

一种信号外推和层级学习SAR超分辨率方法

王 焱, 王 潇, 高宇洋, 董刚刚*

(西安电子科技大学雷达信号处理国家重点实验室, 陕西西安 710071)

摘要: 成像分辨率是合成孔径雷达(Synthetic Aperture Radar, SAR)系统最为重要的指标参数, 更高分辨能力的成像结果能显著提升图像层次, 使得目标轮廓、纹理及散射特性更清晰, 有效抑制相干斑噪声对细节的污染, 从而为下游图像解译与信息提取提供更稳健的底层物理表征。经验理论建模的方法物理意义清晰、理论推导严密, 但在拟合实际数据时容易出现模型失配, 且忽略历史信息。先验数据驱动的方法特征表示与数据拟合能力强, 但无法考虑相干成像原理, 理论可解释性差。对此, 提出一种信号外推与层级融合的SAR单视复图像超分辨率新方法。首先, 根据SAR成像原理进行频域补零的信号外推, 完成初始对齐任务, 实现理论可解释外推。其次, 在此基础上设计包括双模交叉学习特征学习和精细化特征融合重建的超分辨率专属学习框架, 通过卷积与Transformer的双模交叉学习机制, 从初始对齐图像挖掘高层语义表征与细节电磁特征, 其中卷积分支用于局部特征学习, Transformer分支用于长时窗依赖建模, 并设计残差跨层特征融合完成精细重建, 实现SAR单视复图像超分辨率重建。最后, 针对通用指标无法对SAR成像质量进行全面客观评价的问题, 构建SAR超分辨率评价体系, 从可视化聚焦、点目标成像、相位保真度等维度客观评价重建结果。利用实测数据开展大量实验验证, 结果表明所提方法可提高峰值信噪比(Peak Signal-to-noise Ratio, PSNR) 6.27 dB, 同时降低峰值旁瓣比5.85 dB。

关键词: SAR超分辨率; 信号外推; 多尺度对齐; 层级学习

基金项目: 国家自然科学基金(No.61971324, No.62571400)

中图分类号: TN95

文献标识码: A

文章编号: 0372-2112(2026)02-0601-10

电子学报URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250767

A Novel SAR Super-Resolution Method via Signal Extrapolation and Hierarchical Learning

WANG Yan, WANG Xiao, GAO Yuyang, DONG Ganggang*

(National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract: The quality of SAR imaging was important for the downstream tasks. The classical methods were relied on the parameterized models to fit the measured data, and hence suffered from mismatch. The learning-driven methods ignored the coherent imaging mechanism and phase information. To solve these problems, a new complex-valued SAR image super-resolution method via signal extrapolation and hierarchical learning was proposed in this paper. It was composed of three phases, signal extrapolation, dual-mode cross learning, and hierarchical fusion. The spatial alignment of amplitude and phase was first achieved by the imaging operation on the zero-padded frequencies. Then, a cross learning of convolution and Transformer was employed to capture the high-level semantic information. Finally, the high-resolution SAR image was formed by feature refinement. On this basis, an evaluation system composed of the vision metrics, the imaging metrics, and the phase congruency were presented. Extensive rounds of experiments demonstrated that the proposed method improved the peak signal-to-noise ratio (PSNR) by 6.27 dB, the peak sidelobe ratio (PSLR) by 5.85 dB.

Keywords: SAR super-resolution; signal extrapolation; multi-scale alignment; hierarchical learning

Foundation Item(s): National Natural Science Foundation of China (No.61971324, No.62571400)

0 引言

SAR (Synthetic Aperture Radar) 广泛应用于广域监视与侦察预警、环境监测与灾害评估以及资源勘探等领域^[1]。图像分辨率是反映传感器性能的重要指

标^[2], 分辨率越高, 从图像中获取的信息就越丰富, 对下游图像解译任务的支撑效果越好^[3-4]。因此, 对成像分辨率的不断改善, 始终是SAR信号处理的永恒目标, 它既能提高可视化效果, 也能有效提升图像解译精度。

收稿日期: 2025-09-04; 录用日期: 2026-02-04; 责任编辑: 朱梅玉

*通信作者: 董刚刚

(1) 参数化建模超分辨率

根据 SAR 相干成像原理可知,导致图像分辨率退化的主要因素有:一是数据采集和成像过程中不可避免的相位误差残余,如系统噪声、运动误差和非理想成像条件等,SAR 高分辨率成像依赖于雷达与目标之间的相对运动关系,但非理想运动模型也会产生相位误差,使得成像质量退化。二是雷达系统硬件限制,SAR 成像距离向高分辨率依赖于发射信号带宽,方位向分辨率与相干积累能量有关,更高的分辨率需要更大带宽或更长积累时间,但同时又对数据存储、传输和实时处理等提出更高的要求。因此,通过信号处理技术提升成像质量更具现实意义,经典的方法包括以下3种。

谱估计方法。SAR 超分辨率成像的关键是从受噪声污染的观测数据中精确重构目标特征,因此可建模为二维谱估计问题。与传统傅里叶变换不同,现代谱估计通过优化谱分析算法突破瑞利极限,包括非参数化与参数化两类。非参数化方法无需预设模型,直接从观测数据中提取频谱信息,如自相关图分析、加窗周期图法及 BT 谱估计等。参数化方法采用数学模型对信号进行结构化描述,然后根据测量数据估计模型参数,如自适应最小方差谱估计算法、幅相联合估计算法、迭代优化算法,以及子空间分解等。

带宽外推。外推是利用信号已知的部分信息推测整体信息,它依赖于严格的理论约束前提。对于满足能量有限条件的连续频带受限信号,理论上只需获取其任意有限区间的连续采样数据,即可重构信号在整个时域的完整形态。Brito 等人^[5]提出一种自适应加权范数的相位恢复方法,通过恢复子孔径或全组频率样本相位历史,将其外推到更大孔径,获得超分辨率成像结果。张平和杨汝良^[6]提出一种最小加权范数约束和最小方差谱估计的 SAR 超分辨率方法,外推相位历史场的有效带宽,成像质量优于自适应加权范数外推方法。Biondi^[7]提出一种针对线性调频信号电磁攻击的频谱复原方案,首先确定频谱攻击区域和范围,然后利用较低分辨率数据对剩余频谱信息进行聚焦成像,实现频谱外推重建。

正则化求逆。本质是将对目标区域的观测及成像过程建模为数学求逆问题,然后确定散射源在斜平面内的空间分布及其对应的后向散射强度参数,如早期的 Tikhonov 和全变分等,以及稀疏表示和低秩约束等。He 等人^[8]将压缩感知与多词典学习相结合,通过稀疏编码空间金字塔机进行分类,结合多字典学习进行训练,实现 SAR 图像超分辨率重建方法。王伟伟等人^[9]提出一种面向条带式成像的稀疏孔径 SAR 成像方法,首先沿方位向以部分子孔径采样获取稀疏数据并进行匹配滤波,然后对方位向使用小波基作为

场景散射系数的稀疏基,通过求解最小 L1 范数重构散射系数,实现方位向降采样条件下无模糊成像。

(2) 数据驱动学习超分辨率

以“无监督样本预训练”与“逐层梯度下降最优化”等为代表的深度学习逐渐成为近年来的主流超分辨率重建学习策略,如卷积网络、循环网络、Transformer 网络及其改进策略等,实现从低质数据到高分辨率成像的回归。Lim 等人^[10]提出一种基于卷积模型的超分辨率增强深度网络(Enhanced Deep Residual Networks, EDSR),剔除传统残差网络中不必要的模块提高稳定性,同时扩展模型规模进一步改善学习效果。文献[11]针对高低频信息利用不充分等问题,提出更深层残差信道注意网络(Residual Channel Attention Network, RCAN),通过残差结构加深网络层级,并包含具有短跳转连接的残差块,同时允许跳跃连接绕过丰富的低频信息,使主网络专注于学习高频信息。另一种解决思路是利用生成模型实现超分辨率重建,如生成对抗网络(Generative Adversarial Network, GAN),它通过构建生成器和鉴别器,以对抗博弈的思想同时进行训练,从而根据输入的低质数据生成高分辨率成像。针对最小化均方重建误差的优化超分辨率学习方法重建结果具有较高的峰值信噪比,但缺乏高频细节,无法与更高分辨率所预期的保真度相匹配。Ledig 等人^[12]提出一种用于图像超分辨率的生成对抗网络(Super-resolution Generative Adversarial Network, SRGAN),使用对抗性损失和内容损失组成的感知损失函数进行训练,对抗性损失使鉴别器更高效地区分超分辨率结果和原始图像。文献[13]提出一种两阶段扩散模型的超分辨率方法,首先利用全球尺度数据对模型进行预训练获取初始估计,然后将其与卫星数据相结合合成雷达反射率作为扩散模型的条件。文献[14]提出一种归一化数据超分辨率的流生成模型,将不确定性量化引入超分辨率学习过程,从捕获高分辨率数据缺失信息的高斯潜在空间中采样,生成不同超分辨率重建结果,并使用不同尺度样本增强训练样本,增强泛化能力适应不同尺度数据。

(3) 本文的解决方案

近年来 SAR 超分辨率研究取得显著进展,但现有方法仍面临一些问题和挑战:一是参数化建模超分辨率方法根据理论模型拟合实际测量数据,难以保证参数估计精度,也容易出现模型失配,影响图像解译。二是数据驱动的超分辨率学习策略,主要关注视觉重建过程中散射强度损失,相位分量却被忽略。三是现有研究的评价针对性不强,使用峰值信噪比和结构相似度等图像视觉指标,无法客观评判重建结果。对此,本文提出一种带宽外推和层级学习的理论可解释

SAR 单视复图超分辨率新方法。首先根据成像原理设计带宽外推模块,通过频域补零成像实现低分辨率成像初始对齐;其次,在此基础上提出卷积与 Transformer 双模交叉学习,从初始对齐结果挖掘高层语义表征与细节电磁特征;最后,设计残差跨层特征融合完成对齐学习,实现超分辨率重建。进一步构建包括视觉差异指标、成像质量指标、相位保真指标的评估体系,从不同角度评价超分辨率重建结果。本文贡献如下:一是设计面向 SAR 超分辨率任务的神经网络框架,利用历史数据随机采样学习 SAR 成像退化原理,实现可学习、可积累的 SAR 超分辨率重建。二是将相干成像原理与优化学习策略相结合,实现物理可解释超分辨率重建。三是构建 SAR 超分辨率评价体系,从可视化聚焦、点目标成像、相位保真度等维度全面评价重建质量。

1 SAR 信号模型

一般 SAR 成像过程可抽象为信号与点扩散函数的卷积^[15-16]。

$$s_r(x) = h(x) * s(x) = \int h^*(\zeta - x) \cdot s(\zeta) d\zeta \quad (1)$$

其中: h 为系统脉冲响应; s, s_r 表示发射与接收信号。

$$s_r(\hat{t}, t_m) = \exp\left(j2\pi f_c \left(t - \frac{2R_k}{c}\right) + j\pi K \left(\hat{t} - \frac{2R_k}{c}\right)^2\right) \cdot \sigma_k \cdot \text{rect}\left(\frac{\hat{t} - \frac{2R_k}{c}}{T_p}\right) \quad (3)$$

其中, σ_k 为散射系数。脉冲压缩后距离分辨率取决于发射信号带宽,方位向分辨率取决于多普勒带宽,压缩结果呈 sinc 函数形状,包络随方位角位置时延不同,导致距离方位耦合,通过距离徙动校正进行聚焦:

$$s(\hat{t}, t_m) = \sigma_k \cdot \text{sinc}\left[\pi B_r \left(\tau - \frac{2R_0}{c}\right)\right] \cdot \text{sinc}\left[\pi B_d t_m\right] \quad (4)$$

其中: B_r 和 B_d 分别为发射信号带宽和多普勒带宽,通过傅里叶变换谱估计可生成 SAR 图像; R_0 为目标最短距离。

2 SAR 超分辨率方法

针对经典 SAR 超分辨率方法在实际场景中容易模型失配,现有方法忽略成像原理与相位、可解释性弱等问题,本文提出一种信号外推和层级学习的 SAR 超分辨率新方法,包括信号外推空间初始对齐、双模交叉学习特征细化和特征融合对齐重建,整体框架如图 1 所示。


2.1 信号外推

与视觉超分辨率不同, SAR 超分辨率需要精确重建幅度与相位,相位反映电磁波传播过程中的路径信息,但现有方法通常忽略成像原理与相位信息。对此,本文根据成像原理设计信号外推,将低质 SAR 图

计算自相关函数 $r_{ss}(k) = \mathbb{E}[s_r^*(n)s_r(n+k)]$, 估计功率谱密度函数 $p(f) = \sum_{k=-(N-1)}^{N-1} \omega(k)r_{ss}(k)\exp(-j2\pi f k)$, 其中 $\omega(\cdot)$ 为窗函数, 对其进行傅里叶变换得到的频域表示 $S(\omega) = H(\omega)F(\omega)$ 。因此, 成像本质可看作二维复正弦函数参数估计问题, 等效为基于傅里叶滤波器构建的线性系统约束条件下的变量求解。若要估计带宽外信息, 需获取频段外信号先验知识。由于目标散射强度非负, 它在散射场支撑域内 $s(x) > 0$, 若假设支撑域为矩形区域, 信号频谱分为带内和带外两部分 $S(\omega) = [S_{in}(\omega) + S_{out}(\omega)] \otimes \text{sinc}(X_\omega)$, 由于 sinc 函数支撑区域为 $(-\infty, +\infty)$, 卷积时带宽外频谱与带宽内频谱混合, 表明目标带宽外频谱可通过系统传递函数混合到带宽内频谱, 因此通过提取带外信息实现超分辨率处理理论上是可行的。若假设雷达发现调频斜率为 K 的线性调频信号:

$$s(\hat{t}, t_m) = \text{rect}\left(\frac{\hat{t}}{T_p}\right) \exp\left(j2\pi f_c t + \pi K \hat{t}^2\right) \quad (2)$$

其中: f_c 为雷达载频; $t_m = mT_r$ 为脉冲重复周期整数倍; $\hat{t} = t - t_m$ 是快时间; T_p 是脉冲宽度; R_k 为雷达与目标之间的瞬时距离, 则接收到的回波信号为



注: RFRG 表示残差融合重建模组。

图 1 信号外推与层级学习 SAR 超分辨率整体框架

Figure 1 Overall framework of signal extrapolation and hierarchical learning for SAR super-resolution

像投影至距离-方位二维频域,并补零填充,使其与参考图像进行空间初始对齐,然后重新转换至图像域,提取初始对齐结果的浅层特征:

$$I_z = \mathcal{F}^{-1}\left(\mathcal{Z}\left(\mathcal{F}(I_r)\right)\right) \quad (5)$$

其中: \mathcal{F} 表示距离-方位傅里叶变换; \mathcal{Z} 表示补零操作; \mathcal{F}^{-1} 表示从频域到图像域的逆傅里叶变换。为了适应后续的双模交叉混合学习,用空间初始对齐结果复数据 I_z 表示两通道张量,然后引入 3×3 滤波器的卷积运算从初始对齐结果提取浅层特征, $F_z = \otimes_3(R(I_z))$, 其中 \otimes_3 表示 3×3 滤波器的卷积运算,

$R(I_z)$ 表示将空间初始对齐结果重置为两通道张量。采用信号外推进行空间初始对齐从而避免相位失真。

2.2 双模交叉学习

将初始对齐结果输入双模交叉混合学习模块,实现从全局到局部的层级学习与特征细化。双模学习包括卷积和Transformer两种模式,其中卷积分支利用小尺寸滤波器核提取图像局部特征,Transformer分支通过加权注意力机制学习全局特征^[17]。整个学习框架包括多个残差融合重建模组,如图2所示,卷积分支提取局部特征,Transformer提取全局特征,然后进行组合和优化。




图2 双模交叉学习机制

Figure 2 Dual-mode cross-learning mechanism

卷积分支。为挖掘不同尺度细节特征,将不同尺度的滤波结果以跨层跳接的方式进行组合,通过堆叠的层级卷积运算提取初始对齐成像结果的局部特征,形成如图3所示卷积分支。首先将输入的特征图分成两部分,分别输入两个分支并行处理,其中第一个分支包含 3×3 卷积层和GELU(Gaussian Error Linear Unit)激活函数,目的是在最优分辨率单元情况下提取更多的局部细节特征;第二个分支采用最大池化层对输入特征进行降维处理,随后使用 1×1 卷积层和GELU激活函数进一步增强特征表达,获取结构信息。两个分支的输出特征图以拼接的方式进行组合,并通过 1×1 卷积层进行特征合并,引入跳跃连接挖掘多尺度信息。

Transformer分支。Transformer分支通过长时窗线

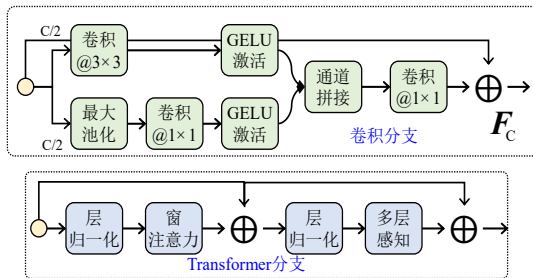


图3 双模分支及异形注意力机制

Figure 3 Dual-mode branches and heteromorphic attention mechanism

将卷积分支的输出 F_C 使用 1×1 、 3×3 滤波器卷积 \otimes_1 、 \otimes_3 生成查询 $Q \in \mathbb{R}^{H \times W \times C}$,对Transformer分支

性加权的注意力学习机制获取更大时空窗口的全局信息^[18-19],与卷积学习模式形成互补,如图3所示。针对SAR图像中地物地形与典型目标特点,采用窗高和宽不等的矩形窗自注意力学习机制 S_A^{Rw} ,将其划分为水平窗 H_{Rwin} 和垂直窗 V_{Rwin} ,通过矩形窗移位扩展特征感受野,获取更多方向细节信息。假设输入特征为 $F_{in} \in \mathbb{R}^{H \times W \times C}$,将其划分为 $\frac{H \times W}{S_h \times S_w}$ 个矩形窗,其中 s_h 和 s_w 分别是矩形窗高和宽度。对于第 i 个窗口特征 $F_i \in \mathbb{R}^{(s_h \times s_w) \times C}$,计算查询 Q 、键 K 和值 V :

$$Q_i = F_i W_i^Q, K_i = F_i W_i^K, V_i = F_i W_i^V \quad (6)$$

其中, $W_i^Q \in \mathbb{R}^{C \times d}$, $W_i^K \in \mathbb{R}^{C \times d}$ 和 $W_i^V \in \mathbb{R}^{C \times d}$ 表示投影加权矩阵,自注意力计算过程为


$$S_A(Q_i, K_i, V_i) = \text{softmax} \left(\frac{Q_i K_i^T}{\sqrt{d}} + B \right) V_i \quad (7)$$

其中: B 表示动态相对位置编码,对数值 V 执行卷积操作以增强局部提取能力; d 为特征维度。注意力头分组,计算自注意力,然后将其进行拼接输出:

$$S_A^{Rw}(X) = \oplus (V_{Rwin}, H_{Rwin}) W^P \quad (8)$$

其中: $W^P \in \mathbb{R}^{C \times C}$ 表示用于融合特征的线性投影; V_{Rwin} 、 H_{Rwin} 分别表示垂直和水平矩形窗口注意力,然后通过多层感知机完成特征转换,得到Transformer分支特征 F_T 。

特征融合模块。将卷积分支的输出作为先验查询 Q ,Transformer分支的输出用于提供键 K 和值 V ,通过交互注意力机制,对Transformer分支的全局特征进行优化,实现交叉混合学习,如图4所示。同时挖掘空间维与通道维蕴含的重要信息,执行通道维交互注意力,探索通道依赖性,并降低计算复杂度^[20]。由于空间维 N 远大于通道维 C ,键值线性加权计算复杂度为 $O(N^2C)$,计算效率很低。对此,本文采用通道注意力法将二次项转移到通道维度 $O(NC^2)$,从而有效降低计算复杂度,详见表1。



输出 F_T 先进行层归一化,然后采用与查询类似的操作获得键 $K \in \mathbb{R}^{H \times W \times C}$ 和值 $V \in \mathbb{R}^{H \times W \times C}$ 。之后对 Q 、 K




图4 双模特征融合模块

Figure 4 Dual-modal feature fusion module

表 1 通道注意力计算复杂度分析

Table 1 Computational complexity analysis of channel attention

	参数量	加/乘法次数	FLOPs
全局注意力	\$424.4 \times 10^3\$	\$1.61 \times 10^9\$	\$4.15 \times 10^9\$
通道注意力		\$3.14 \times 10^6\$	\$1.73 \times 10^9\$

注: FLOPs 为每秒浮点运算数量。

和 V 执行重置, 得到 $\hat{Q} \in \mathbb{R}^{C \times HW}$ 、 $\hat{K} \in \mathbb{R}^{C \times HW}$ 和 $\hat{V} \in \mathbb{R}^{C \times HW}$, 然后计算交互注意力 I_A :

$$I_A(\hat{Q}, \hat{K}, \hat{V}) = \text{Softmax}\left(\frac{\hat{Q}\hat{K}^T}{\alpha}\right)\hat{V} \quad (9)$$

其中, α 为可学习参数。将细化后的特征添加到 F_T 得到融合后的输出 F_{fuse} , 将其传递给改进的前馈网络进一步聚合特征。通过引入门控机制, 充分提取空间和通道信息, 最终提高模型性能。

$$F_{\text{fuse}} = \oplus(I_A(F_C, N_L(F_T)), F_T) \quad (10)$$

$$F_R = \oplus(\phi_{\text{IMLP}}(N_L(F_{\text{fuse}})), F_{\text{fuse}}) \quad (11)$$

其中: I_A 表示交互注意力机制, 指在精细化全局表示之前引入局部信息; N_L 表示层归一化。

2.3 融合重建成像

将卷积与 Transformer 交叉混合学习结果进行层级特征融合, 以有监督的方式进行对齐学习, 实现超分辨率重建成像, 如图 5 所示。

构造 3×3 小尺寸滤波卷积模块对交叉混合学习特征进行聚合, 同时将信号外推结果与特征学习结果进行跨阶段连接, 更好地保留不同类型信息:

$$I_r = \otimes_3(\oplus(F_R, F_z)) \quad (12)$$

其中: I_r 为参考图像; F_R 为 RFRG 模组获取的深层特征; F_z 为信号外推空间对齐阶段得到的浅层特征; \oplus 表示通道聚合。最终以监督引导的方式获取 SAR 超分辨率重建结果。

2.4 优化学习策略

为获取最优网络参数与配置实现高效推理, 本文提出一种层级度量的损失量化策略, 包括局部损失、结构损失和全局损失三部分, 其中局部损失是由预测结果与理论成像的像素级差异组成, 结构损失是由预测结果与理论成像的结构相似度组成, 全局损失是由




图5 融合重建模块

Figure 5 Fusion reconstruction module

预测结果与理论成像的特征级差异组成。

局部损失。相干积累形成的 SAR 图像中, 每个像素均由相邻若干个散射子相干叠加而成, 图像普遍存在大量的斑点噪声即相干斑, 它对重建结果造成严重干扰。对此, 假设参考图像与推理结果之间的重建误差服从 Laplace 分布, 使用 $\ell_c(I_1, I_r) = \|S_r(I_1) - I_r\|_1$ 量化它们的统计差异, 其中 I_1 为输入低质数据, $S_r(\cdot)$ 表示超分辨率模型抽象映射。 ℓ_c 损失度量对异常值不敏感, 在处理含噪声或异常像素的图像时可展现出更强的鲁棒性, 从而有效应对成像场景强杂波以及斑点噪声带来的不利影响, 抑制重建过程中异常像素的误差累积, 更好地重建目标散射特性。

结构损失。为使预测的成像结果在局部细节上尽可能接近理论成像结果, 引入结构相似度 (Structural Similarity Index, SSIM) 进行损失度量, $\ell_s(I_1, I_r) = 1 - \text{SSIM}(I_1, I_r)$, 约束重建结果与参考图像在局部区域的统计差异。理论上结构相似度的取值区间为 $[0, 1]$, 预测结果与理论成像越相似, 则结构相似度越接近于 1, 否则趋近于 0。

全局损失。为使预测结果与理论重建保持相似的宏观电磁散射特性, 定义全局损失为预测训练神经网络提取的深层特征之间的差异, 将预测结果与理论成像输入预训练的神经网络, 提取中间层特征进行相似性比对^[21]。假设用 $\phi(I)$ 表示从输入图像提取中间层抽象特征, 则全局损失定义为 $\|\phi(I_1) - \phi(I_r)\|_2^2$ 。最终的目标函数为局部损失、全局损失与结构损失的线性加权。

3 SAR 超分辨率成像质量评价

针对现有方法计算视觉差异, 难以得出客观的评价结果, 本文分别从可视化聚焦、点目标成像、相位保真度等维度进行评价^[22]。其中, 可视化聚焦采用图像视觉常用指标, 如结构相似度、峰值信噪比等, 量化重建结果与参考图像的统计差异; 特显点目标使用分辨指标, 如峰值旁瓣比、积分旁瓣比和脉冲响应宽度, 评估旁瓣水平、主瓣分辨能力等。

可视化聚焦。是指从视觉差异的角度来衡量

SAR 超分辨率方法对幅度分量的重建精确度,主要包括峰值信噪比、结构相似性指数^[23],以及学习感知图像块相似性(Learned Perceptual Image Patch Similarity, LPIPS)^[24],LPIPS 是利用预训练的特征提取网络提取抽象特征并计算相似性。

点目标成像。是根据特显点目标评价 SAR 成像质量的标准方法,包括峰值旁瓣比(Peak Side Lobe Ratio, PSLR)、积分旁瓣比(Integrated Side Lobe Ratio, ISLR)和冲激响应宽度(Impulse Response Width, IRW)。其中,PSLR 是指第一个旁瓣与主瓣的峰值高度比,用于评估在强点目标附近识别弱目标的能力,以 dB 为单位;ISLR 是指分辨率单元外部的能量与分辨率单元内部的能量之比;IRW 是冲激响应的 3 dB 主瓣宽度 $\Delta\tau_{3\text{dB}} = \tau_2 - \tau_1$ 。对于实测数据,通常选取图像中的特显目标,对其中心区域切片进行若干倍(如 8 倍、16 倍)的插值并作归一化处理,生成幅度剖面曲线,然后计算评估指标,如图 6 所示。




图 6 点目标成像指标计算方法

Figure 6 Calculation methods for point target imaging metrics

相位保真度。与可见光被动成像不同,雷达图像是通过测量发射电磁波的回波信号所获得,通过中频正交采样形成复图像,现有的方法通常忽略相位重建。对此,本文提出相位保真度评价方法,首先计算成像质量改善结果与参考图像之间相位的绝对误差 $E = |\phi(I_s) - \phi(I_r)|$,其中 ϕ 表示 SAR 图像相位,然后统计误差分布区间 $\delta_k = \Omega(\tau_{k-1} < E \leq \tau_k)$,其中 Ω 表示像素占比统计。

4 实验结果与分析

4.1 实验设置

SAR 实测数据。为了验证所提方法在不同地形、不同场景的超分辨率效果,本文采用桑迪亚国家实验室的机载实测数据集进行实验,测试平台于 2006 年 2 月 14 日进行飞行实验,共采集 64 景 SAR 图像数据。该数据集来源于两次飞行任务,分别标记为“上午”和“下午”。每次飞行任务包含 32 幅在美国新墨西哥阿尔伯克基附近采集的聚束 SAR 图像。每次飞行任务进一步划分为 8 个航段,每个航段包含 4 幅图像。

图像数据为原始复数 SAR 数据文件,图像尺寸为 $3\,000 \times 1\,754$ 像素。为开展不同倍数的超分辨率重建实验,同时考虑到算力的限制,将原始的多景数据分别裁剪为 256×256 大小的切片,然后根据实验要求以频率截断的方式构建数据集,随机划分训练集和测试集,进行指标验证。

实验设置。训练过程采用 Adam 优化器,参数设置为 $\beta_1 = 0.9, \beta_2 = 0.999$,初始学习率为 2×10^{-4} ,批大小为 16,利用 NVIDIA 3060 GPU 实现并行计算。SAR 超分辨率网络设置 4 个细化特征组(Refined Feature Group, RFRG),每个包含 1 个卷积分支和 2 个 Transformer 分支,特征通道数、注意力头数和多层感知机(Multilayer Perceptron, MLP)扩展比分别设置为 48、6 和 2,增量多层感知机(Incremental Multi-Layer Perceptron, IMLP)扩展比设置为 2.66。针对矩形窗自注意力机制参数,分别进行三种不同窗参数实验,如表 2 所示,最终采用 $[4, 8]$ 矩形窗。为评价所提方法的有效性,分别从可视化聚焦、点目标成像、相位保真度等维度与基线方法进行比较,包括信号外推成像^[25]、线性插值(Bicubic)^[26],以及 SRGAN(生成对抗网络)^[12]、EDSR(卷积学习模型)^[10]、RCAN(残差学习模型)^[11]、SwinIR(Transformer 模型)等学习方法。

表 2 异形窗注意力机制消融实验

Table 2 Ablation study on heteromorphic window attention mechanism

窗参数	4×8	2×8	4×16
SSIM	0.933 8	0.926 3	0.904 9
PSNR	32.05	31.47	32.12

4.2 可视化评价

首先利用实测数据,分别进行 2 倍和 4 倍的 SAR 超分辨率重建实验,对结果进行视觉评价,实验结果如表 3 所示,其中 LPIPS 使用 VGGNet 预训练网络模型进行评价。双三次插值是指在映射点的邻域内通过三次线性加权进行对齐,补零成像是将 SAR 图像逆向投影至波数域,然后进行补零成像实现重建,次优方法是指重建指标仅次于所提方法。

可以看出,无论是 2 倍重建或是 4 倍重建,所提方法均显著优于基线方法,其中 PSNR 和 SSIM 指标显著提升。以 2 倍重建实验为例,PSNR 最多提升 6.27 dB(插值),最少提升 2.37 dB(EDSR),SSIM 最多提升 13.63%(插值),最少提升 3.88%(信号外推),LPIPS 指标最多下降 0.103 7(SwinIR)、最少下降 0.010 5(信号外推)。对于 4 倍重建实验,也能得出类似的结果。究其原因,本文方法将卷积模式与 Transformer 架构的优势相结合,实现双模交叉混合学习,从而改善特征学习效率。

通过实验可知:一是线性插值效果最差,明显逊

表3 SAR超分辨率可视化评价结果(2×/4×)

Table 3 Visual evaluation results of SAR super-resolution (2×/4×)

方法	PSNR/dB	SSIM	LPIPS
双三次插值	32.81/26.67	0.759 4/0.483 8	0.173 8/0.404 1
SRGAN	36.57/28.97	0.851 4/0.561 2	0.161 4/0.398 8
EDSR	36.71/29.02	0.853 9/0.566 9	0.161 0/0.383 6
RCAN	36.60/29.15	0.851 5/0.565 5	0.172 8/0.396 1
SWinIR	33.21/27.14	0.781 0/0.545 6	0.221 0/0.403 8
补零成像	35.79/27.51	0.856 9/0.545 6	0.128 9/0.391 9
所提方法	39.08/33.84	0.895 7/0.690 4	0.118 4/0.335 8
次优方法	2.37/4.69 ↑	3.88%/12.35%	0.010 5/0.047 8
最大提升	6.27/7.17 ↑	13.63%/20.66%	0.103 7/0.068 3

注:加粗数据为最优结果。

于深度学习方法,因为 SAR 图像每个像素都是相邻若干个散射子的相干叠加,线性插值的方法很难精确重建后向散射系数;二是信号外推的方法综合效果甚至优于深度学习的拟合策略,因为 SAR 成像相位分量受相干成像的影响,随机性较强,直接使用深度学习策略进行拟合,不考虑雷达成像原理,学习效果并不理想;三是与卷积学习模型相比,Transformer 模型(SWinIR)的学习效果稍逊,甚至比信号外推结果还差,因为 Transformer 更擅长于对长时窗的建模与学习,对局部特征的重建效果不理想;四是本文方法首先使用信号外推实现空间对齐,充分考虑相干成像原理,然后借助卷积模块与 Transformer 模块的交叉混合学习,实现二者的优势互补,从而提高超分辨率重建质量。

4.3 点目标评价

图像指标评价本质是统计差异度量,它依赖于参考图像。与之不同,成像质量评价重点分析点目标分辨能力和旁瓣水平,通过计算点目标峰值旁瓣比、积分旁瓣比和冲激响应宽度衡量成像效果。为确保剖面曲线的连续性,提高数值计算精度,本文对点目标中心区域切片进行 16 倍的插值并做归一化处理,生成幅度剖面图用于定量评估,计算不同成像指标,实验结果如表 4 所示,其中不同方法的点目标成像样例如图 7 所示。

可以看出,传统方法的点目标分辨率提升有限,如 RCAN 方法的结果甚至差于原始成像。尽管基于深度学习的超分辨率方法如 RCAN、SwinIR 在视觉效果上接近高分辨率图像,但未能保持目标点聚焦特性,RCAN 方法在采样切片中呈现出多个邻近的亮点特征,导致轮廓失真和伪影,水平与垂直方向的幅度剖面曲线表明,尽管基线方法的冲激响应宽度更小,

但导致目标电磁特性失真,且旁瓣水平显著提升。相比之下,本文提出的方法在各项评估指标中均表现出显著优势,PSLR、ISLR 和 IRW 接近甚至超过参考图像,完整保留目标结构与分辨特性。

通过实验可知:一是直接将视觉图像超分辨率方法应用于 SAR 图像并不能得到理想的学习效果,以 RCAN 方法为例,从点目标成像的角度来看其推理结果甚至逊于原始成像,如 PSLR 指标和 ISLR 指标。二是充分挖掘 SAR 成像原理对于优化学习策略的超分辨率方法起着十分重要的作用,如补零结果优于线性插值,表明将成像理论与优化学习相结合可显著提升网络学习效果,也增加物理可解释性。

表4 SAR超分辨率点目标评价结果(2×)

Table 4 Point target evaluation results of SAR super-resolution (2×)

方法	距离向			方位向		
	PSLR	ISLR	IRW	PSLR	ISLR	IRW
原始成像	-17.28	-13.57	180	-22.16	-15.57	163
次插值	-14.96	-12.31	236	-12.81	-11.57	291
补零	-13.71	-10.48	239	-14.85	-11.25	243
RCAN	-18.77	-16.83	135	-5.49	-4.38	74
SRGAN	-19.89	-14.13	175	-19.41	-13.96	194
SwinIR	-19.20	-15.00	246	-14.21	-11.71	267
所提方法	-22.04	-15.70	175	-22.74	-16.25	166




图7 超分辨点目标结果

Figure 7 Super-resolution results of point targets

4.4 相位保真度评估

SAR 成像本质是对观测地域的反演,其中幅度分量取决于观测场景的后向散射系数,相位分量则与电磁波传播路径有关,它们均对图像解译和信息获取有十分重要的作用。与现有方法相比,本文所提方法的显著特点之一是可对相位分量进行精确重建。对此,实验章节最后对不同方法的相位重建误差进行验证,与幅度分量不同,相位分量的值域区间为 $[-\pi, \pi]$,误差的取值区域是 $[0, 2\pi]$,将其以 $\frac{\pi}{8}$ 间隔划分成 16 个量化区间,统计其误差占比,实验结果如图 8 所示。

为进一步验证 SAR 超分辨率重建的几何精度,图 9 展示了所提方法方位-距离剖面曲线对比结果,并使用地球移动距离(Earth's Moving Distance, EMD)量化重建效果。可以看出,所提方法的重建 EMD 误差在 10^{-2} 量级左右,表明几何重建精度较高。

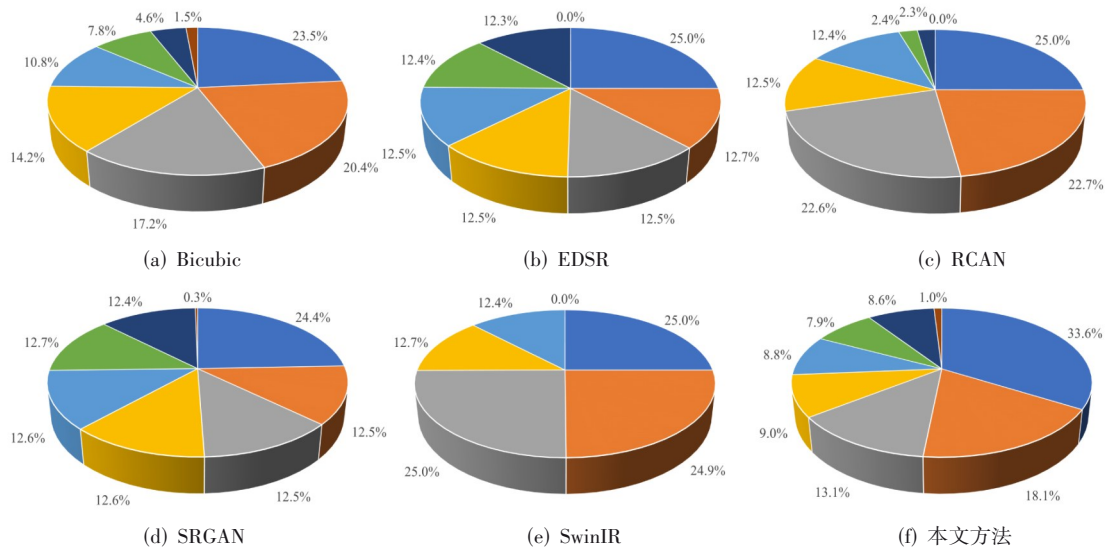


图 8 SAR 超分辨率相位评价结果
Figure 8 Phase evaluation results of SAR super-resolution

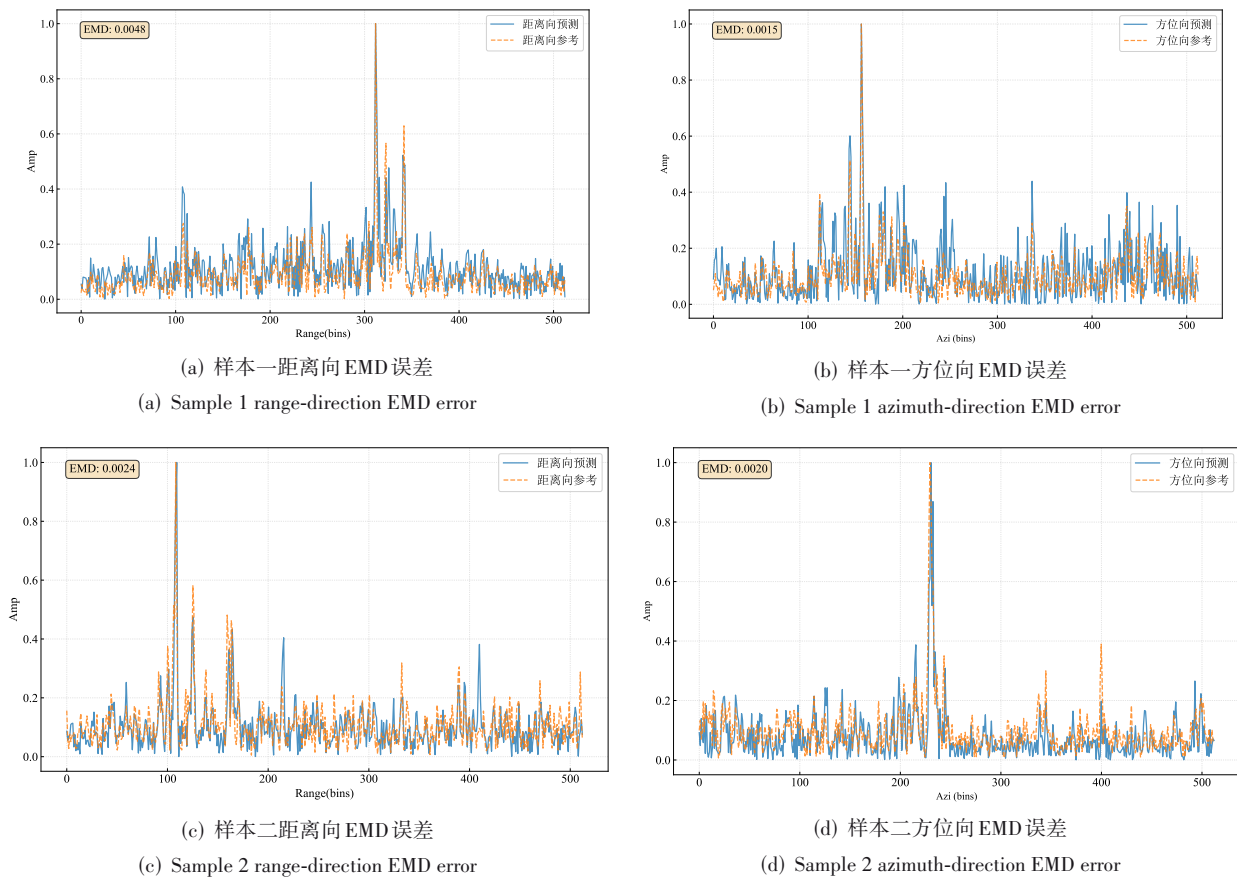


图 9 SAR 方位-距离剖面曲线重建及 EMD 距离
Figure 9 Reconstruction of SAR azimuth-range profile curves and EMD distance

5 结论

针对经典 SAR 超分辨率方法忽略历史数据、现有学习方法不考虑 SAR 相干成像原理的实际,本文提

出一种信号外推与层级学习的理论可解释 SAR 超分辨率新方法,首先根据相干成像原理构建超分辨率专属模型,包括信号外推、双模交叉学习与融合重建,

信号外推阶段借鉴 SAR 成像原理设计频域补零再成像实现空间初始对齐,双模学习阶段采用卷积与 Transformer 交叉混合学习实现特征细化,并最终以监督约束的方式实现特征融合重建成像。为提高学习效率,设计局部损失、结构损失、全局损失进行组合优化。在此基础上,构建 SAR 超分辨率质量评价体系,从可视化聚焦、点目标成像、相位保真度三个维度进行全面、客观评价。通过实测数据的实验验证表明,与基线与经典方法相比,所提方法既能提高结构相似度、峰值信噪比、LPIPS 等可视化效果,也能改善峰值旁瓣比、积分旁瓣比、3 dB 带宽等点目标成像质量。

参考文献

- [1] 杨汝良. 高分辨率微波成像[M]. 北京: 国防工业出版社, 2013.
Yang Ruliang. High resolution microwave imaging[M]. Beijing: National Defense Industry Press, 2013. (in Chinese)
- [2] 董刚刚, 匡纲要, 刘宏伟. 合成孔径雷达目标识别[M]. 北京: 人民邮电出版社, 2026.
Dong Ganggang, Kuang Gangyao, Liu Hongwei. Synthetic aperture radar target recognition[M]. Beijing: Posts & Telecom Press, 2026.
- [3] Zhao Guowei, Jiang Jiaqing, Dong Ganggang, et al. SAR ship detection via knowledge transfer: From optical image[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2025, 18: 17526-17538.
- [4] 赵国威, 蒋嘉庆, 董刚刚. 跨模态渐进式知识迁移 SAR 目标检测技术[J]. 电子学报, 2025, 53(9): 3147-3162.
Zhao Guowei, Jiang Jiaqing, Dong Ganggang. Cross-modal SAR target detection via progressive knowledge transfer[J]. Acta Electronica Sinica, 2025, 53(9): 3147-3162. (in Chinese)
- [5] Brito A E, Chan S H, Cabrera S D. SAR image super-resolution via 2-D adaptive extrapolation[J]. Multidimensional Systems and Signal Processing, 2003, 14(1/2/3): 83-104.
- [6] 张平, 杨汝良. 合成孔径雷达空间变迹带宽外推超分辨率算法[J]. 测绘学报, 2010, 39(1): 71-75.
Zhang Ping, Yang Ruliang. A new SAR superresolution algorithm based on apodization extrapolation[J]. Acta Geodaetica et Cartographica Sinica, 2010, 39(1): 71-75. (in Chinese)
- [7] Biondi F. Recovery of partially corrupted SAR images by super-resolution based on spectrum extrapolation[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(2): 139-143.
- [8] He Chu, Liu Longzhu, Xu Lianyu, et al. Learning based compressed sensing for SAR image super-resolution[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(4): 1272-1281.
- [9] 王伟伟, 廖桂生, 张磊, 等. 一种基于压缩感知的稀疏孔径 SAR 成像方法[J]. 电子学报, 2012, 40(12): 2487-2494.
Wang Weiwei, Liao Guisheng, Zhang Lei, et al. An imaging method based on compressive sensing for sparse aperture of SAR[J]. Acta Electronica Sinica, 2012, 40(12): 2487-2494. (in Chinese)
- [10] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2017: 1132-1140.
- [11] Zhang Yulun, Li Kunpeng, Li Kai, et al. Image super-resolution using very deep residual channel attention networks[C]//Computer Vision - ECCV 2018. Cham: Springer, 2018: 294-310.
- [12] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 105-114.
- [13] He Xuming, Zhou Zhiwang, Zhang Wenlong, et al. DiffSR: Learning radar reflectivity synthesis via diffusion model from satellite observations[C]//ICASSP 2025 - 2025 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2025: 10888161.
- [14] Shen Jingyi, Shen Hanwei. PSRFlow: Probabilistic super resolution with flow-based models for scientific data[J]. IEEE Transactions on Visualization and Computer Graphics, 2024, 30(1): 986-996.
- [15] 王国栋, 周荫清, 李春升. SAR 图像超分辨与点扩展函数扰动校正算法[J]. 北京航空航天大学学报, 2000, 26(6): 640-643.
Wang Guodong, Zhou Yinqing, Li Chunsheng. SAR Bayesian super-resolution algorithm with a correction of perturbed point spread function[J]. Journal of Beijing University of Aeronautics and Astronautics, 2000, 26(6): 640-643. (in Chinese)
- [16] 王正明, 朱炬波, 谢美华. SAR 图像提高分辨率技术[M]. 2 版. 北京: 科学出版社, 2013.
Wang Zhengming, Zhu Jubo, Xie Meihua. Technique of SAR image superresolution[M]. 2nd ed. Beijing: Science Press, 2013. (in Chinese)
- [17] Zamir S W, Arora A, Khan S, et al. Restormer: Efficient transformer for high-resolution image restoration[C]//

- 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 5718-5729.
- [18] Li Ao, Zhang Le, Liu Yun, et al. Feature modulation transformer: Cross-refinement of global representation via high-frequency prior for image super-resolution[C]// 2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2023: 12480-12490.
- [19] Zhang Xindong, Zeng Hui, Guo Shi, et al. Efficient long-range attention network for image super-resolution[M]// Computer Vision - ECCV 2022. Cham: Springer Nature Switzerland, 2022: 649-667.
- [20] 周登文, 李文斌, 李金新, 等. 一种轻量级的多尺度通道注意图像超分辨率重建网络[J]. 电子学报, 2022, 50(10): 2336-2346.
Zhou Dengwen, Li Wenbin, Li Jinxin, et al. Image super-resolution reconstruction based on lightweight multi-scale channel attention network[J]. Acta Electronica Sinica, 2022, 50(10): 2336-2346. (in Chinese)
- [21] Kim J, Oh J, Lee K M. Beyond image super-resolution for image recognition with task-driven perceptual loss[C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2024: 2651-2661.
- [22] 吕彤光, 陆仲良, 粟毅, 等. 冲激信号 SAR 成像的方位分辨率分析[J]. 电子学报, 2000, 28(6): 40-43.
Lü Tongguang, Lu Zhongliang, Su Yi, et al. The analysis of the azimuth resolution of impulse signal SAR[J]. Acta Electronica Sinica, 2000, 28(6): 40-43. (in Chinese)
- [23] Wang Zhou, Bovik A C, Sheikh H R, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [24] Zhang R, Isola P, Efros A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 586-595.
- [25] Kusano S, Sato M, Yokota Y. Data interpolation and resampling for a synthetic aperture radar data[C]// 2011 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2011: 652-655.
- [26] Parker J A, Kenyon R V, Troxel D E. Comparison of interpolating methods for image resampling[J]. IEEE Transactions on Medical Imaging, 1983, 2(1): 31-39.

作者简介



王焱 男, 1999年8月出生于山西省晋城市。现为西安电子科技大学信息与通信工程专业在读研究生。主要研究方向为雷达信号处理、目标检测与深度学习及其在信息系统的应用。

E-mail: wy1582275925@163.com



王潇 男, 2002年10月出生于江西省南昌市。现为西安电子科技大学电子工程学院在读研究生。主要研究方向为雷达信号处理、SAR运动目标检测与深度学习及其在信息系统的应用。

E-mail: 25021211782@stu.xidian.edu.cn



高宇洋 男, 2001年出生于河南省洛阳市。现为西安电子科技大学电子工程学院在读研究生。主要研究方向为雷达信号处理、SAR超分辨率成像。

E-mail: 23021211877@stu.xidian.edu.cn



董刚 男, 1982年11月出生于陕西省西安市。现为西安电子科技大学教授、博士生导师。2012年和2016年获得国防科技大学工学硕士与博士学位。主要研究方向为雷达成像、智能信息处理、目标检测识别、遥感图像解译等。获2017年度中国电子学会优秀博士学位论文。

E-mail: donggang@nudt.edu.cn