

基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法

陈思伟* 裴子健 戴林裕

(国防科技大学电子科学学院 长沙 410073)

摘要: 极化逆合成孔径雷达(ISAR)是获取卫星目标高分辨率信息的重要手段。简缩极化能够平衡系统复杂度与极化信息容量,目前已广泛应用于各类地基ISAR系统。然而,在卫星过境时,为了调整观测区域,其搭载的天线部件通常会存在相对于卫星本体的独立机械转动。这类运动部件会在回波中引入额外的频率调制,造成ISAR图像散焦。基于深度学习的ISAR图像重聚焦方法通常侧重于目标整体的重聚焦,而忽略了运动部件所引起的频率特征变化,从而导致模型的聚焦性能有限。针对上述问题,该文提出了一种基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法。该方法的核心思想是基于布朗桥扩散模型学习散焦ISAR图像和聚焦ISAR图像之间的映射关系,同时提取ISAR图像的空间特征和频率特征用于引导模型的学习,进而实现运动部件重聚焦。在此基础上,构建了极化ISAR卫星目标电磁仿真数据集并开展了对比实验,结果验证了所提方法具有更好的运动部件聚焦性能和泛化性能。

关键词: 逆合成孔径雷达; 卫星目标; 天线运动; 重聚焦; 扩散模型

中图分类号: TN95

文献标识码: A

文章编号: 2095-283X(2026)x-0001-15

DOI: 10.12000/JR26086

CSTR: 32380.14.JR26086

引用格式: 陈思伟, 裴子健, 戴林裕. 基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26086.

Reference format: CHEN Siwei, PEI Zijian, and DAI Linyu. Refocusing satellite antenna motion in compact polarimetric ISAR images using a spatial-frequency feature-guided brownian bridge diffusion model[J]. *Journal of Radars*, in press. doi: 10.12000/JR26086.

Refocusing Satellite Antenna Motion in Compact Polarimetric ISAR Images Using a Spatial-Frequency Feature-Guided Brownian Bridge Diffusion Model

CHEN Siwei* PEI Zijian DAI Linyu

(College of Electronic Science and Technology, National University of Defense Technology,
Changsha 410073, China)

Abstract: Polarimetric inverse synthetic aperture radar (ISAR) is an important tool for obtaining high-resolution information about satellite targets. Compact polarization provides an optimal balance between system complexity and polarization information capacity and has been widely used in various ground-based ISAR systems. However, during satellite transit, the onboard antenna components often undergo independent mechanical rotation relative to the satellite main body to adjust the observation area. This motion introduces additional frequency modulation into the echo signals, resulting in defocused ISAR images. Existing deep

收稿日期: 2026-04-29; 改回日期: ; 网络出版: 2026-xx-xx

*通信作者: 陈思伟 chenswnudt@163.com *Corresponding Author: CHEN Siwei, chenswnudt@163.com

基金项目: 国家自然科学基金(U24B20189, 62122091), 湖南省科技创新计划项目(2024RC1040)

Foundation Items: The National Natural Science Foundation of China (U24B20189, 62122091), The Science and Technology Innovation Program of Hunan Province (2024RC1040)

责任主编: 高贵 Corresponding Editor: GAO Gui

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

learning-based refocusing methods primarily focus on the global refocusing of ISAR images and often overlook the frequency feature variations induced by component motion, thereby limiting the model's focusing capabilities. To address these challenges, this study proposes a novel refocusing method for satellite antenna motion in compact polarimetric ISAR imaging based on a spatial-frequency feature-guided Brownian bridge diffusion model. The core idea behind this method is to utilize the Brownian bridge diffusion model to learn the intricate mapping between defocused and focused ISAR images. Simultaneously, spatial and frequency features are extracted from the ISAR images to guide this learning process, thereby achieving precise refocusing of the moving components. To validate this approach, an electromagnetic simulation dataset for polarimetric ISAR satellite targets is established, and comparative experiments are conducted. The results show that the proposed method achieves superior performance in refocusing moving components and exhibits enhanced generalization capabilities.

Key words: Inverse Synthetic Aperture Radar (ISAR); Satellite target; Antenna motion; Refocusing; Diffusion model

1 引言

逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)是卫星目标信息获取与监视的主要技术手段^[1-4]。极化ISAR能获取目标的极化散射矩阵,为目标散射机理解译提供支撑。但是全极化系统需要多组正交极化收发通道,导致硬件成本较高,现有大型地基ISAR系统通常采用简缩极化模式^[5-7]。简缩极化是一种特殊的双极化模式,通过单极化发射、双极化接收电磁波,既能获取目标的部分极化散射信息,又能将数据量压缩至两通道,降低系统成本和复杂度。简缩极化ISAR主要有 $\pi/4$ 模式^[8]、双圆极化模式^[9]和混合极化模式^[10]3种,本文主要关注双圆极化模式。

雷达卫星作为目前对地观测的重要手段之一,在过境时为了调整观测区域,其搭载的大型天线部件通常存在独立于卫星本体的机械运动,天线运动会在雷达回波中引入额外的相位与频率调制分量。这类附加调制会破坏方位向聚焦所需的理想相位关系,使得天线部件对应的散射能量无法有效相干积累,进而出现散焦现象。散焦不仅会造成天线区域轮廓模糊、结构细节丢失,还会产生伪影与能量弥散,降低整体ISAR图像的聚焦质量,影响目标特征提取、结构识别、在轨目标分析等后续应用的性能。因此,有必要对天线部件运动导致的散焦进行重聚焦处理,恢复目标清晰的成像结果,从而削弱天线部件运动对成像质量及后续应用的影响。

当前,对此类具有运动部件目标的重聚焦方法主要可以分为基于信号处理的重聚焦方法和基于深度学习的重聚焦方法两类。在基于信号处理的重聚焦方法中,部分研究聚焦于特定运动形式,通过建立准确的部件运动模型,估计其频率、幅度与相位等参数,并据此对回波信号实施补偿处理。

文献[11]提出了一种正弦调频Fourier-Bessel变换算法。通过在传统Fourier-Bessel变换的函数基中引入分辨率参数,提升了分解精度,实现了对多成分微多普勒分量的估计。文献[12]利用子孔径序列成像提取距离多普勒曲线,并构造最小熵优化函数估计部件运动参数,以实现运动补偿功能。然而,此类方法需要针对不同运动形式进行精准建模,对运动模型的准确性要求较高,且所针对的场景较为单一。另一类研究通过预先分离目标主体回波与运动部件回波,而后对两部分分别成像。文献[13]利用目标回波与部件回波在短时傅里叶变换谱图的差异,提出了一种基于短时傅里叶变换谱图滑窗相消的微动杂波去除方法。文献[14]利用目标主体回波和运动部件回波的时频分布差异,提出一种基于变分模态分解与模态优选的重聚焦方法。将变分模态分解扩展至复数域处理ISAR回波数据,并结合图像熵最小化准则优化分解参数与筛选模态,获得了无人机的高分辨率ISAR成像结果。此类方法降低了对运动模型的依赖,但仍面临运动部件信号残留和目标主体成像损失的问题,影响最终ISAR图像的质量。

随着深度学习技术的不断发展,以卷积神经网络(Convolutional Neural Network, CNN)和生成对抗网络(Generative Adversarial Network, GAN)为代表的深度学习方法在重聚焦任务中得到了应用。文献[15]针对地面运动目标设计了一种复值地面运动目标指示网络(Complex Valued Ground Moving Target Indication Network, CV-GMTINet),实现了动目标的重聚焦。文献[16]针对卫星目标整体机动与姿态调整导致的ISAR图像散焦问题,提出了一种端到端的复值图神经网络。通过提取ISAR数据特征形成图节点,利用图结构挖掘节点间

关系,学习卫星目标整体机动和姿态调整给回波带来的高阶项信息,在此基础上完成了基于散焦ISAR图像的卫星目标分类。文献[17]设计了一种端到端的复值生成对抗网络,在仿真数据集和Yak-42飞机的实测数据上验证了重聚焦性能。文献[18]提出了一种用于舰船目标三维旋转重聚焦的复值通道融合U形网络(Complex Valued Channel Fusion U-shape Network, CV-CFUNet),通过GF-3卫星数据验证了方法的有效性。然而,当前基于深度学习的重聚焦方法主要针对由目标整体转动引起的散焦问题,对于目标部件独立于整体运动所导致的散焦情况还鲜有研究。此外,现有方法主要关注ISAR图像的空间特征,忽略了部件运动所引起的频率特征变化,导致模型的聚焦能力有限。

针对上述问题,本文提出了一种基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法,利用扩散模型的前向加噪和反向去噪迭代过程,来学习散焦ISAR图像与聚焦ISAR图像之间的映射关系,从而实现重聚焦。本文的创新点主要包含两方面。首先,设计了空频特征引导模块(Spatial-Frequency Feature Guidance Module, SFFG),在空域捕捉目标纹理、结构等空间信息,在频域补偿部件运动引起的频谱偏移,进而提高重聚焦性能。其次,将扩散模型噪声损失与ISAR图像像素损失结合,在保证图像分布一致性的同时,强化部件边缘、散射中心等结构的保真度,提高重聚焦结果的真实性。

2 简缩极化ISAR卫星天线运动重聚焦方法

简缩极化ISAR卫星天线运动重聚焦的关键在于学习散焦ISAR图像与聚焦ISAR图像之间的映射关系。同时,需关注ISAR图像中的频率特征变化。鉴于布朗桥扩散模型^[19]能够描述固定起始状态和终止状态之间的扩散过程,本节首先介绍简缩极化ISAR数据表征形式。然后,建立用于简缩极化ISAR运动部件重聚焦的布朗桥扩散模型,并构建了一种引导模型聚焦过程的空间特征引导模块。在此基础

上,提出了一种基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法。

2.1 简缩极化ISAR数据表征

在水平和垂直极化基下,全极化模式的极化散射矢量 $\mathbf{k}$ 为

$$\mathbf{k} = [S_{HH} \ S_{HV}; S_{VH}; S_{VV}]^T \quad (1)$$

其中, S_{HV} 为发射垂直极化波,接收水平极化波的后向散射系数,其他项定义类似,上标T为转置操作。

本文面向地基ISAR系统中常用的双圆极化工作模式,基于卫星目标简缩极化ISAR数据开展天线运动重聚焦研究。对于简缩极化中的双圆极化模式,系统发射左旋圆极化电磁波,并同时接收左旋和右旋圆极化回波。此时,其极化散射矢量 $\mathbf{k}_{\text{DCP-L}}$ 可表示为^[9]

$$\begin{aligned} \mathbf{k}_{\text{DCP-L}} &= [S_{LL} \ S_{RL}] \\ &= [(S_{HH} - S_{VV} + 2jS_{HV}) \ j(S_{HH} + S_{VV})]^T/2 \end{aligned} \quad (2)$$

其中, S_{RL} 为发射左旋圆极化电磁波,接收右旋圆极化电磁波的后向散射系数,其他项定义类似。

2.2 布朗桥扩散模型

针对卫星天线运动重聚焦任务,将布朗桥扩散模型建模为图1所示形式。该模型以前向加噪过程将聚焦ISAR图像逐步退化为散焦ISAR图像,反向过程则基于去噪UNet网络实现噪声预测,由散焦ISAR图像生成得到聚焦ISAR图像。

2.2.1 前向过程

对于给定的起点 x_0 和终点 x_T ,起始数据分布经过 T 次迭代得到终点的数据分布,布朗桥过程中的中间态 x_t 的概率分布可表示为^[19]:

$$p(x_t|x_0, x_T) = \mathcal{N}\left(x_t; \left(1 - \frac{t}{T}\right)x_0 + \frac{t}{T}x_T, \frac{t(T-t)}{T}\mathbf{I}\right) \quad (3)$$




图1 卫星天线运动重聚焦布朗桥扩散模型结构图

Fig. 1 Schematic diagram of the Brownian bridge diffusion model for refocusing moving components in satellite targets

其中, T 为布朗桥过程总迭代次数, $\mathbf{I}$ 表示与输入数据 x_0 具有相同维度的单位矩阵。为避免在总迭代次数过多时, 中间状态 $t = T/2$ 所达到的最大方差 $\delta = T/4$ 过大, 将布朗桥扩散模型的前向过程建模为^[19]

$$q(x_t | x_0, y) = \mathcal{N}(x_t; (1 - m_t)x_0 + m_ty, \delta_t \mathbf{I}) \quad (4)$$

$$\delta_t = 2s(m_t - m_t^2) \quad (5)$$

其中, $m_t = t/T$, (x_0, y) 为来自聚焦ISAR图像和散焦ISAR图像的数据对, s 为缩放因子, 用于控制采样过程中的多样性。此时在前向过程中, 方差在初始时刻为0, 在中间状态 $t = T/2$ 时达到最大值 $\delta = 1/2$, 并在 $t = T$ 时重新下降到0。

基于式(4), x_t 和 x_{t-1} 状态的表达式为

$$x_t = (1 - m_t)x_0 + m_ty + \sqrt{\delta_t}\epsilon_t \quad (6)$$

$$x_{t-1} = (1 - m_{t-1})x_0 + m_{t-1}y + \sqrt{\delta_{t-1}}\epsilon_{t-1} \quad (7)$$

其中, $\epsilon_t, \epsilon_{t-1} \sim \mathcal{N}(0, \mathbf{I})$, 将式(6)中 x_0 的表达式代入式(7)中, 可以进一步得到相邻两状态间的前向传播过程为

$$q(x_t | x_{t-1}, y) = \mathcal{N}\left(x_t; \frac{1 - m_t}{1 - m_{t-1}}x_{t-1} + \left(m_t - \frac{1 - m_t}{1 - m_{t-1}}m_{t-1}\right)y, \delta_{t|t-1}\mathbf{I}\right) \quad (8)$$

$$\delta_{t|t-1} = \delta_t - \delta_{t-1} \frac{(1 - m_t)^2}{(1 - m_{t-1})^2} \quad (9)$$

通过前向过程可以得到, 在初始时刻 $t = 0$ 时, x_0 为聚焦ISAR图像。在 $t = T$ 时, 有 $x_T = y$, 此时 x_T 为散焦ISAR图像, 从而完成了聚焦ISAR图像到散焦ISAR图像的转换。

2.2.2 反向过程

在反向过程中, 从散焦ISAR图像数据 y 出发, 基于状态 x_t 来预测 x_{t-1} 的状态, 反向过程的表达式为^[9]

$$p_\vartheta(x_{t-1} | x_t, y) = \mathcal{N}(x_{t-1}; \mu_\vartheta(x_t, t), \tilde{\delta}_{t-1}\mathbf{I}) \quad (10)$$

其中, $\mu_\vartheta(x_t, t)$ 为基于 x_t 在 t 时刻预测得到的 x_{t-1} 的分布平均值, $\tilde{\delta}_{t-1}$ 为 x_{t-1} 的分布方差。 $\tilde{\delta}_{t-1}$ 可基于前向过程参数进行求解, $\mu_\vartheta(x_t, t)$ 则基于反向过程中的去噪UNet网络模型进行预测得到。式(10)将散焦到聚焦的物理过程建模为概率化逆映射, 以散焦图像 y 为初始状态, 通过反向迭代逐步去除对应运动目标高次相位误差的等效噪声, 天然适配ISAR重聚焦中相位非平稳演化的特性, 缓解了传统方法的相位估计误差与残留相位问题。

基于变分推理, 网络的优化目标从以最大概率生成数据 x_0 被转化为优化证据下界(Evidence Lower Bound, ELBO), ELBO的表达式为^[20]

$$L_{\text{ELBO}} = -\mathbb{E}_q(D_{\text{KL}}(q(x_T | x_0, y) \| p(x_T | y))) + \sum_{t=2}^T D_{\text{KL}}(q(x_{t-1} | x_t, x_0, y) \| p_\vartheta(x_{t-1} | x_t, y)) - \log p_\vartheta(x_0 | x_1, y) \quad (11)$$

其中, $D_{\text{KL}}(P \| Q)$ 表示计算分布 P 和分布 Q 之间的Kullback-Leibler散度。由 $x_T = y$, 式(11)中第1项为常数项。由式(4)和式(8), ELBO表达式的第2项可基于贝叶斯定理进行展开, 最终得到的ELBO简化表达式为^[20]

$$L_{\text{ELBO}} = \mathbb{E}_{x_0, y, \epsilon} \left[k_{\epsilon t} \left\| m_t(y - x_0) + \sqrt{\delta_t}\epsilon - \epsilon_\vartheta(x_t, t) \right\|^2 \right] \quad (12)$$

$$k_{\epsilon t} = (1 - m_{t-1}) \frac{\delta_{t|t-1}}{\delta_t} \quad (13)$$

其中, $\mathbb{E}[\cdot]$ 为取均值操作, $\epsilon_\vartheta(x_t, t)$ 为去噪UNet网络根据当前状态 x_t 和当前时间步 t 所得到的预测噪声。式(11)—式(12)将重聚焦转化为端到端优化问题, 通过最小化预测噪声与真实相位误差的均方误差, 实现对散焦相位的自适应校正, 无需手动估计相位参数。式(13)的权重系数可自适应调整不同散焦程度区域的优化权重, 保护重聚焦后图像的细节与精度。

布朗桥扩散模型的最终优化目标为通过训练反向过程中的去噪网络, 使其能够准确预测在前向过程中所加入的噪声, 从而实现从散焦ISAR图像到聚焦ISAR图像的重建。

2.3 空频特征引导模块

为引导模型共同利用空间和频率特征以实现更准确地聚焦, 提出了一种空频特征引导模块。空频特征引导模块以扩散模型反向过程中上层的输出特征、时间步信息以及原始散焦ISAR图像数据作为输入。通过双分支并行结构分别提取空间特征与频率特征, 并基于当前时间步自适应调整特征分量, 实现空频特征的交互融合。空频特征引导模块的整体结构如图2橙色框内所示。

在空间特征提取分支中, 首先通过 1×1 卷积进行特征通道维度转换, 然后依托残差通道注意力模块(Residual Channel Attention Block, RCAB)^[21]对ISAR图像的空间细节、纹理等特征进行提取。




图 2 简缩极化ISAR卫星天线运动重聚焦方法框架

Fig. 2 Compact polarization ISAR satellite target moving components refocusing method framework

RCAB模块由 3×3 卷积操作、LeakyReLU激活函数以及通道注意力层组成。卷积操作用于提取局部空间特征，LeakyReLU激活函数引入非线性变换以增强模型的表达能力。通道注意力层首先对各通道特征进行全局平均池化。然后，经过卷积实现通道间的信息交互与权重分配，使得模型能够关注更重要的通道特征，提升空间特征提取的有效性。最后，通过 1×1 卷积调整输出通道数，以适配后续特征交互操作。空间特征提取分支的表达式为

$$\mathbf{F}_{\text{spatial}} = f_{1 \times 1}(f_{\text{RCAB}}(f_{1 \times 1}(\mathbf{F}_{\text{in}}))) \quad (14)$$

其中， $\mathbf{F}_{\text{in}}$ 和 $\mathbf{F}_{\text{spatial}}$ 分别为空间特征提取分支的输入特征和输出特征， $f_{1 \times 1}$ 为 1×1 的卷积单元， f_{RCAB} 为两个级联的RCAB模块。

在频率特征提取分支中，首先通过二维快速傅里叶变换将ISAR图像数据转换至频域，以获取ISAR图像频域表征。然后，设置与特征图同维度的可学习参数作为频域滤波器对频谱信息进行自适应调制，以学习由部件运动引起的频谱调制特性。最后，由二维傅里叶逆变换将调制后的频率特征变换回图像数据，从而实现图像频域结构的针对性增强与有效整合。频率特征提取分支的表达式为

$$\mathbf{F}_{\text{frequency}} = f_{\text{IFFT}}(f_{\text{filter}}(f_{\text{FFT}}(\mathbf{F}_{\text{in}}))) \quad (15)$$

其中， f_{FFT} 和 f_{IFFT} 分别为二维傅里叶变换和二维傅里叶逆变换。

在特征融合部分，基于当前时间步对空间特征

和频率特征进行自适应加权，同时融入散焦ISAR数据特征。具体地，首先通过正弦位置编码^[22]将时间步长映射为16维向量。然后，通过多层感知机结构分别获取空间和频率特征的加权系数 β, γ ，将空间和频域的特征分别与对应的调制参数进行相乘与相加，实现动态调制。对散焦ISAR数据，经过多层感知机结构进行特征提取。最后，将调制后的空间特征、频率特征以及散焦ISAR数据特征进行相加融合，得到空频特征引导模块的输出特征，模块的表达式为

$$\mathbf{F}_{\text{out}} = (\beta_1 \mathbf{F}_{\text{frequency}} + \gamma_1) + (\beta_2 \mathbf{F}_{\text{spatial}} + \gamma_2) + f_{\text{MLP}}(\mathbf{F}_y) \quad (16)$$

其中， β_1 和 γ_1 分别为频率特征调制的乘法和加法系数， β_2 和 γ_2 分别为空间特征调制的乘法和加法系数， f_{MLP} 为多层感知机结构， $\mathbf{F}_y$ 为散焦ISAR图像数据。

2.4 重聚焦方法整体架构

基于所构建的布朗桥扩散模型与空频特征引导模块，进一步提出了一种基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法，所提方法的整体框架如图2所示。在使用电磁仿真软件获取到回波数据之后，采用经典的极坐标格式算法(Polar Coordinate Formatting Algorithm, PFA)进行成像，得到简缩极化ISAR二维图像数据。该图像中，目标主体在传统成像处理后能够聚

焦, 而天线等运动部件由于在相干积累时间内存在相对转动, 会引入额外相位调制和频率调制, 从而产生成像散焦。本文所提算法即作用于传统成像算法之后的图像域重聚焦环节, 以天线部件处于运动状态时获得的散焦简缩极化ISAR图像作为网络输入, 输出重聚焦后的简缩极化ISAR图像, 期望输出则为对应天线部件处于静止状态时获得的聚焦ISAR图像。

对于复数形式的简缩极化ISAR数据 $\mathbf{k}_{\text{DCP-L}} = [S_{\text{LL}} \ S_{\text{RL}}]$, 采用实虚部分离的形式作为空频特征引导布朗桥扩散模型的输入 $\mathbf{I}_{\text{ref}}$, 数据维度为 $256 \times 256 \times 4$, 表达式为

$$\mathbf{I}_{\text{ref}} = [\text{Re}(S_{\text{LL}}), \text{Im}(S_{\text{LL}}), \text{Re}(S_{\text{RL}}), \text{Im}(S_{\text{RL}})]^T \quad (17)$$

其中, $\text{Re}(\cdot)$ 和 $\text{Im}(\cdot)$ 分别为取复数域数据的实部和虚部操作。

空频特征引导布朗桥扩散模型包含前向过程和反向过程两个阶段。前向过程从聚焦ISAR图像 x_0 出发, 在固定时间步长 T 的控制下, 通过逐步加噪演化散焦ISAR图像 $x_T = y$, 该过程满足固定起点与终点的约束, 构成一个布朗桥随机过程。在本研究中, 时间步长 T 设置为200, 正向过程的方差缩放因子 s 设置为1。反向过程则以去噪UNet模型为主干网络对噪声进行预测, 在每个反向去噪过程中, 除当前噪声状态 x_t 和时间步嵌入 t 外, 进一步通过空频特征引导模块提取图像的空间特征和频率特征并一同输入至去噪UNet网络, 进一步提升对卫星天线运动的聚焦能力, 增强网络的收敛稳定性。此时, 反向过程的表达式为

$$p_{\vartheta}(x_{t-1} | x_t, y) = \mathcal{N}(x_{t-1}; \mu_{\vartheta}(x_t, t, c), \tilde{\delta}_t \mathbf{I}) \quad (18)$$

模型输出得到 S_{LL} 通道和 S_{RL} 通道实数形式的天线运动重聚焦结果 $\mathbf{O}_{\text{ref}}^r$, 然后通过运算 $\mathbf{h}$ 将实数形式的输出数据转换为复数数据 $\mathbf{O}_{\text{ref}}$, 表达式为

$$\begin{aligned} \mathbf{O}_{\text{ref}} &= \mathbf{h}(\mathbf{O}_{\text{ref}}^r) \\ &= [\text{Re}(S_{\text{LL}}^{\text{ref}}) + \text{jIm}(S_{\text{LL}}^{\text{ref}}) \ \text{Re}(S_{\text{RL}}^{\text{ref}}) + \text{jIm}(S_{\text{RL}}^{\text{ref}})]^T \end{aligned} \quad (19)$$

基于式(12), 包含空频特征的ELBO训练损失为

$$\begin{aligned} L_{\text{ELBO}}^c &= \mathbb{E}_{x_0, y, \epsilon, c} \left[k_{\epsilon t} \left\| m_t(y - x_0) \right. \right. \\ &\quad \left. \left. + \sqrt{\delta_t} \epsilon - \epsilon_{\vartheta}(x_t, t, c) \right\|^2 \right] \end{aligned} \quad (20)$$

其中, $\epsilon_{\vartheta}(x_t, t, c)$ 为结合空频特征引导后的得到的预测噪声。

进一步地, 布朗桥扩散模型固有的噪声预测损

失本质是对数据分布的学习, 其更侧重于生成图像在统计特性上与真实样本的一致性。然而, 对于简缩极化ISAR卫星天线运动重聚焦任务而言, 其对聚焦后部件的几何结构、边缘细节等信息要求较高, 仅依靠噪声预测损失往往难以保证像素级的重建精度, 易导致生成结果虽具有合理的统计分布, 却在细节上出现模糊或结构失真。因此, 引入像素损失函数作为网络的补充约束, 计算重聚焦图像与真实聚焦图像在像素空间中的逐点差异, 进一步强化模型对局部结构的生成能力。像素损失函数 L_{pix} 的表达式为

$$L_{\text{pix}} = \sqrt{\|\mathbf{O}_{\text{ref}} - \mathbf{O}_{\text{ref-gt}}\|_1 + \epsilon_{\text{loss}}^2} \quad (21)$$

其中, $\mathbf{O}_{\text{ref}}$ 和 $\mathbf{O}_{\text{ref-gt}}$ 分别为重聚焦图像和真实聚焦图像, ϵ_{loss} 为平滑项, 通常取值为 10^{-3} 。

天线运动重聚焦模型的训练总损失 L_{ref} 为预测噪声损失和像素损失两部分的和, 表达式为

$$L_{\text{ref}} = L_{\text{pix}} + L_{\text{ELBO}}^c \quad (22)$$

3 实验结果与分析

3.1 实验数据介绍

针对当前缺乏公开极化ISAR卫星目标实测数据的问题, 研究团队前期发布了Pol-ISARSpace-Target-1.0电磁仿真数据集^[23]。在此基础上, 本文进一步对含有典型天线运动的卫星目标开展电磁仿真, 构建卫星目标部件静止状态和运动状态的数据集。具体的, 选取搭载平板天线的Lacrosse卫星、Radarsat-2卫星以及搭载抛物面天线的Capella卫星和QPS-SAR卫星, 基于Feko电磁仿真软件^[24]开展电磁计算, 四型卫星电磁仿真示意图如图3所示, 图中蓝色短箭头为雷达电磁波照射方向。

参考文献^[23], 仿真设置的中心频率为16 GHz, 带宽为2 GHz, 电磁波极化方式设置为水平和垂直全极化。俯仰角设置为40°, 45°和50° 3种典型值。鉴于所选目标具有轴对称特性, 同时为保证后续成像处理中对于0°和90°中心方位角能获取完整的成像积累角数据, 设置仿真的方位角范围为-2.5°~92.5°。此外, 综合考虑成像幅宽和目标尺寸, 设置频率步进为0.01 GHz, 方位角的角度步进为0.025°。Lacrosse卫星和Radarsat-2卫星的平板天线绕建立在部件中心坐标系的Y轴转动, Capella卫星和QPS-SAR卫星的抛物面天线绕其部件坐标系的X轴转动。在天线部件运动的情况下, 转速设置为0.12 rad/s和0.15 rad/s, 该转速属于卫星搭载可动天线在波束指向调整、观测区域切换或姿态配合过程中的中低速机械转动量级, 对于地基ISAR观




图 3 含典型天线运动的卫星电磁仿真示意图

Fig. 3 Schematic diagram of satellite electromagnetic simulation with typical moving components

测而言，即使天线部件在单个相干积累时间内只发生微小的转动，也会在回波中引入与目标主体整体运动不同的附加相位调制和频率调制，进而造成局部散焦。因此，该转速具有合理性和代表性^[25,26]。

对于所获取的极化ISAR回波数据，以 0° 为成像中心方位角起始值， 1° 为步进，采用极坐标格式算法PFA^[27]，在 5° 相干积累角和2 GHz带宽条件下进行成像处理，获得目标部件运动状态和静止状态下的配对图像。每类卫星目标共获取273组配对图像，通过频域插值和图像裁剪将图像大小设置为 256×256 ，最终构建包含1092组图像对的数据集。

其中，部件运动状态对应的散焦图像作为网络输入，静止状态对应的聚焦图像作为监督真值，用于计算像素级重建损失。具体而言，对于相干积累期间存在部件转动的ISAR回波，图像散焦主要由孔径内散射中心位置随时间变化所引起的相位误差及空间展宽造成。为构建与散焦样本在物理状态上严格对应的聚焦真值，本文将成像孔径中心时刻的部件姿态选作参考姿态。在真值生成过程中，假设部件在整个相干积累时间内始终保持该参考姿态不变，并采用与散焦图像完全相同的成像参数和处理流程，生成相应的静止聚焦图像。由此，每幅聚焦真值均与其输入散焦图像具有一致的孔径中心姿态，而非由任意静止姿态生成。

因此，网络学习的是由运动状态下的局部散焦图像到其对应孔径中心姿态下聚焦图像的映射。换言之，对于任一运动状态下的输入散焦极化ISAR图像，网络期望输出与该样本成像孔径中心时刻部件姿态相对应的聚焦结果，从而保证输入与真值之间的姿态一致性和物理对应关系。

对于构建的极化ISAR卫星目标电磁仿真数据集 λ_{all} 。按照仿真俯仰角将数据划分为3个子集，记为 λ_{40} 、 λ_{45} 和 λ_{50} ，分别对应 40° 、 45° 和 50° 俯仰角下所有方位角极化ISAR数据，其中 $\lambda_{all} = \lambda_{40} \cup \lambda_{45} \cup \lambda_{50}$ 。在每个子集下按照8: 1: 1的比例划分训练集、验证集和测试集。考虑到简缩极化ISAR数据样本有限，采用跨俯仰角联合训练策略，共设置4种训练场景和3种测试场景。具体地，4种训练场景分别为 $\lambda_{train}^{40,45}$ 、 $\lambda_{train}^{45,50}$ 、 $\lambda_{train}^{40,50}$ 和 λ_{train}^{all} ，3种测试场景分别为 λ_{test}^{40} 、 λ_{test}^{45} 和 λ_{test}^{50} 。其中， $\lambda_{train}^{40,45}$ 表示联合 λ_{40} 和 λ_{45} 数据子集的训练集数据进行训练， λ_{test}^{40} 表示对 λ_{40} 数据子集的测试集进行测试，其他变量定义类似。不同场景的数据情况如表1所示。训练过程中，运动状态和静止状态的数据在相同成像条件下成对生成，其中运动状态成像结果作为网络输入，静止状态成像结果作为监督训练的真值数据，用于计算像素损失并约束模型学习散焦图像到聚焦图像之间的映射关系。

表 1 卫星天线运动重聚焦不同场景数据情况

Tab. 1 Data scenarios for refocusing of moving components in satellite target

场景	俯仰角	数据数量
$\lambda_{\text{train}}^{\text{all}}$	40°, 45°, 50°	876组
$\lambda_{\text{train}}^{40,45}$	40°, 45°	584组
$\lambda_{\text{train}}^{45,50}$	45°, 50°	584组
$\lambda_{\text{train}}^{40,50}$	40°, 50°	584组
$\lambda_{\text{test}}^{40}$	40°	36组
$\lambda_{\text{test}}^{45}$	45°	36组
$\lambda_{\text{test}}^{50}$	50°	36组

3.2 对比实验分析

选取传统的最小熵自聚焦方法(Minimum Entropy, MiniEnt)^[28]和基于深度学习的CV-GMTNet^[15], CV-CFUNet^[18], CVPHD^[17]和扩散模型(Denoising Diffusion Probabilistic Model, DDPM)^[29]作为对比方法。其中, CV-GMTNet和CV-CFUNet为CNN架构, CVPHD为以GAN为主体的生成式网络。实验中训练和测试所使用数据目标部件的转速为0.12 rad/s。所提方法和对比的深度学习方法统一使用Adam优化器对网络模型进行训练, 参数设置为 $\beta_1 = 0.9$, $\beta_2 = 0.999$, 初始学习率设置为 10^{-4} , 训练轮数设置为500。实验硬件配置为Intel Xeon 8336C CPU和8张NVIDIA A800 GPU。

在定量评价方面, 选取平均绝对误差(Mean Absolute Error, MAE)、结构相似性指标(Structure Similarity Index Measure, SSIM)和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)作为定量指标。其中, MAE指标越低表明图像间差异越小, SSIM和PSNR指标越高表明重聚焦效果越好。指标表达式为

$$\text{MAE}(\mathbf{O}_{\text{ref}}, \mathbf{O}_{\text{ref-gt}}) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W \left(\left| \mathbf{o}_{\text{ref}}^{ij} - \mathbf{o}_{\text{ref-gt}}^{ij} \right| \right) \quad (23)$$

$$\begin{aligned} \text{SSIM}(\mathbf{O}_{\text{ref}}, \mathbf{O}_{\text{ref-gt}}) \\ = \frac{(2\mu_{\text{ref}}\mu_{\text{gt}} + c_1)(2\sigma_{\text{ref,gt}} + c_2)}{(\mu_{\text{ref}}^2 + \mu_{\text{gt}}^2 + c_1)(\sigma_{\text{ref}}^2 + \sigma_{\text{gt}}^2 + c_2)} \end{aligned} \quad (24)$$

$$\begin{aligned} \text{PSNR}(\mathbf{O}_{\text{ref}}, \mathbf{O}_{\text{ref-gt}}) \\ = 20\log_{10} \left(\frac{\max(|\mathbf{O}_{\text{ref-gt}}|)}{\sqrt{\text{MSE}(\mathbf{O}_{\text{ref}}, \mathbf{O}_{\text{ref-gt}})}} \right) \end{aligned} \quad (25)$$

$$\text{MSE}(\mathbf{O}_{\text{ref}}, \mathbf{O}_{\text{ref-gt}}) = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W \left(\left| \mathbf{o}_{\text{ref}}^{ij} - \mathbf{o}_{\text{ref-gt}}^{ij} \right|^2 \right) \quad (26)$$

其中, $\mathbf{O}_{\text{ref}}$ 和 $\mathbf{O}_{\text{ref-gt}}$ 分别为重聚焦图像和真实聚焦图像, H 和 W 为ISAR图像的几何尺寸, μ_{ref} 和 μ_{gt} 分别为重聚焦图像和真实聚焦图像的幅度均值, σ_{ref} 和 σ_{gt} 分别为重聚焦图像和真实聚焦图像的幅度标准差, $\sigma_{\text{ref,gt}}$ 为重聚焦图像与真实聚焦图像的幅度协方差, c_1 和 c_2 为非零常数, 通常设置为 10^{-4} , max为取峰值操作。

3.2.1 部件相同转速的对比实验

使用卫星目标部件转速为0.12 rad/s的数据对各个模型进行训练和测试, 比较不同重聚焦方法在部件相同转速条件下的重聚焦性能。不同重聚焦方法得到的4类卫星 S_{LL} 通道和 S_{RL} 通道结果如图4和图5所示。图中每一行为一类卫星目标, 每一列为不同方法重聚焦结果。具体的, 子图(a)为部件运动状态下的ISAR成像结果, 子图(b)为部件静止状态下的参考聚焦真值, 子图(c)至子图(h)分别为最小熵方法(Minimum Entropy, MiniEnt)、CV-GMTNet方法、CV-CFUNet方法、CVPHD方法、DDPM方法和所提重聚焦方法得到的聚焦结果。此外, 为方便对比, 在参考聚焦真值中将不同重聚焦方法显著差异区域用白圈进行标注。可以看到, 所提方法得到的Lacrosse卫星和Radarsat-2卫星平板天线部件结构更为清晰, Capella卫星和QPS-SAR卫星的抛物面天线部件结构更为完整, 与参考聚焦真值更为接近。

基于所划分的4种训练场景和3种测试场景, 计算每种重聚焦方法的MAE, SSIM, PSNR和图像熵指标结果。所有方法在不同训练与测试场景下的MAE, SSIM, PSNR和图像熵指标定量计算结果如表2至表5所示。从12组不同训练与测试场景下定量指标的均值结果来看, 所提方法的MAE, SSIM, PSNR和图像熵指标均值分别为0.742, 0.969, 33.518 dB和4.798 bit, 均取得了最优性能。相较于最优对比方法, 所提方法的MAE和图像熵指标分别降低了4.872%和18.011%, SSIM和PSNR分别提升0.207%和3.511%, 验证了所提方法的性能优势。

3.2.2 部件不同转速的对比实验

为评估不同重聚焦方法对部件转速的泛化能力, 在原有测试集基础上对每类目标增加了部件转速为0.15 rad/s的5帧数据。使用目标部件转速为0.12 rad/s的数据对模型进行训练, 而后对目标部件转速为0.15 rad/s的数据进行推理。在此设置下, 模型训练与测试数据的部件转速不同, 从而对比分析不同重聚焦方法在部件不同转速条件下的性能表现。



图 4 4类卫星不同方法 S_{LL} 通道图像聚焦对比结果Fig. 4 Comparison results of S_{LL} image focusing using different methods for four types of satellites图 5 4类卫星不同方法 S_{RL} 通道图像聚焦对比结果Fig. 5 Comparison results of S_{RL} image focusing using different methods for four types of satellites

表 2 不同重聚焦方法MAE指标结果
Tab. 2 MAE results of different refocusing methods

重聚焦 方法	$\lambda_{\text{train}}^{40,45}$			$\lambda_{\text{train}}^{45, 50}$			$\lambda_{\text{train}}^{40,50}$			$\lambda_{\text{train}}^{\text{all}}$			MAE 均值 ↓
	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	
MiniEnt	-	-	-	-	-	-	-	-	-	1.357	1.429	1.635	1.474
CV-GMTINet	0.948	1.199	1.445	0.936	1.146	1.314	0.905	1.173	1.321	0.940	1.189	1.381	1.158
CV-CFUNet	0.769	0.983	1.260	0.788	1.071	1.157	0.793	1.085	1.173	0.740	0.949	1.134	0.992
CVPHD	0.527	0.648	1.220	1.121	0.627	0.729	0.538	1.098	0.767	0.570	0.704	0.815	0.780
DDPM	0.824	0.834	0.817	0.840	0.810	0.766	0.841	0.819	0.810	0.759	0.766	0.746	0.803
所提方法	0.543	0.677	1.070	0.778	0.702	0.822	0.571	0.915	0.859	0.483	0.663	0.825	0.742

注：MiniEnt为传统的最小熵重聚焦方法，无需进行训练。

表 3 不同重聚焦方法SSIM指标结果
Tab. 3 SSIM results of different refocusing methods

重聚焦 方法	$\lambda_{\text{train}}^{40,45}$			$\lambda_{\text{train}}^{45, 50}$			$\lambda_{\text{train}}^{40,50}$			$\lambda_{\text{train}}^{\text{all}}$			SSIM 均值 ↑
	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	
MiniEnt	-	-	-	-	-	-	-	-	-	0.911	0.924	0.921	0.919
CV-GMTINet	0.935	0.921	0.909	0.938	0.927	0.919	0.942	0.927	0.920	0.936	0.923	0.912	0.926
CV-CFUNet	0.955	0.942	0.924	0.954	0.935	0.932	0.954	0.934	0.931	0.959	0.947	0.936	0.942
CVPHD	0.981	0.977	0.939	0.940	0.979	0.974	0.981	0.944	0.972	0.978	0.973	0.969	0.967
DDPM	0.923	0.903	0.912	0.907	0.918	0.925	0.922	0.905	0.910	0.937	0.949	0.936	0.921
所提方法	0.979	0.973	0.949	0.964	0.972	0.968	0.977	0.956	0.965	0.981	0.975	0.966	0.969

注：MiniEnt为传统的最小熵重聚焦方法，无需进行训练。

表 4 不同重聚焦方法PSNR指标结果(dB)
Tab. 4 PSNR results of different refocusing methods (dB)

重聚焦 方法	$\lambda_{\text{train}}^{40,45}$			$\lambda_{\text{train}}^{45, 50}$			$\lambda_{\text{train}}^{40,50}$			$\lambda_{\text{train}}^{\text{all}}$			PSNR 均值 ↑
	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	
MiniEnt	-	-	-	-	-	-	-	-	-	27.868	28.793	28.542	28.401
CV-GMTINet	30.123	28.663	28.171	29.709	28.346	28.091	29.701	27.815	27.978	30.047	28.800	28.379	28.819
CV-CFUNet	30.471	29.312	27.628	30.637	27.704	28.979	30.740	27.773	28.854	31.369	29.908	29.559	29.411
CVPHD	34.377	34.548	28.974	28.720	34.548	34.745	34.008	28.525	33.191	33.013	32.140	31.782	32.381
DDPM	30.743	30.566	31.253	30.855	30.669	30.352	30.666	30.484	29.132	31.815	32.640	31.318	30.874
所提方法	35.290	33.920	30.521	32.521	33.553	33.611	35.173	30.918	33.106	36.251	34.309	33.042	33.518

注：MiniEnt为传统的最小熵重聚焦方法，无需进行训练。

表 5 不同重聚焦方法图像熵指标结果(bit)
Tab. 5 Image entropy results of different refocusing methods (bit)

重聚焦 方法	$\lambda_{\text{train}}^{40,45}$			$\lambda_{\text{train}}^{45, 50}$			$\lambda_{\text{train}}^{40,50}$			$\lambda_{\text{train}}^{\text{all}}$			熵 均值 ↓
	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	$\lambda_{\text{test}}^{40}$	$\lambda_{\text{test}}^{45}$	$\lambda_{\text{test}}^{50}$	
MiniEnt	-	-	-	-	-	-	-	-	-	7.589	7.614	7.965	7.723
CV-GMTINet	6.812	6.905	7.523	7.418	6.709	6.814	6.721	7.307	6.613	6.508	6.411	6.506	6.854
CV-CFUNet	6.307	6.413	7.019	6.904	6.208	6.312	6.215	6.809	6.106	6.003	5.907	6.011	6.351
CVPHD	5.809	5.914	6.522	6.417	5.706	5.811	5.713	6.308	5.605	5.502	5.409	5.510	5.852
DDPM	6.125	6.224	6.103	6.358	6.225	6.079	6.154	6.056	5.911	5.267	5.342	6.124	5.997
所提方法	4.803	4.908	5.412	5.306	4.704	4.809	4.711	5.207	4.605	4.402	4.308	4.406	4.798

注：MiniEnt为传统的最小熵重聚焦方法，无需进行训练。

以 S_{LL} 通道数据为例,针对不同转速数据,不同重聚焦方法对4类卫星目标所得到的重聚焦结果如图6所示。可以看到,相较于对比方法,所提方法在部件不同转速条件下对Lacrosse卫星和Radarsat-2卫星的平板天线部件、Capella卫星和QPS-SAR卫星的抛物面天线部件的聚焦效果更优,与参考聚焦真值更为接近,验证了所提方法对于部件不同转速的适应能力。

计算每种重聚焦方法在不同部件转速数据上的定量指标结果,所得到的MAE, SSIM, PSNR和图像熵指标的均值如表6所示。可以看到,相较于在相同部件转速数据上的测试结果,各重聚焦方法对

于部件的不同转速数据聚焦性能均有所下滑。然而,所提方法在不同部件转速数据上MAE、SSIM、PSNR和图像熵指标仍取得了最优结果,指标均值分别为0.931, 0.957, 32.410 dB和5.128 bit,说明所提方法对于目标部件的不同转速具有更优的泛化性能。

3.3 消融实验分析

对所提基于空频特征引导布朗桥扩散模型的简缩极化ISAR天线运动重聚焦方法进行消融实验分析,依次移除空频特征引导模块和像素损失函数,以验证各组件的有效性。

将移除空-频特征交互模块的模型定义为模型




图 6 4类卫星不同方法 S_{LL} 通道图像部件不同转速聚焦对比结果

Fig. 6 Comparison results of S_{LL} image focusing using different methods for four satellites under different rotational speeds of components

表 6 不同重聚焦方法在部件不同转速条件下的定量指标的均值

Tab. 6 Mean quantitative indicators of different refocusing methods under different rotational speeds of components

重聚焦方法	MAE ↓	SSIM ↑	PSNR(dB) ↑	图像熵(bit) ↓
MiniEnt	1.468	0.914	27.815	8.679
CV-GMTINet	1.206	0.922	28.962	7.312
CV-CFUNet	0.999	0.945	29.825	6.769
CVPHD	0.974	0.954	30.794	6.413
DDPM	0.982	0.917	29.452	6.554
所提方法	0.931	0.957	32.410	5.128

注：表内加粗数值表示最优。

A, 移除像素损失函数的模型定义为模型B, 不同模型得到的4类卫星 S_{LL} 通道和 S_{RL} 通道图像聚焦对比结果如图7和图8所示, 其中子图(a)为散焦图像, 子图(b)为参考聚焦真值, 子图(c)至子图(e)分别为模型A、模型B和所提方法的聚焦结果。不同模型MAE, SSIM, PSNR和图像熵指标的均值如表7所示。

对于模型A, 移除了空频特征引导模块, 在布朗桥扩散模型的反向过程中缺少额外的空间和频率特征引导, 导致聚焦效果不佳。由表7中的定量指标计算结果可知, 相较所提方法, 模型A的MAE和图像熵指标分别提升3.639%和7.086%, SSIM和PSNR指标分别降低0.310%和1.912%。对于模型B, 移除了像素损失函数, 模型缺乏像素级的误差约束机制, 导致聚焦性能下降。与所提方法相比, 模型B的MAE和图像熵指标分别提升7.412%和5.857%, SSIM和PSNR指标分别降低0.310%和3.022%。上述结果表明, 所提空频特征引导模块和像素损失函数有利于提升天线运动的重聚焦性能。

3.4 方法复杂度与推理效率分析

为对比不同方法复杂度与推理效率, 本文随机选取500帧样本, 进行3次独立重复实验, 并统计各方法的参数量以及在CPU和GPU平台上的单帧推理时间。实验平台配置为Intel Xeon 8336C CPU和NVIDIA A800 GPU。

对于所有深度学习方法, 测试阶段的batch size设置为1。对于传统最小熵自聚焦方法MiniEnt, 其参数设置和迭代停止准则均与原算法^[28]保持一致。具体而言, 在每一阶段内, 若当前图像熵相对于前一次迭代的相对变化量不超过 10^{-4} , 则认为该阶段收敛, 并进入相邻阶段间的收敛性判断; 进一步地, 若相邻两个阶段之间图像熵的相对变化量不超过 10^{-4} , 则算法终止, 否则进入下一阶段继续迭代。每进入一个新的阶段, 相位搜索步长减半。表8给出了各方法的复杂度与推理效率, 其中单帧图像推理时间以3次独立重复实验的“均值 $\pm$ 标准差”表示。

由表8可以看出, 深度学习方法在GPU平台上




图7 4类卫星不同模型 S_{LL} 通道图像聚焦对比结果

Fig. 7 Comparison results of S_{LL} image focusing using different models for four types of satellites




图 8 4类卫星不同模型 S_{RL} 通道图像聚焦对比结果

Fig. 8 Comparison results of S_{RL} image focusing using different models for four types of satellites

表 7 消融实验定量指标的均值

Tab. 7 Mean quantitative indicators for the ablation experiment

方法	模块/损失		MAE ↓	SSIM ↑	PSNR(dB) ↑	图像熵(bit) ↓
	空频特征引导模块	像素损失				
模型A	×	√	0.769	0.966	32.877	5.138
模型B	√	×	0.797	0.966	32.505	5.079
所提方法	√	√	0.742	0.969	33.518	4.798

注：表内加粗数值表示最优。

表 8 方法复杂度与推理效率对比

Tab. 8 Comparison of methods complexity and inference efficiency

方法	参数量 (M)	CPU单帧推理时间 (s)	GPU单帧推理时间 (s)
MiniEnt	-	5.34±0.35	6.47±0.47
CV- GMTINet	12.6	18.87±0.21	0.86±0.08
CV-CFUNet	10.9	17.43±0.19	0.68±0.07
CVPHD	7.8	9.23±0.13	0.47±0.05
DDPM	15.3	169.24±0.53	1.09±0.12
所提方法	18.2	189.34±0.67	1.22±0.09

的推理速度明显快于CPU平台，说明卷积、矩阵乘法和张量运算能够充分利用GPU的并行计算优势。其中，CVPHD在CPU和GPU上的推理时间均最短，分别为 9.23 ± 0.13 s和 0.47 ± 0.05 s。所提方法的推理时间最长，在CPU和GPU上分别为 189.34 ± 0.67 s和 1.22 ± 0.09 s。

传统MiniEnt方法不涉及深度网络参数量统计。由于其采用逐阶段迭代搜索，需要反复更新相位、计算图像熵并判断停止条件，该过程具有较强的顺序性，难以充分利用GPU并行计算。因此，MiniEnt在GPU上的推理时间略高于CPU。此外，

表中各方法3次重复实验的标准差均较小,表明测试结果具有较好的稳定性。

4 结语

本文针对简缩极化ISAR卫星天线运动重聚焦问题,提出了一种基于空频特征引导布朗桥扩散模型的简缩极化ISAR卫星天线运动重聚焦方法。通过布朗桥扩散模型学习散焦ISAR图像与聚焦ISAR图像间的映射关系。同时,设计空频特征引导模块提取ISAR图像的空间和频率特征引导模型的学习。此外,设计像素损失函数强化模型对于目标细节的重聚焦能力。实验结果表明,在模型训练与测试使用相同部件转速数据的条件下,所提重聚焦方法较最优对比方法MAE和图像熵指标分别降低了4.872%和18.011%,SSIM和PSNR指标分别提升0.207%和3.511%。同时,在采用与训练数据不同的部件转速数据进行测试时,所提方法具有更优的泛化性能。还对比了不同方法的计算复杂度,表明所提方法在性能和效率之间取得了较好地平衡。

值得注意的是,本文目前主要基于仿真数据开展方法验证,针对实际场景中的非合作目标,在无先验信息的条件下,存在实测聚焦数据难以获取、运动特征未知等现实挑战。在后续研究中,我们将结合物理先验与半监督/无监督学习思路,探索在缺乏先验信息条件下对非合作目标的重聚焦方法,增强算法在实际场景中的应用可行性。此外,所提方法主要针对天线运动部件引起的散焦问题开展重聚焦研究。值得一提的是,其基本思路并不局限于天线运动部件,也具有拓展至其他类型运动部件重聚焦任务的潜力。在后续研究中,将进一步考虑太阳能帆板、机械臂等其他类型运动部件。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

参 考 文 献

- [1] CUI Xingchao, FU Yaowen, SU Yi, *et al.* Physical parameters joint estimation of satellite parabolic antenna with key frame Pol-ISAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5100416. doi: [10.1109/TGRS.2023.3335960](#).
- [2] LI Mingdian, XIAO Shunping, and CHEN Siwei. Polarimetric ISAR space target structure recognition based on embedded scattering mechanism and semi-supervised representation learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5102019. doi: [10.1109/TGRS.2025.3533930](#).
- [3] 陈思伟. 成像雷达极化旋转域解译: 理论与应用[M]. 北京: 科学出版社, 2024: 1-251.
CHEN Siwei. Imaging Radar Polarimetric Rotation Domain Interpretation: Theory and Applications[M]. Beijing: Science Press, 2024: 1-251.
- [4] CHEN Siwei. Imaging Radar Polarimetric Rotation Domain Interpretation: Theory and Applications[M]. Boca Raton, FL, USA: CRC Press, 2024: 1-260. doi: [10.1201/9781003461296](#).
- [5] LI Mingdian, XIAO Shunping, and CHEN Siwei. Compact polarimetric ISAR space target components recognition with dual-branch correlation aggregation graph attention network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5107917. doi: [10.1109/TGRS.2025.3607102](#).
- [6] LI Mingdian, DENG Junwu, XIAO Shunping, *et al.* NLSAN: A non-local scene awareness network for compact polarimetric ISAR image super-resolution[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5111416. doi: [10.1109/TGRS.2023.3331822](#).
- [7] PEI Zijian, LI Mingdian, and CHEN Siwei. Quad-Pol ISAR data reconstruction from compact-pol mode based on polarimetric and spatial feature aggregation network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 3503705. doi: [10.1109/LGRS.2025.3557943](#).
- [8] SOUYRIS J C, IMBO P, FJORTOFT R, *et al.* Compact polarimetry based on symmetry properties of geophysical media: The $\pi/4$ mode[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 634-646. doi: [10.1109/TGRS.2004.842486](#).
- [9] STACY N and PREISS M. Compact polarimetric analysis of X-band SAR data[C]. The 6th European Conference on Synthetic Aperture Radar, Dresden, Germany, 2006: 1-4.
- [10] RANEY R K. Hybrid-polarity SAR architecture[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(11): 3397-3404. doi: [10.1109/TGRS.2007.895883](#).
- [11] 何其芳, 张群, 罗迎, 等. 正弦调频Fourier-Bessel变换及其在微动目标特征提取中的应用[J]. 雷达学报, 2018, 7(5): 593-601. doi: [10.12000/JR17069](#).
HE Qifang, ZHANG Qun, LUO Ying, *et al.* A sinusoidal frequency modulation fourier-bessel transform and its application to micro-doppler feature extraction[J]. *Journal of Radars*, 2018, 7(5): 593-601. doi: [10.12000/JR17069](#).
- [12] 符吉祥, 邢孟道, 徐丹, 等. 一种基于微波光子超高分辨雷达机翼振动参数估计方法[J]. 雷达学报, 2019, 8(2): 232-242. doi: [10.12000/JR19001](#).
FU Jixiang, XING Mengdao, XU Dan, *et al.* Vibration-parameters estimation method for airplane wings based on microwave-photonics ultrahigh-resolution radar[J]. *Journal of Radars*, 2019, 8(2): 232-242. doi: [10.12000/JR19001](#).
- [13] 万显荣, 谢德强, 易建新, 等. 基于STFT谱图滑窗相消的微动杂波去除方法[J]. 雷达学报, 2022, 11(5): 794-804. doi: [10.](#)

- 12000/JR22157.
- WAN Xianrong, XIE Deqiang, YI Jianxin, *et al.* Micro-doppler clutter removal method based on the cancelation of sliding STFT spectrogram[J]. *Journal of Radars*, 2022, 11(5): 794–804. doi: [10.12000/JR22157](#).
- [14] 李中余, 桂亮, 海宇, 等. 基于变分模态分解与优选的超高分辨ISAR成像微多普勒抑制方法[J]. 雷达学报(中英文), 2024, 13(4): 852–865. doi: [10.12000/JR24043](#).
- LI Zhongyu, GUI Liang, HAI Yu, *et al.* Ultrahigh-resolution ISAR micro-doppler suppression methodology based on variational mode decomposition and mode optimization[J]. *Journal of Radars*, 2024, 13(4): 852–865. doi: [10.12000/JR24043](#).
- [15] MU Huilin, ZHANG Yun, JIANG Yicheng, *et al.* CV-GMTINet: GMTI using a deep complex-valued convolutional neural network for multichannel SAR-GMTI system[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5201115. doi: [10.1109/TGRS.2020.3047112](#).
- [16] ZHANG Yun, YUAN Haoxuan, LI Hongbo, *et al.* Complex-valued graph neural network on space target classification for defocused ISAR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4512905. doi: [10.1109/lgrs.2022.3185709](#).
- [17] YUAN Haoxuan, LI Hongbo, ZHANG Yun, *et al.* High-resolution refocusing for defocused ISAR images by complex-valued Pix2pixHD network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4027205. doi: [10.1109/lgrs.2022.3210036](#).
- [18] HUA Qinglong, ZHANG Yun, JIANG Yicheng, *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. doi: [10.1109/taes.2023.3242233](#).
- [19] LI Bo, XUE Kaitao, LIU Bin, *et al.* BBDM: Image-to-image translation with brownian bridge diffusion models[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, Canada, 2023: 1952–1961. doi: [10.1109/CVPR52729.2023.00194](#).
- [20] KIM S H and CHUNG D. Conditional brownian bridge diffusion model for VHR SAR to optical image translation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 4008305. doi: [10.1109/LGRS.2025.3562401](#).
- [21] ZHANG Yulun, LI Kunpeng, LI Kai, *et al.* Image super-resolution using very deep residual channel attention networks[C]. 15th European Conference on Computer Vision, Munich, Germany, 2018: 294–310. doi: [10.1007/978-3-030-01234-2_18](#).
- [22] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is all you need[C]. The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 6000–6010.
- [23] 陈思伟, 李铭典, 崔兴超. Pol-ISARSpaceTarget-1.0: 极化ISAR空间目标精细识别电磁仿真数据集[J]. 信号处理, 2025, 41(8): 1443–1454. doi: [10.12466/xhcl.2025.08.013](#).
- CHEN Siwei, LI Mingdian, and CUI Xingchao. Pol-ISARSpaceTarget-1.0: Polarimetric ISAR electromagnetic simulation dataset for space target fine recognition[J]. *Journal of Signal Processing*, 2025, 41(8): 1443–1454. doi: [10.12466/xhcl.2025.08.013](#).
- [24] 刘源, 焦金龙, 王晨, 等. FEKO仿真原理与工程应用[M]. 北京: 机械工业出版社, 2017: 1–512.
- LIU Yuan, JIAO Jinlong, WANG Chen, *et al.* Principles and Engineering Applications of FEKO Simulation[M]. Beijing: China Machine Press, 2017: 1–512.
- [25] 侯庆森, 李光祚, 徐仲秋, 等. 基于联合运动参数快速估计的空间目标ISAR成像方法[J]. 雷达学报(中英文), 2025, 14(2): 424–438. doi: [10.12000/JR24251](#).
- HOU Qingsen, LI Guangzuo, XU Zhongqiu, *et al.* A ISAR imaging method for space targets based on fast estimation of joint motion parameters[J]. *Journal of Radars*, 2025, 14(2): 424–438. doi: [10.12000/JR24251](#).
- [26] SHE Yuchen, LI Shuang, LI Yinkang, *et al.* Slew path planning of agile-satellite antenna pointing mechanism with optimal real-time data transmission performance[J]. *Aerospace Science and Technology*, 2019, 90: 103–114. doi: [10.1016/j.ast.2019.04.028](#).
- [27] LIPPS R and KERR D. Polar reformatting for ISAR imaging[C]. IEEE Radar Conference, RADARCON'98. Challenges in Radar Systems and Solutions, Dallas, USA, 1998: 275–280. doi: [10.1109/NRC.1998.678014](#).
- [28] LI Xi, LIU Guosui, and NI Jinlin. Autofocusing of ISAR images based on entropy minimization[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1999, 35(4): 1240–1252. doi: [10.1109/7.805442](#).
- [29] HO J, JAIN A, and ABBEEL P. Denoising diffusion probabilistic models[C]. The 34th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2020: 574.

作者简介

陈思伟, 教授, 主要研究方向为极化雷达成像、目标识别与机器学习等。

裴子健, 硕士生, 主要研究方向为极化逆合成孔径雷达图像处理与解译等。

戴林裕, 博士生, 主要研究方向为极化雷达图像超分辨率重建、相干斑滤波等。

(责任编辑: 于青)