})$ 计算图像熵损失 \mathcal{L}_{ME} ,利用对抗损失和图像熵损失更新生成器参数 θ_1 和判别器参数 θ_2 ;最后,针对复杂运动舰船目标SAR散焦图像,采用训练好的生成器进行重聚焦处理.

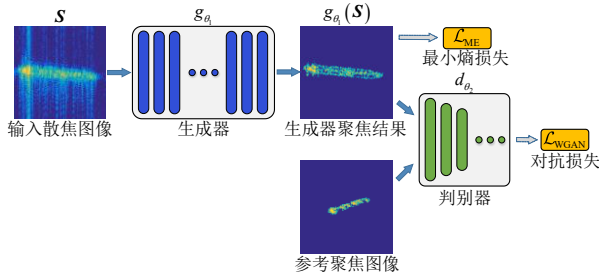


图3 算法流程图

3.1 生成器

在本文所提重聚焦算法之中,生成器需要不断优化自身生成的重聚焦结果,并使判别器难以准确分辨.生成器架构图如下图4所示.

3.1.1 生成器处理流程

根据第2节所述SAR舰船目标信号模型的分析可

得,舰船目标回波信号相位误差可以在距离-多普勒域建模为多项式形式.因此,在生成器中首先通过方位向快速傅里叶变换(Fast Fourier Transform, FFT)将散焦舰船目标图像 \mathbf{S} 变换到RD域,即

$$\mathbf{S}_{\text{RD}} = f(\mathbf{S}) \quad (13)$$

其中, \mathbf{S}_{RD} 代表RD域图像, $f(\cdot)$ 代表FFT操作.




图4 生成器架构图

生成器的重点是利用PECE-Net逐距离单元估计 \mathbf{S}_{RD} 相位图的多阶相位误差系数.这里,令 ψ_{θ_1} 表示PECE-Net.由于生成器的可学习参数仅存在于PECE-Net,因此PECE-Net的可学习参数仍可用 θ_1 表示.则,PECE-Net估计所得相位误差系数矩阵 \mathbf{E} 可以表示为

$$\mathbf{E} = \psi_{\theta_1}(\arg(\mathbf{S}_{\text{RD}})) \quad (14)$$

其中, $\arg(\cdot)$ 代表取相位操作.

利用所得相位误差系数矩阵 \mathbf{E} 对RD域图像 \mathbf{S}_{RD} 进行相位误差校正,再经方位向快速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)得到生成器聚焦结果 $g_{\theta_1}(\mathbf{S})$,即

$$g_{\theta_1}(\mathbf{S}) = \hat{f}\left(\mathbf{S}_{\text{RD}} \cdot \exp\left(-j \cdot \sum_i \mathbf{E}_i f_i^i\right)\right) \quad (15)$$

其中, $\hat{f}(\cdot)$ 代表IFFT操作.

3.1.2 PECE-Net

为了降低重聚焦任务的复杂度并凸显相位误差的相关特征,PECE-Net将散焦舰船目标图像变换到距离-多普勒域并提取相位图进行处理,并将相位图沿距离向滑窗划分多个子带,各子带彼此存在重叠.假设散焦舰船目标图像 \mathbf{S} 的尺寸为 $H \times W \times C$,子带的距离向宽度为 $k=2n+1$, $n=1,2,3,\dots$,则子带的尺寸为 $H \times k \times C$,子带个数为 $W-2n$.将划分的子带拼接为三维矩阵输入到PECE-Net之中,则输入数据的矩阵维度为 $H \times k \times C \times (W-2n)$.PECE-Net由1个输入层,5个卷积层,2个全连接层和1个输出层组成,网络架构如图5所示.5个卷积层卷积核尺寸均为 3×3 ,卷积核个数分别为96、256、384、384和256.第1,2,5个卷积层的步长为 2×1 ,第3,4个卷积层的步长为 1×1 .两个全连接层的神经元个数分别为1024与256.卷积层和全连接层的激活函数均为斜率为0.1的leaky-ReLU^[23].输出层神经元个数

为 N , 由于所提重聚焦算法不考虑对 1 阶相位误差的补偿, 因此输出层神经元依次输出 $2 \sim N+1$ 阶相位误差系数. 当输入 SAR 图像数据维度设置为 $128 \times 128 \times 1$ 、估计相位误差最高阶数为 5 阶 (即 $N=4$) 时, PECE-Net 的总参数量约为 16.17 M.




图5 PECE-Net 架构图

PECE-Net 属于实数域网络, 其前向传播与反向传播过程如下. 在 PECE-Net 第 l 个卷积层中, 将输入特征图 \mathbf{a}^{l-1} 与卷积层的权值矩阵 \mathbf{W}^l 卷积, 并加入偏置项 \mathbf{b}^l 得到中间变量 \mathbf{z}^l . \mathbf{z}^l 由实数域激活函数 $\sigma(\cdot)$ 激活, 得到卷积层的输出 \mathbf{a}^l . PECE-Net 卷积计算过程可以表示为

$$\begin{aligned} \mathbf{a}^l &= \sigma(\mathbf{z}^l) \\ &= \sigma(\mathbf{W}^l * \mathbf{a}^{l-1}) + \mathbf{b}^l \end{aligned} \quad (16)$$

其中, $*$ 表示卷积运算操作.

在 PECE-Net 第 l 个全连接层中, 将输入特征图 \mathbf{a}^{l-1} 与全连接层的权值矩阵 \mathbf{W}^l 卷积, 并加入偏置项 \mathbf{b}^l 得到中间变量 \mathbf{z}^l . \mathbf{z}^l 由 $\sigma(\cdot)$ 激活, 得到全连接层的输出 \mathbf{a}^l . PECE-Net 全连接层计算过程可以表示为

$$\begin{aligned} \mathbf{a}^l &= \sigma(\mathbf{z}^l) \\ &= \sigma(\mathbf{W}^l \mathbf{a}^{l-1}) + \mathbf{b}^l \end{aligned} \quad (17)$$

假设第 l 个全连接层的误差项为 δ^l , 则第 $l-1$ 个全连接层的误差项可以推导为

$$\delta^{l-1} = (\mathbf{W}^l)^\top \delta^l \odot \sigma'(\mathbf{z}^{l-1}) \quad (18)$$

其中, $\sigma'(\cdot)$ 是激活函数 $\sigma(\cdot)$ 的导数, $(\cdot)^\top$ 表示矩阵转置操作, \odot 表示哈达玛积. 第 l 个全连接层的权值矩阵和偏置项的梯度为

$$\frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} = \delta^l (\mathbf{a}^{l-1})^\top \quad (19)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} = \sum \delta^l \quad (20)$$

假设第 l 个卷积层的误差项为 δ^l , 则第 $l-1$ 个卷积层的误差项可以推导为

$$\delta^{l-1} = \delta^l (\mathbf{W}^l)^\circ \odot \sigma'(\mathbf{z}^{l-1}) \quad (21)$$

其中, $(\cdot)^\circ$ 表示将矩阵旋转 180 度. 第 l 个卷积层的权值矩阵和偏置项的梯度为

$$\frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} = \mathbf{a}^{l-1} * \delta^l \quad (22)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} = \sum \delta^l \quad (23)$$

PECE-Net 第 l 个卷积层或全连接层的权值矩阵和偏置项的更新公式为

$$\mathbf{W}^l \leftarrow \mathbf{W}^l + \eta \frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} \quad (24)$$

$$\mathbf{b}^l \leftarrow \mathbf{b}^l + \eta \frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} \quad (25)$$

其中, η 为学习率. 式(16)~(25)所包含的所有变量均属于实数域.

3.2 判别器

判别器用于处理生成器输出的聚焦结果与参考聚焦图像, 并不断优化自身参量以尽可能将两者区分开来. 生成器与判别器形成博弈对抗关系, 并在训练中逐渐达到纳什均衡. 为了充分利用复数域 SAR 图像的幅度和相位信息, 采用复数域卷积神经网络 (Complex-Valued Convolutional Neural Network, CV-CNN) 构建判别器, 其所有元素均被扩展到复数域. 判别器的网络架构如图 6 所示, 包含一个输入层、四个复数域卷积层、一个复数域全连接层和一个输出层. 四个复数域卷积层的卷积核尺寸均为 4×4 , 步长均为 2×2 , 卷积核个数分别为 32、64、128 和 128. 复数域全连接层的神经元个数为 1 024. 输出层神经元个数为 1.




图6 判别器架构图

3.2.1 判别器前向传播

复数域卷积层由实数域卷积层向复数域扩展得到. 复数域卷积层中卷积操作的示意图如图 7 所示. 在第 l 个复数域卷积层中, 将输入特征图 \mathbf{a}^{l-1} 与卷积层的权值矩阵 \mathbf{W}^l 卷积, 并加入偏置项 \mathbf{b}^l 得到中间变量 \mathbf{z}^l . \mathbf{z}^l 由复数域激活函数 $\sigma_{\text{Re-Im}}(\cdot)$ 激活, 得到复数域卷积层的输出 \mathbf{a}^l . 复数域卷积计算过程可以表示为

$$\begin{aligned} \mathbf{a}^l &= \sigma_{\text{Re-Im}}(\mathbf{z}^l) \\ &= \sigma \left(\text{Re}(\mathbf{W}^l) * \text{Re}(\mathbf{a}^{l-1}) \right. \\ &\quad \left. - \text{Im}(\mathbf{W}^l) * \text{Im}(\mathbf{a}^{l-1}) \right) + \text{Re}(\mathbf{b}^l) \\ &\quad + j \cdot \sigma \left(\text{Re}(\mathbf{W}^l) * \text{Im}(\mathbf{a}^{l-1}) \right. \\ &\quad \left. + \text{Im}(\mathbf{W}^l) * \text{Re}(\mathbf{a}^{l-1}) \right) + \text{Im}(\mathbf{b}^l) \end{aligned} \quad (26)$$

其中, Re 和 Im 分别表示复数的实部和虚部. 复数激活函数 $\sigma_{\text{Re-Im}}(\cdot)$ 分别激活实部和虚部. 对于复变量 \mathbf{z}^l ,

$\sigma_{\text{Re-Im}}(\cdot)$ 的激活过程如下

$$\sigma_{\text{Re-Im}}(z) = \sigma(\text{Re}(z)) + j \cdot \sigma(\text{Im}(z)) \quad (27)$$

其中, $\sigma(\cdot)$ 为实数域激活函数. 判别器的 $\sigma(\cdot)$ 激活函数采用的是 leaky-ReLU 函数.




图7 复数域卷积计算示意图

复数域全连接层由实数域全连接层向复数域扩展得到. 在第 l 个复数域全连接层中, 将输入特征图 \mathbf{a}^{l-1} 与全连接层的权值矩阵 \mathbf{W}^l 卷积, 并加入偏置项 \mathbf{b}^l 得到中间变量 \mathbf{z}^l . \mathbf{z}^l 由 $\sigma_{\text{Re-Im}}(\cdot)$ 激活, 得到复数域全连接层的输出 \mathbf{a}^l . 复数域全连接层计算过程可以表示为

$$\begin{aligned} \mathbf{a}^l &= \sigma_{\text{Re-Im}}(\mathbf{z}^l) \\ &= \sigma(\text{Re}(\mathbf{W}^l)\text{Re}(\mathbf{a}^{l-1}) \\ &\quad - \text{Im}(\mathbf{W}^l)\text{Im}(\mathbf{a}^{l-1})) + \text{Re}(\mathbf{b}^l) \\ &\quad + j \cdot \sigma(\text{Re}(\mathbf{W}^l)\text{Im}(\mathbf{a}^{l-1}) \\ &\quad + \text{Im}(\mathbf{W}^l)\text{Re}(\mathbf{a}^{l-1})) + \text{Im}(\mathbf{b}^l) \end{aligned} \quad (28)$$

经过多层特征提取后, 最终由输出层输出类别. 判别器本质上是一个二分类器, 其输出层由单个神经元组成. 输出层不包含激活函数. 后续通过构建对抗损失 $\mathcal{L}_{\text{WGAN}}$ 和图像熵损失 \mathcal{L}_{ME} , 以无监督的方式学习生成器和判别器的参数.

3.2.2 判别器反向传播

假设第 l 个复数域全连接层的误差项为 δ^l , 则第 $l-1$ 个复数域全连接层的误差项可以推导为

$$\begin{aligned} \delta^{l-1} &= \left(\text{Re}(\delta^l)\text{Re}\left((\mathbf{W}^l)^T\right) \right. \\ &\quad \left. + \text{Im}(\delta^l)\text{Im}\left((\mathbf{W}^l)^T\right) \right) \odot \sigma'(\text{Re}(\mathbf{z}^{l-1})) \\ &\quad - j \cdot \left(\text{Re}(\delta^l)\text{Im}\left((\mathbf{W}^l)^T\right) \right. \\ &\quad \left. - \text{Re}\left((\mathbf{W}^l)^T\right)\text{Im}(\delta^l) \right) \odot \sigma'(\text{Im}(\mathbf{z}^{l-1})) \end{aligned} \quad (29)$$

第 l 个复数域全连接层的权值矩阵和偏置项的梯度为

$$\begin{aligned} \frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} &= \left(\text{Re}(\mathbf{a}^{l-1}) \right)^T \text{Re}(\delta^l) + \left(\text{Im}(\mathbf{a}^{l-1}) \right)^T \text{Im}(\delta^l) \\ &\quad + j \cdot \left(\left(\text{Re}(\mathbf{a}^{l-1}) \right)^T \text{Im}(\delta^l) - \left(\text{Im}(\mathbf{a}^{l-1}) \right)^T \text{Re}(\delta^l) \right) \end{aligned} \quad (30)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} = \sum \delta^l \quad (31)$$

假设第 l 个复数域卷积层的误差项为 δ^l , 则第 $l-1$ 个复数域卷积层的误差项可以推导为

$$\begin{aligned} \delta^{l-1} &= \left(\text{Re}(\delta^l) * \text{Re}(\mathbf{W}^l) \right)^\odot \\ &\quad + \text{Im}(\delta^l) * \text{Im}(\mathbf{W}^l)^\odot \odot \sigma'(\text{Re}(\mathbf{z}^{l-1})) \\ &\quad - j \cdot \left(\text{Re}(\delta^l) * \text{Im}(\mathbf{W}^l) \right)^\odot \\ &\quad - \text{Im}(\delta^l) * \text{Re}(\mathbf{W}^l)^\odot \odot \sigma'(\text{Im}(\mathbf{z}^{l-1})) \end{aligned} \quad (32)$$

第 l 个复数域卷积层的权值矩阵和偏置项的梯度为

$$\begin{aligned} \frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} &= \text{Re}(\mathbf{a}^{l-1}) * \text{Re}(\delta^l) + \text{Im}(\mathbf{a}^{l-1}) * \text{Im}(\delta^l) \\ &\quad + j \cdot \left(\text{Re}(\mathbf{a}^{l-1}) * \text{Im}(\delta^l) - \text{Im}(\mathbf{a}^{l-1}) * \text{Re}(\delta^l) \right) \end{aligned} \quad (33)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} = \sum \delta^l \quad (34)$$

第 l 个复数域卷积层或全连接层的权值矩阵和偏置项的更新公式为

$$\mathbf{W}^l \leftarrow \mathbf{W}^l + \eta \frac{\partial \mathcal{L}}{\partial \mathbf{W}^l} \quad (35)$$

$$\mathbf{b}^l \leftarrow \mathbf{b}^l + \eta \frac{\partial \mathcal{L}}{\partial \mathbf{b}^l} \quad (36)$$

需要注意的是, 式(26)~(36)所包含的所有变量均属于复数域.

3.3 损失函数

基于上述生成器和判别器的网络架构, 接下来构建对抗损失 $\mathcal{L}_{\text{WGAN}}$ 和图像熵损失 \mathcal{L}_{ME} . 将生成器输出的聚焦结果 $g_{\theta_1}(\mathbf{S})$ 与参考聚焦图像 \mathbf{T} 输入判别器中, 判别器决定生成器输出聚焦结果分布与参考聚焦图像分布之间的距离. 生成器 g_{θ_1} 和判别器 d_{θ_2} 参考 WGAN^[24] 的对抗损失进行训练. 对抗损失 $\mathcal{L}_{\text{WGAN}}$ 可以表示为

$$\mathcal{L}_{\text{WGAN}} = \mathbb{E}\left(d_{\theta_2}(\mathbf{T})\right) - \mathbb{E}\left(d_{\theta_2}(g_{\theta_1}(\mathbf{S}))\right) \quad (37)$$

其中, \mathbb{E} 表示期望算子, 即取均值操作. 根据式(37)可得, 生成器 g_{θ_1} 试图生成与 \mathbf{T} 相似的聚焦图像, 而判别器 d_{θ_2} 旨在将生成器输出的聚焦结果 $g_{\theta_1}(\mathbf{S})$ 和参考聚焦图像 \mathbf{T} 区分开来. 在这种博弈情况下, 生成器 g_{θ_1} 试图将损失最小化, 而判别器 d_{θ_2} 试图使损失最大化.

此外, 参考最小熵准则^[12]引入图像熵损失 \mathcal{L}_{ME} . 对于生成器输出的聚焦结果 $g_{\theta_1}(\mathbf{S})$, 引用 Shannon 熵的定义方法, 计算图像熵损失 \mathcal{L}_{ME} 为

$$\mathcal{L}_{\text{ME}} = - \sum_{h=1}^H \sum_{w=1}^W \sum_{c=1}^C \rho_{hwc} \log \rho_{hwc} \quad (38)$$

$$\rho_{hwc} = \frac{|g_{\theta_1}(\mathbf{S})_{hwc}|^2}{P} \quad (39)$$

$$P = \sum_{m=1}^M \sum_{n=1}^N \sum_{c=1}^C |g_{\theta_1}(\mathbf{S})_{hwc}|^2 \quad (40)$$

其中, $g_{\theta_1}(\mathbf{S})_{hwc}$ 表示生成器输出聚焦结果 $g_{\theta_1}(\mathbf{S})$ 第 h 行第 w 列第 c 通道的像素值, P 表示图像的总功率, ρ_{hwc} 表示像素的功率与图像总功率的比值. 图像熵能够反映图像的聚焦程度, 图像聚焦程度越好, 图像熵越小.

根据定义的损失函数, 采用交替优化策略对生成器 g_{θ_1} 和判别器 d_{θ_2} 进行优化, 将其描述为一个对抗性极小-极大问题, 表示为

$$\min_{\theta_1} \max_{\theta_2} \{ \mathcal{L}_{\text{WGAN}}(\theta_1, \theta_2) + \alpha \mathcal{L}_{\text{ME}}(\theta_1) \} \quad (41)$$

其中, α 是控制图像熵损失 \mathcal{L}_{ME} 大小的超参数.

基于最小熵准则与生成对抗网络的重聚焦方法具体步骤如算法 1 所列.

算法 1 基于最小熵准则与生成对抗网络的重聚焦方法

输入: SAR 散焦舰船目标图像

输出: 生成器最佳模型参数 θ_1^* 与 SAR 舰船目标重聚焦结果

1. 初始化生成器参数 θ_1 与判别器参数 θ_2 , 学习率 η , 超参数 α , 迭代次数 $q \leftarrow 0$, 最大迭代次数 q_{\max}

2. 构造散焦数据集 \mathcal{S}_1 和参考聚焦数据集 \mathcal{S}_2

训练阶段

3. While $q < q_{\max}$ Do

4. $q \leftarrow q + 1$

5. 随机从 \mathcal{S}_1 中选取一个散焦舰船目标样本 \mathbf{S}

6. 随机从 \mathcal{S}_2 中选取一个参考聚焦舰船目标样本 \mathbf{T}

7. 前向传播并计算损失函数

a. 由式(13)~(17)计算生成器输出聚焦结果 $g_{\theta_1}(\mathbf{S})$

b. 根据式(26)~(28)计算判别器输出结果 $d_{\theta_2}(g_{\theta_1}(\mathbf{S}))$ 和 $d_{\theta_2}(\mathbf{T})$

c. 根据式(37)~(40)计算对抗损失 $\mathcal{L}_{\text{WGAN}}$ 和图像熵损失 \mathcal{L}_{ME}

8. 误差反向传播并更新网络权值 θ_1 和 θ_2

a. 根据式(29)~(34)对判别器进行误差反向传播

b. 根据式(18)~(23)对生成器进行误差反向传播

c. 根据式(35)~(36)更新判别器网络权值 θ_2

d. 根据式(24)~(25)更新生成器网络权值 θ_1

9. End While

重聚焦阶段

10. 根据训练所得最佳模型参数 θ_1^* 构生成器

11. 分析生成器对 SAR 舰船目标图像的重聚焦性能

实验. 首先, 在仿真数据集中, 利用所提方法对存在不同阶次相位误差的散焦舰船目标图像进行重聚焦处理, 对比分析所提方法与传统重聚焦方法的性能; 然后, 验证所提方法对 GF-3 散焦舰船目标图像的重聚焦效果; 最后, 对比分析不同重聚焦方法的重聚焦处理运算时间, 进行计算效率分析.

4.1 实验数据

4.1.1 仿真数据集

仿真数据集由射线跟踪 SAR 成像方法仿真得到, 仿真流程示意图如图 8 所示. 该方法根据射线追踪法和成像场景参数, 获取舰船三维模型的散射点坐标和雷达散射截面 (Radar Cross Section, RCS), 再利用 RD 成像算法得到聚焦的静止目标切片 360 张, 尺寸为 128×128 . 通过随机裁剪的方式将 360 张聚焦切片样本扩增到 12 000 张, 尺寸为 120×120 . 雷达被设置工作在 C 波段 (5.4 GHz) 并且属于星载体制. 雷达轨道高度为 755 km, 平台速度为 7 568 m/s, 脉冲宽度为 $45 \mu\text{s}$, PRF 为 1 178 Hz. 侧摆、俯仰和偏航的角速度范围均为 $0 \sim 0.1 \text{ rad/s}$. 信噪比 (Signal-to-Noise Ratio, SNR) 范围为 $-10 \sim 10 \text{ dB}$. 舰船类别为 5 类. 仿真参数设置如表 1 所示.




图 8 仿真数据集仿真流程示意图

表 1 仿真参数设置

参数	值
轨道高度/km	755
平台速度/(m/s)	7 568
PRF/Hz	1 178
脉冲宽度/ μs	45
载频/GHz	5.40
信噪比范围/dB	$[-10, 10]$
侧摆角速度/(rad/s)	$[0, 0.1]$
俯仰角速度/(rad/s)	$[0, 0.1]$
偏航角速度/(rad/s)	$[0, 0.1]$

(1) 仿真数据集 I

为了探究所提方法对存在不同阶次相位误差散焦 SAR 舰船目标图像的重聚焦效果, 从聚焦的静止目标切片中随机选取 6 000 张, 并在距离-多普勒

4 实验结果分析

为了验证所提重聚焦方法的有效性, 本文构建两个仿真数据集和一个高分三号 (GF-3) 数据集开展验证

域添加相位误差构建仿真散焦舰船目标数据集 I, 剩余 6 000 张切片用于构建仿真参考聚焦舰船目标数据集. 考虑到低频相位误差中的高阶分量通常较小, 因此在仿真中仅添加了 2~5 阶相位误差. 仿真数据集 I 散焦舰船目标图像示例如图 9 所示.

(2) 仿真数据集 II

为了探究所提方法对三维转动舰船目标的重聚焦

效果, 通过设置散射点的三维转动, 并在 RD 成像中加入随机噪声, 获得散焦的三维转动舰船目标切片共计 6 000 张, 构建仿真散焦舰船目标数据集 II. 仿真三维转动角速度范围为 0~0.1 rad/s. 仿真数据集 II 散焦舰船目标图像示例如图 10 所示. 仿真数据集 II 对应的参考聚焦目标数据同样来自仿真参考聚焦舰船目标数据集.




图 9 仿真数据集 I 散焦舰船目标图像示例




图 10 仿真数据集 II 散焦舰船目标图像示例

4.1.2 GF-3 数据集

本文从 GF-3 SAR 图像中截取 68 张复数域舰船目标图像切片. 同样通过随机裁剪的方式进行样本扩充, 得到 5 000 张尺寸为 120×120 的散焦舰船目标切片, 用于构建 GF-3 散焦舰船目标数据集. 同时, 从 GF-3 SAR 图像中截取并扩充得到 5 000 张聚焦舰船目标切片, 用于构建 GF-3 参考聚焦舰船目标数据集. 本文所用 GF-3 SAR 数据的成像模式为精细条带 1(FSI), 幅宽为 50 km. GF-3 散焦舰船目标图像示例如图 11 所示.




图 11 GF-3 数据集散焦舰船目标图像示例

4.2 实验设置与聚焦质量评价指标

所提重聚焦方法的训练需要设置许多超参数以获取优化权值. 训练参数设置为: 迭代次数 20, 每批次训练样本数目为 1, 学习率 0.000 2, 超参数 α 设为 10. 子带宽度 $k=3$. 环境架构: Python3.6, CUDA10.0, cudnn7.5, Tensorflow1.14. 仿真数据集 I、仿真数据集 II 和 GF-3 数据集均随机选取样本量的 80% 作为训练样本, 并需要各自训练一个重聚焦模型. 三个数据集剩余 20% 的数据作为测试样本, 并利用各数据集的重聚焦模型进行

重聚焦性能评价.

为了便于分析所提重聚焦方法的性能, 采用均方误差 (Mean-Square Error, MSE)、结构相似性指标 (Structural Similarity Index Metric, SSIM)^[25]、图像熵和信杂噪比 (Signal-to-Clutter plus Noise Ratio, SCNR) 来衡量重聚焦精度. MSE 反映的是重聚焦结果与理想聚焦图像之间的差异程度. MSE 越小, 差异越小. SSIM 评估的是重聚焦结果与理想聚焦图像之间的相似性水平. SSIM 的取值范围是 0~1, SSIM 越接近 1, 表示越相似. 图像熵可以表征图像中强散射点的聚集情况, 衡量图像的聚集程度. 图像熵的计算方法见式 (38)~(40). 熵越小, SCNR 越大, 重聚焦性能越好. 对于实测数据中的非合作舰船目标, 难以计算信号、杂波和噪声的能量. 特别是对于散焦 SAR 舰船目标, 舰船散焦信号中混杂着杂波和噪声. 因此, 可采用如下近似计算方法:

$$\text{SCNR} = 10 \log_{10} \left(\frac{\sigma_A}{\sigma_{S-A}} \right) \quad (42)$$

其中, S 表示复数域散焦图像, A 表示标签图像, σ_A 为 A 的方差, σ_{S-A} 为 S 减去 A 所得矩阵的方差. 虽然 SCNR 是通过近似计算得到的, 但仍可以用于比较不同方法的重聚焦效果.

4.3 仿真数据集 I 重聚焦结果分析

4.3.1 不同阶次相位误差重聚焦结果分析

为了探索所提方法对不同阶次相位误差的重聚焦性能, 采用仿真数据集 I 对生成器和判别器进行对抗训

练. 在仿真数据集 I 训练样本上的损失函数曲线如图 12 所示. 从图 12 中可以看出, 训练损失随着训练批次数的增加而减少, 大约在训练批次数为 8×10^4 时收敛到一个较低值, 具备良好的收敛性能. 利用训练好的生成器对分别存在二到五阶相位误差仿真散焦舰船目标进行重聚焦处理, 结果如图 13 所示. 由图 13(a) 和图 13(b)~(e) 对比可以看出, 由于相位误差的存在, 舰船目标存在明显的散焦现象. 经过生成器重聚焦处理后, 存在不同阶次相位误差的散焦图像都得到了很好的重聚焦处理, 图像质量也得到了很大的提升. 对比分析图 13(a) 和图 13(f)~(i) 可得, 重聚焦处理后的舰船目标与原始未添加相位误差的聚焦图像很接近, 散射点聚焦良好. 由生成器输出相位误差系数可得不同阶次

相位误差条件下沿方位维相位误差曲线如图 13(j)~(m) 所示, 生成器估计相位误差与仿真相位误差较为一致, 两者的曲线重合度较高, 验证了所提重聚焦方法的有效性.




图 12 仿真数据集 I 损失函数曲线

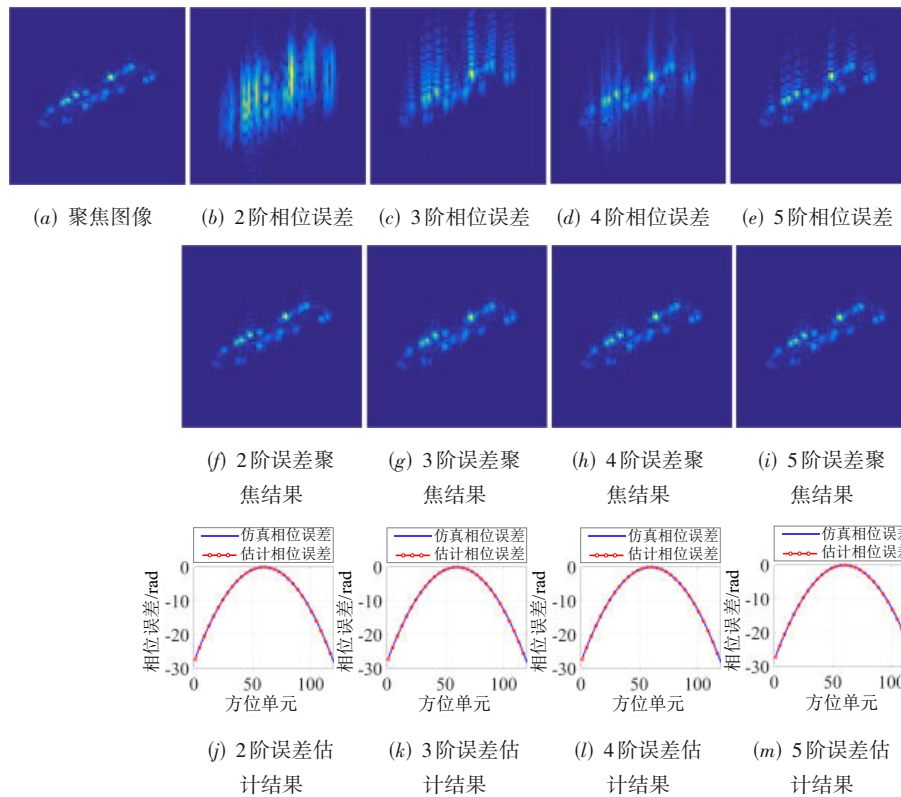


图 13 仿真数据集 I 不同阶次相位误差重聚焦结果

根据生成器对仿真数据集 I 测试样本的重聚焦结果, 采用 MSE、SSIM、SCNR 和图像熵 4 个指标进行重聚焦性能评估, 结果如表 2 所示. 表 2 中的指标统计是对所有测试样本的平均统计结果, 下同. 在未添加相位误差的仿真聚焦图像中, 图像熵为 0.86. 从表 2 可以看出, 与原图相比, 添加相位误差后图像的图像熵变大, 尤其是添加二阶相位误差的图像质量严重受损. 经过生成器重聚焦处理后, 不同阶次相位误差下重聚焦结果的 SCNR 平均提高约 30 dB, MSE 和 SSIM 得到了很大提升, 图像熵降低范围约为 0.5, 与原图较为接近. 定量结

果表明, 所提方法对存在不同阶次相位误差的散焦舰船目标均具有良好的重聚焦性能.

4.3.2 不同方法重聚焦性能对比

为了探究所提方法与经典重聚焦方法的性能对比, 将 PGA、MEA 与本文方法进行比较. 不同方法对二到五阶相位误差散焦图像的重聚焦结果如图 14 所示. 从图 14 可以看出, PGA 和 MEA 均具有一定的重聚焦效果, 但仍残留了部分散焦能量. 经过本文方法处理后的图像质量有了很大的提升, 能够有效地聚焦舰船目标的各个散射点. 对上述不同方法的重聚焦效果进行定

表 2 仿真数据集 I 不同阶次相位误差重聚焦性能指标统计

	MSE	SSIM	图像熵	SCNR/dB
聚焦图像	—	—	0.86	—
二阶相位误差	2.40×10^{-3}	0.88	1.81	-12.28
处理结果	3.65×10^{-5}	0.99	0.85	24.07
三阶相位误差	7.89×10^{-4}	0.93	1.40	-2.64
处理结果	1.76×10^{-5}	0.99	0.90	30.98
四阶相位误差	3.05×10^{-4}	0.94	1.38	5.62
处理结果	1.53×10^{-5}	0.99	0.86	31.76
五阶相位误差	1.23×10^{-4}	0.97	1.07	13.54
处理结果	2.89×10^{-6}	0.99	0.87	47.46

量分析,结果如表 3 所示. 由表 3 可知,对于经过 PGA 处理的重聚焦结果,MSE 降低了约二分之一,SSIM 增加了约 0.03,SCNR 增加了约 7 dB,图像熵略有下降. MEA 的重聚焦效果与 PGA 类似,MSE 和 SCNR 两项指标略优于 PGA,SSIM 和图像熵两项指标劣于 PGA. 本文方法处理后的重聚焦结果在各项评价指标上均表现最佳,MSE 降低了约 98%,SSIM 增加了约 0.06,SCNR 增加了约 32 dB,图像熵最接近于原始聚焦 SAR 图像. 综上所述,本文方法在各项指标上均取得了最好的量化评价结果,充分体现了本文方法在 SAR 舰船目标重聚焦方面的优势.




图 14 仿真数据集 I 不同方法重聚焦结果

表 3 仿真数据集 I 不同方法重聚焦结果指标统计

	MSE	SSIM	图像熵	SCNR/dB
聚焦图像	—	—	0.86	—
散焦图像	9.05×10^{-4}	0.93	1.41	1.05
PGA	4.25×10^{-4}	0.96	1.03	8.13
MEA	3.58×10^{-4}	0.96	1.16	9.49
本文方法	1.81×10^{-5}	0.99	0.87	33.57

聚焦结果示例如图 15 所示,可以看出剩余 4 类舰船目标的重聚焦处理效果均较好,舰船目标形态特征得到了较好恢复. 对上述第 2~5 类舰船目标的重聚焦效果进行定量分析,结果如表 4 所示. 由表 4 可得,仅选取第 1 类舰船目标进行训练,所提方法在剩余 4 类舰船目标的散焦图像上均获得较高的重聚焦精度. 通过留 P 法交叉验证了所提方法的鲁棒性和准确性. 由第 2 节相位误差模型分析可得,舰船目标的散焦问题主要来源于复杂运动引起的相位误差. 因此,生成器从散焦问题的本质出发,在距离-多普勒域仅对相位图进行处理,并利用 PECE-Net 在逐距离单元估计相位误差系数,一定程度上降低了解空间的自由度,避免了不同类型舰船目标幅度信息对网络重聚焦性能的不利影响,提升了所提方法的鲁棒性与泛化能力.

4.3.3 网络泛化能力分析

如第 4.1.1 节所述,仿真数据集 I 中包含 5 类不同的舰船目标,每类舰船目标包含 1 200 张样本. 为了衡量模型的泛化能力,使用留 P 法(Leave-P-Out)进行交叉验证. 选取第 1 类舰船目标的 1 200 张样本进行训练,并分别对剩余 4 类舰船目标的样本进行重聚焦验证. 重

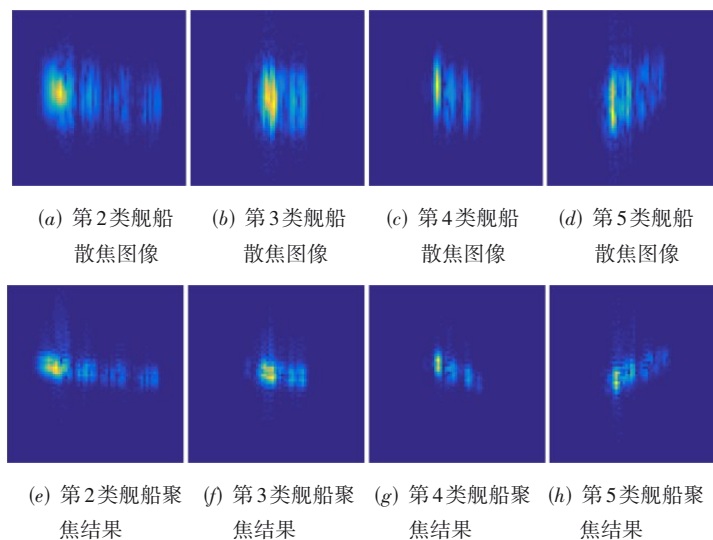


图 15 仿真数据集 I 留 P 法交叉验证重聚焦结果

表4 仿真数据集I留P法交叉验证重聚焦结果指标统计

	MSE	SSIM	图像熵	SCNR/dB
第2类舰船目标	8.75×10^{-4}	0.94	1.15	0.60
处理结果	2.28×10^{-4}	0.99	0.80	14.61
第3类舰船目标	6.87×10^{-4}	0.95	1.11	0.40
处理结果	1.77×10^{-4}	0.99	0.76	16.43
第4类舰船目标	1.08×10^{-3}	0.90	1.90	1.03
处理结果	3.34×10^{-4}	0.97	1.42	13.92
第5类舰船目标	6.47×10^{-4}	0.95	1.04	-0.36
处理结果	1.66×10^{-4}	0.99	0.69	13.26

4.4 仿真数据集II重聚焦结果分析

在仿真数据集II重聚焦实验中,将所提方法与PGA和MEA进行对比,结果如图16所示.使用分别在侧摆转动、俯仰转动、偏航转动和三维转动情况下的四个SAR散焦舰船目标图像对不同方法的重聚焦结果进行可视化展示,如图16所示.图16(a)为舰船静止状态的仿真图像,可作为不同方法聚焦结果的对比参考.但需要注意的是由于舰船目标在成像过程中存在三维转动,其理想聚焦图像与静止状态成像结果之间存在一定程度畸变.从图16(b)可以看出,舰船不同部位的散焦程度是不同的,舰船中心的散焦程度较小,舰船头部和尾部的散焦程度较严重,散焦现象具有空变性,成像结果沿距离向成“X”状.图16(c)(d)(e)分别为PGA、MEA、本文方法的重聚焦结果.PGA方法对三维转动舰船目标的重聚焦效果不佳.MEA方法聚焦效果略优于PGA,但仍残余大量散焦能量.从图16(e)可以看出,所提方法对不同三维转动情况的舰船目标仍然具有较好的聚焦效果,一定程度上恢复出了舰船的形状.

对仿真数据集II的重聚焦效果进行定量分析,结果如表5所示.由表5可得,仿真数据集II的平均图像熵为3.05.与静止成像结果相比,三维转动成果结果的图像熵变大,图像质量变差.经过PGA处理后,各项评价指标均有有限提升,但与原始三维转动散焦图像的各项指标差异很小.MEA的各项指标优于PGA,图像熵降低0.2,SCNR提升约2 dB.本文方法处理后的重聚焦结果在各项评价指标上均表现最佳,MSE降低了约50%,SSIM增加了约0.14,SCNR增加了约4 dB,图像熵降低0.68.由表5的定量评价可得,本文方法在各项指标上均取得了较好的结果,充分体现了本文提出的重聚焦方法在三维转动舰船目标重聚焦方面的有效性.需要注意,表5中各方法MSE、SSIM、SCNR三项指标在计算过程中采用的聚焦图像并不是三维转动舰船目标的理想聚焦结果,而是静止状态聚焦结果,两者之间存在一定畸变.因此表5中各方法的MSE较实际情况偏高,SSIM、SCNR较实际情况偏低.




图16 仿真数据集II不同方法重聚焦结果

表5 仿真数据集II不同方法重聚焦结果指标统计

	MSE	SSIM	图像熵	SCNR/dB
聚焦图像	—	—	0.86	—
散焦图像	2.18×10^{-3}	0.69	3.05	-10.37
PGA	2.07×10^{-3}	0.69	3.02	-10.334
MEA	1.55×10^{-3}	0.73	2.85	-8.33
本文方法	1.24×10^{-3}	0.83	2.37	-6.48

4.5 GF-3数据集重聚焦结果分析

在仿真数据训练的基础上,对GF-3数据进行迁移训练.迁移训练迭代次数为40.迁移训练完成后对GF-3数据集测试样本进行重聚焦,结果如图17所示.在图17(a1)中,舰船的散焦程度沿距离向基本一致,可以判断该舰船目标的运动状态以平动为主.在图17(a2)~(a4)中,舰船首尾两端的散焦程度明显高于舰船中部,可以判断舰船目标的运动状态以三维转动为主.由图17(b1)~(b4)可得,PGA对三维转动舰船目标的重聚焦效果较差,图像仍存在大量散焦.MEA的重聚焦效果与PGA类似,没有有效恢复舰船目标的真实形状.对比图17(a1)~(a4)和图17(d1)~(d4)可得,本文所提方法可有效实现对三维转动舰船目标的重聚焦,即使在如图17(a4)的强杂波环境下也能有效恢复舰船形状.对重聚焦效果进行定量分析可得,散焦图像的图像熵为3.12,PGA的图像熵为2.47,MEA的图像熵为2.65,本文方法的图像熵为2.05.本文方法重聚焦结果图像熵降低约1,量化评价结果充分反映了所提方法在重聚焦性能上的优越性.

为了分析使用CV-CNN构建判别器的优势,采用CNN构造具有相同自由度的实数域判别器架构,并基于幅度图像的对比实验分析可得使用实数域判别器的图像熵为2.36,相较于使用复数域判别器的本文方法图像熵增加0.31,重聚焦性能下降.对比分析结果验证了复数域网络相对于实数域网络的优势.

4.6 计算效率分析

在配置Intel(R) Core(TM) i7-6700 CPU和NVIDIA

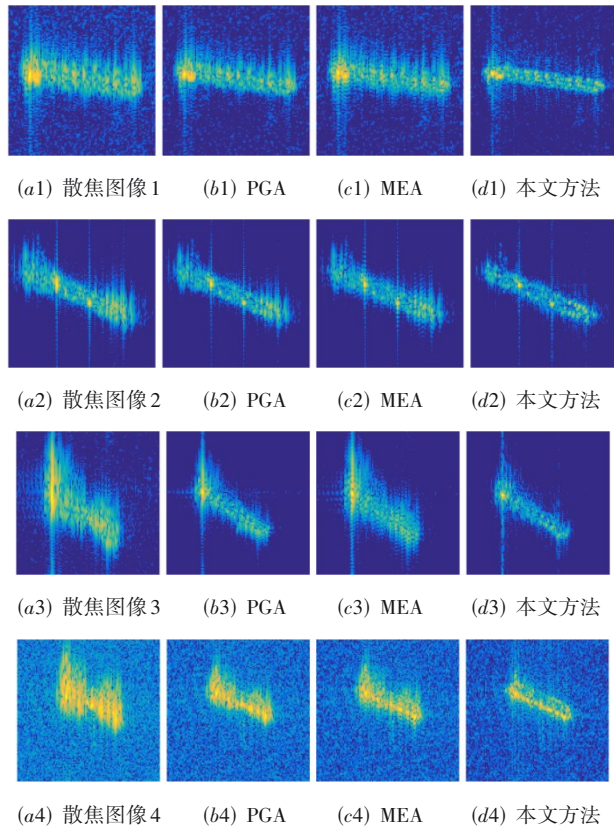


图 17 GF-3数据集不同方法重聚焦结果

GeForce RTX 1080 显卡的计算机上对不同方法的计算效率进行统计分析. 统计各个方法对尺寸为 120×120 的单张散焦图像的处理时间, 结果如表 6 所示. 由表 6 可得, 在各方法处理时间中, PGA 的处理时间最长, 本文方法的处理时间最短. 由于使用显卡进行并行计算的优势, 本文方法处理时间优于基于 PGA 和 MEA 的传统重聚焦方法.

表 6 运算效率统计

重聚焦方法	处理时间/s
PGA	1.46
MEA	0.35
本文方法	0.01

5 结论

本文针对三维转动舰船目标的重聚焦问题, 从 SAR 成像原理出发, 理论推导和分析了舰船三维转动状态对 SAR 成像造成的不利影响. 在此基础上, 以生成对抗思想设计了 SAR 三维转动舰船目标重聚焦方法, 提出了相位误差系数估计网络 PECE-Net 以逐距离单元估计相位误差系数, 基于 CV-CNN 设计判别器网络架构, 推导了网络的前向传播与反向传播算法, 引入了最小熵准则和对抗损失, 以无监督的方式进行网络训练. 通过在仿真数据和 GF-3 数据上的实验, 验证了所提方

法的有效性. 与传统的 PGA 和 MEA 相比, 本文方法具有更小的熵和 MSE, 更大的 SSIM 和 SCNR, 重聚焦精度得到了显著提升.

参考文献

- [1] 李春升, 王伟杰, 王鹏波, 等. 星载 SAR 技术的现状与发展趋势[J]. 电子与信息学报, 2016, 38(1): 229-240.
LI C S, WANG W J, WANG P B, et al. Current situation and development trends of spaceborne SAR technology[J]. Journal of Electronics & Information Technology, 2016, 38(1): 229-240. (in Chinese)
- [2] 张云, 化青龙, 姜义成, 等. 基于混合型复数域卷积神经网络的三维转动舰船目标识别[J]. 电子学报, 2022, 50(5): 1042-1049.
ZHANG Y, HUA Q L, JIANG Y C, et al. Recognition of 3D rotating ship based on mix-CV-CNN[J]. Acta Electronica Sinica, 2022, 50(5): 1042-1049. (in Chinese)
- [3] CALLOWAY T M, DONOHOE G W. Subaperture autofocus for synthetic aperture radar[J]. IEEE Transactions on Aerospace and Electronic Systems, 1994, 30(2): 617-621.
- [4] RAN L, LIU Z, LI T, et al. Extension of map-drift algorithm for highly squinted SAR autofocus[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(9): 4032-4044.
- [5] HUANG Y, LIU F Y, CHEN Z Y, et al. An improved map-drift algorithm for unmanned aerial vehicle SAR imaging [J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(11): 1-5.
- [6] WAHL D E, EICHEL P H, GHIGLIA D C, et al. Phase gradient autofocus—a robust tool for high resolution SAR phase correction[J]. IEEE Transactions on Aerospace and Electronic Systems, 1994, 30(3): 827-835.
- [7] LI Y K, O'YOUNG S. Kalman filter disciplined phase gradient autofocus for stripmap SAR[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(9): 6298-6308.
- [8] YE W, YEO T S, BAO Z. Weighted least-squares estimation of phase errors for SAR/ISAR autofocus[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(5): 2487-2494.
- [9] CHAN H L, YEO T S. Noniterative quality phase-gradient autofocus (QPGA) algorithm for spotlight SAR imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 1998, 36(5): 1531-1539.
- [10] XI L, GUOSUI L, NI J L. Autofocusing of ISAR images based on entropy minimization[J]. IEEE Transactions on Aerospace and Electronic Systems, 1999, 35(4): 1240-1252.

- [11] WANG J, LIU X. SAR minimum-entropy autofocus using an adaptive-order polynomial model[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(4): 512-516.
- [12] ZENG T, WANG R, LI F. SAR image autofocus utilizing minimum-entropy criterion[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(6): 1552-1556.
- [13] BERIZZI F, CORSINI G. Autofocusing of inverse synthetic aperture radar images using contrast optimization[J]. IEEE Transactions on Aerospace and Electronic Systems, 1996, 32(3): 1185-1191.
- [14] ITOH T, SUEDA H, WATANABE Y. Motion compensation for ISAR via centroid tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 1996, 32(3): 1191-1197.
- [15] WANG Y, JIANG Y C. Inverse synthetic aperture radar imaging of maneuvering target based on the product generalized cubic phase function[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(5): 958-962.
- [16] PU W. SAE-net: A deep neural network for SAR autofocus[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5220714.
- [17] LIU Z, YANG S Y, GAO Q W, et al. AFnet and PAFnet: Fast and accurate SAR autofocus based on deep learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5238113.
- [18] LI M, WU J J, HUO W B, et al. STLS-LADMM-net: A deep network for SAR autofocus imaging[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5226914.
- [19] HUA Q L, YUN Z, LI H B, et al. Refocusing on SAR ship targets with three-dimensional rotating based on complex-valued convolutional gated recurrent unit[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 4512405.
- [20] XU X, SU F, GAO J, et al. High-squint SAR imaging of maritime ship targets[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.
- [21] HUA Q L, ZHANG Y, JIANG Y C, et al. CV-CFUNet: Complex-valued channel fusion UNet for refocusing of ship targets in SAR images[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(4): 4478-4492.
- [22] CAO R, WANG Y, ZHAO B, et al. Ship target imaging in airborne SAR system based on automatic image segmentation and ISAR technique[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 1985-2000.
- [23] MAAS A L, HANNUN A Y, Ng A Y. Rectifier nonlinearities improve neural network acoustic models[DB/OL]. (2013) [2023]. http://ai.stanford.edu/~amaas/papers/re-lu_hybrid_icml2013_final.pdf.
- [24] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//Proceedings of the 34th International Conference on Machine Learning (Volume 70). New York: ACM, 2017: 214-223.
- [25] WANG Z. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.

作者简介



化青龙 男, 1995年出生, 安徽阜阳人. 现为哈尔滨工业大学博士. 主要研究方向为雷达图像处理和深度学习网络框架.

E-mail: huaqinglong_hit@163.com



张云 女, 1975年出生, 黑龙江虎林人. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理、SAR成像、机器学习和遥感模式分析.

E-mail: zhangyunhit@hit.edu.cn




任航 男, 2000年出生, 河南新乡人, 现为哈尔滨工业大学博士. 主要研究方向为双基地SAR成像.

E-mail: 21b905060@stu.hit.edu.cn



姜义成 男, 1964年出生, 黑龙江哈尔滨人. 现为哈尔滨工业大学教授、博士生导师. 主要研究方向为雷达信号处理.

E-mail: jiangyc@hit.edu.cn



徐丹 女, 1996年出生, 黑龙江七台河人. 现为哈尔滨工业大学讲师. 主要研究方向为数据分析与智能信号处理.

E-mail: xudanhit@hit.edu.cn