

基于自注意力字典学习的稀疏ISAR成像方法

胡长雨^{1,2,3}, 王宇², 程远³

(1. 无锡学院电子信息工程学院, 江苏 无锡 214000; 2. 南京航空航天大学雷达成像与微波光子技术教育部重点实验室, 江苏 南京 210000; 3. 中国航空工业集团雷华电子技术研究所, 江苏 无锡 214000)

摘要: 稀疏逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)成像方法能在有限观测条件下重建出图像对比度高、虚假散射点少的目标图像。结合稀疏变换字典的稀疏ISAR成像方法能够进一步提升目标轮廓和散射点分布的重建质量。然而, 在低压缩比条件下, 此类方法仍易出现目标轮廓重建不完整的问题。其根本原因在于稀疏变换字典所提取的稀疏表示仅能刻画目标的局部结构特征与散射分布特性, 难以充分表征目标的全局结构特征与散射分布特性。为增强稀疏表示对全局结构特征的表征能力, 本文引入自注意力机制(Self-Attention Mechanism, SAM)以指导字典学习(Dictionary Learning, DL), 使得稀疏变换字典能够从测量数据中充分学习目标的全局结构特征。结合SAM的DL模型称为SAM-DL, 进一步提出基于SAM-DL的稀疏ISAR成像方法, 用于低压缩比条件下目标成像。成像结果表明, 相较于现有的DL类成像方法, SAM-DL成像方法在低压缩比条件下重建的目标轮廓更完整, 成像性能更优越。

关键词: 逆合成孔径雷达; 稀疏成像; SAM-DL; 字典学习; 自注意力机制

中图分类号: TN95

文献标志码: A

Sparse ISAR Imaging Method Based on Self-Attention Dictionary Learning

HU Changyu^{1,2,3}, WANG Yu², CHENG Yuan³

1. School of Electronic Information Engineering, Wuxi University, Wuxi 214000, China

2. Key Laboratory of Radar Imaging and Microwave Photonics Technology of the Ministry of Education, Nanjing University of Aeronautics and Astronautics, Nanjing 210000, China

3. China Aviation Industry Corporation Leihua Electronic Technology Research Institute, Wuxi 214000, China

Abstract: Sparse inverse synthetic aperture radar (ISAR) imaging methods are capable of reconstructing target images with high contrast and few artifacts under limited observation conditions. Incorporating sparse transform dictionaries into sparse ISAR imaging can further enhance the reconstruction quality of target contours and scattering distributions. However, these methods still tend to produce incomplete target contours under conditions of low compression ratios. This limitation arises because the sparse representations derived from sparse transform dictionaries primarily capture local structural or scattering features of the target, while failing to sufficiently represent the global structural and scattering features of the target. To strengthen the modeling of global structures within sparse representations, we introduce a self-

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 胡长雨, changyu_hu@cw Xu.edu.cn

基金项目: 国家自然科学基金资助项目(No. 62501274); 江苏省高等学校基础科学(自然科学)研究面上项目(No. 23KJB510035); 南京航空航天大学雷达成像与微波光子技术教育部重点实验室开放基金资助项目(No. NJ20230006); 无锡学院人才科研启动经费资助项目(No. 2023r014)

Foundation Items: The National Natural Science Foundation (No. 62501274); The General Program of Basic Science (Natural Science) Foundation of the Jiangsu Higher Education Institutions (No. 23KJB510035); The Key Laboratory of Radar Imaging and Microwave Photonics Technology (Nanjing University of Aeronautics and Astronautics), Ministry of Education (No. NJ20230006); Wuxi University Research Start-up Fund for Introduced Talents (No. 2023r014)

attention mechanism (SAM) to guide dictionary learning (DL), enabling the sparse transform dictionary to effectively capture global structural features of target from under-sampled measurements. The resulting DL model is referred to as SAM-DL, and we further develop the SAM-DL based sparse ISAR imaging method for target reconstruction under low compression ratios. Experimental results demonstrate that, compared with existing DL-based imaging approaches, the SAM-DL method is able to reconstruct more complete target contours under low compression ratios, achieving superior imaging performance.

Key words: inverse synthetic aperture radar (ISAR), sparse imaging, SAM-DL, dictionary learning, self-attention mechanism

0 引言

逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)是非合作目标探测的重要手段之一^{[1]-[2]}。传统 ISAR 成像方法为距离-多普勒(Range-Doppler, RD)类成像方法。RD 类成像方法成像效率较高,但其成像结果容易受到旁瓣和虚假散射点干扰,成像方法容易失效。

稀疏类 ISAR 成像方法^{[2]-[8]}(包括压缩感知(Compressive Sensing, CS) ISAR 成像方法^{[9]-[15]})通常基于目标相对于背景的稀疏性,通过对压缩采样数据的反演实现目标散射分布的高精度重建。然而,大多数稀疏成像方法多集中于增强目标强散射点,对目标弱散射回波或局部结构性特征的利用有限,往往导致重建目标轮廓不够连续或部分区域结构表达不充分。为进一步提升重建效果,有研究^[11]在稀疏成像模型中引入更加细粒度的结构化先验或区域特征描述,使重建过程能够保持对显著散射成分的相对准确恢复,从而获得更具完整性和稳定性的 ISAR 成像结果。

变换域(如小波域)的稀疏表示通常用于刻画目标的一般性结构特征(如目标轮廓特征)^[11],并能够在一定程度上改善目标轮廓的成像质量。然而,一般性结构特征属于通用特征,主要反映目标轮廓的整体趋势,对具有特定局部结构或复杂散射机制的目标,其轮廓恢复能力有限。后续研究通过将稀疏变换字典^[12]引入到稀疏 ISAR 成像^[16]中,以获得能反映待成像目标局部结构特征或复杂散射机制的特有稀疏表示,从而提高目标特定结构的重建质量。但由于该特有稀疏表示关注待成像目标局部结构特征或复杂散射机制,对于反映目标整体轮廓的非局部结构特征或者散射分布表征能力不足。

有研究人员提出了进一步增强非局部结构表征的方法。一种方法通过构建图像块组并以其替代单独图像块作为稀疏表示的基本单元^[13],使成像过

程能够同时利用局部结构信息与跨区域共享的非局部结构信息。另一种方法将图像块映射至流形空间,并在流行空间建立关于图像块的 K 近邻图模型,以此来表征目标的全局结构信息^[14]。尽管这些方法能够一定程度上相对改善对非局部结构特征的建模,但它们普遍依赖预定义的相似性度量(如欧氏距离或固定 K 值近邻)来构建结构关系,该过程本质上仍基于局部邻域信息,难以准确捕捉全局散射机制。此外,这类度量需要人为设定超参数,对噪声、欠采样和目标结构变化具有较高敏感性,从而影响成像稳定性与一致性。

近年来,自注意力机制(Self-Attention Mechanism, SAM)在建模数据内部的长程依赖关系和全局语义结构方面展现出显著优势,并已在自然语言处理^{[17]-[20]}与图像重建^{[21]-[22]}等领域取得突出成果。其能够在无需预设相似性度量的前提下,根据数据自身的结构自适应地建立远距离元素间的关联,这为弥补现有稀疏 ISAR 成像方法在非局部结构表征方面的不足提供了新的技术路径。鉴于限制 ISAR 成像质量的重要因素之一在于对目标整体轮廓的准确重建,将 SAM 融入稀疏 ISAR 成像中有望增强对目标非局部(全局)结构特征的表达能力,从而提升对目标整体轮廓的重建质量,并进一步改善成像结果的完整性与稳定性。

基于上述考虑,本文首先建立一种结合 SAM 的字典学习(Dictionary Learning, DL)模型,称为 SAM-DL。与基于组字典学习(Group Dictionary Learning, GDL)^[13]或基于最近邻图模型(Nearest Neighbor Graph Model, NNGM)^[14]不同, SAM-DL 不依赖先验相似度量,而是通过对数据语义信息的直接建模来提取内在的全局结构特征,使字典原子在更新过程能够自适应地融合与目标整体结构相关的信息,从而提升稀疏表示对非局部结构特征的表征能力。在此基础上,进一步提出了基于 SAM-DL

的稀疏 ISAR 成像方法。该方法通过引入广义高斯分布假设,将目标成像问题分解为若干图像块重建的子问题,不仅降低了成像的整体复杂度,还使每个子问题均可转化为具有良好性质的凸优化问题。为获得更稳定与一致的重建结果,本文采用拉格朗日对偶上升策略替代传统 K-SVD 中的贪婪更新方式,实现对各子问题的全局收敛。拉格朗日对偶上升策略支持并行求解,这可以显著提升整体成像过程的效率。最后,实测 ISAR 数据成像结果表明,与基于 NNGM 的稀疏 ISAR 成像方法,基于 GDL 的稀疏 ISAR 成像方法和基于 DL 的稀疏 ISAR 成像方法^[12]相比, SAM-DL 成像性能更稳健,成像目标的轮廓更完整,背景更干净。

本文工作对稀疏 ISAR 成像理论的贡献主要包括两方面:

1. 针对低压缩比条件下待成像目标的稀疏表示对其全局结构特征刻画不足的问题,利用自注意力机制理论,显式建模待成像目标的全局结构特征,实现了待成像目标全局结构信息的参数化表征。

2. 针对现有稀疏 ISAR 成像方法未充分利用待成像目标全局结构特征的问题,将参数化表征的全局结构特征作为正则化项,并显式引入与字典学习相结合的稀疏 ISAR 成像模型中,建立了“全局结构特征建模、字典学习和稀疏成像”的一体化理论框架。相较于仅利用局部结构特征的稀疏 ISAR 成像方法,该框架在低压缩比条件下更有利于保持目标轮廓完整性。

1 基于 DL 的稀疏 ISAR 成像

基于 CS 理论, ISAR 成像可以视为在欠采样条件下从有限观测中重建目标场景散射率分布的问题。相应的成像模型如式(1)所示:

$$\mathbf{G}_s = \Psi\sigma + \mathbf{n}_s \quad (1)$$

其中 $\sigma \in \mathbb{C}^n$ 表示需要重构的目标场景散射率分布, $n = N_r \times N_a$, N_r 和 N_a 分别为距离向和方位向的采样点数。测量矩阵为 $\Psi \in \mathbb{C}^{m \times n} (m < n)$, $\mathbf{G}_s \in \mathbb{C}^m$ 表示通过随机欠采获得的测量数据, \mathbf{n}_s 为噪声项。

当测量矩阵满足限制等距性质条件时,若目标场景自然稀疏或者在变换域稀疏,则可以通过求解式(2)的 L1 正则化优化问题获得目标场景的重建结果:

$$\min_{\sigma} \|\mathbf{G}_s - \Psi\sigma\|_2 \|\sigma\|_1 \leq e \quad (2) \text{ s.t.}$$

稀疏成像方法通常依赖预设的稀疏变换域,以获得能够刻画显著结构特征(如目标轮廓、边缘和强散射点)的稀疏表示。设稀疏变换字典为 $\mathbf{D} \in \mathbb{C}^{n \times n}$, 待成像目标场景的稀疏表示系数记作 $\sigma = \mathbf{D}\mathbf{w}$, 可将该表达式形式代回式(2)中,得到式(3)所示的 L1 正则化优化问题:

$$\min_{\mathbf{w}} \|\mathbf{G} - \Psi\mathbf{D}\mathbf{w}\|_2 \|\mathbf{w}\|_1 \leq e \quad (3) \text{ s.t.}$$

为提升稀疏表示对目标结构特征的适应性,字典 \mathbf{D} 不仅可以预设,也可以直接从测量数据中习得。将字典学习引入到式(3)中,构建目标场景重建、稀疏表示求解以及字典学习的联合优化模型:

$$\min_{\sigma, \mathbf{D}_p, \{\mathbf{w}_i\}} \sum_{i=1}^N \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \|\mathbf{G}_s - \Psi\sigma\|_2^2 \|\mathbf{w}_i\|_1 \leq T_p \quad (4) \text{ s.t.}$$

其中 $\sigma_i \in \mathbb{C}^{\sqrt{n_p} \times \sqrt{n_p}}$ 表示从 σ 上获得的第 i 个数据块,提取操作记为 $\sigma_i = \mathcal{F}_i(\sigma)$, 其中 i 为数据块索引。 $\mathbf{D}_p \in \mathbb{C}^{n_p \times n_p}$ 表示面向 σ_i 的待学习的稀疏变换字典, \mathbf{w}_i 为 σ_i 通过 \mathbf{D}_p 找到的稀疏表示, $\{\mathbf{w}_i\}_{i=1}^N$ 表示所有数据块稀疏表示的集合, λ_1 为用于调节稀疏性和表示误差之间平衡的正则化系数。通常采用交替迭代的策略优化式(4),其中 σ_i 是采用共轭梯度方法^[12]获得的, \mathbf{D}_p 和 \mathbf{w}_i 可采用字典学习技术获得。 T_p 为稀疏度约束参数(即每个 \mathbf{w}_i 允许的最大非零元素个数)。

学习好的字典可以捕捉到待成像目标的局部结构特征。然而,仅利用局部结构特征不足以准确重建目标的全局轮廓。虽然 GDL 和 NNGM 等方法可额外结合目标的非局部结构特征成像。但这些非局部结构的表征依赖于预定义的相似性度量(例如欧几里德距离或 K 近邻),且这些度量策略依赖于手动调整参数,对噪声、欠采样率和目标结构变化敏感。

2 基于 SAM-DL 的稀疏 ISAR 成像

SAM 可在无须预定义相似性度量的条件下,自适应地从给定数据中捕获并建模各元素之间的全局语义联系,对噪声干扰和局部结构扰动具有较强的鲁棒性。为更精确地刻画待成像目标的非局部结构特征,本文引入 SAM 以刻画 ISAR 数据的全局语

义关联。与基于图像块组或一维向量的建模方式不同, 本文依然以图像块为基本单元, 这不仅有助于在保持局部细节的同时增强非局部结构的建模能力, 而且能够保持较高的计算效率。在此基础上, 利用 SAM 刻画的 ISAR 数据全局语义联系被显式表示为 SAM 约束项, 并融入 DL 成像模型中, 构建出 SAM-DL 成像模型。通过对该模型的优化, 可将目标的非局部结构信息有效嵌入至稀疏表示中, 从而提升成像目标结构重建质量。本节将详细介绍 SAM 约束项的构建过程及 SAM-DL 成像模型的优化方法。

2.1 自注意力约束项构建

注意到, ISAR 数据块集合 $\{\sigma_i\}_{i=1}^N$ 中的每一个图像块 σ_i 可利用 D_p 稀疏地表示为:

$$\sigma_i \approx \sum_{k=1}^{n_p} d_{pk} w_{k,i} \quad (5)$$

其中 d_{pk} 为 D_p 中第 k 个字典原子, $w_{k,i}$ 为 σ_i 在 d_{pk} 上的表示系数。

针对每一个原子, 其相应的自注意力约束项都以图像块为基础构建。以原子 d_{pk} 为例, 先计算 σ_i 关于 d_{pk} 的表示残差:

$$e_i^{(k)} = \sigma_i - \sum_{j \neq k} d_{pj} w_{j,i} \quad (6)$$

其中 $e_i^{(k)}$ 可以理解为由原图像块减去所有其他字典原子重构结果。

进一步地, 构建 d_{pk} 的自注意力得分:

$$a_i^{(k)} = \mathcal{S}(d_{pk}^H e_i^{(k)} / \sqrt{d}) \quad (7)$$

其中 $\mathcal{S}(\cdot)$ 表示归一化函数^[17], 归一化的操作是为了避免出现失效的概率权重。自注意力得分被视作每一个图像块对字典原子 d_{pk} 更新重要与否的概率权重。

利用表示残差 $e_i^{(k)}$ 与注意力得分 $a_i^{(k)}$ 构建 d_{pk} 的自注意力约束项:

$$\sum_{k=1}^{n_p} \sum_{i \in \Omega_k} a_i^{(k)} \|e_i^{(k)} - d_{pk} w_{k,i}\|_2^2 \quad (8)$$

其中 $w_{k,i}$ 为第 k 个原子 d_{pk} 对第 i 个图像块 σ_i 的稀疏表示系数。 $a_i^{(k)}$ 衡量 σ_i 与原子 d_{pk} 的相关性。 Ω_k 是所有使用了字典原子 d_{pk} 的 ISAR 数据块索引的集合。

2.2 结合自注意力约束项的稀疏 ISAR 成像

将式(8)所示的自注意力约束项加入式(4)所示

的目标函数中, 作为正则化项, 用于引导字典原子更新的方向。加入自注意力约束项后的目标函数依然是联合优化目标场景重建、稀疏表示求解以及字典学习三个子问题:

$$\begin{aligned} \min_{\sigma, D_p, \{w_i\}} & \sum_{i=1}^N \|\sigma_i - D_p w_i\|_2^2 + \lambda_1 \|G_s - \Psi \sigma\|_2^2 + \\ & \lambda_2 \sum_{k=1}^{n_p} \sum_{i \in \Omega_k} a_i^{(k)} \|e_i^{(k)} - d_{pk} w_{k,i}\|_2^2 \text{ s.t. } \|d_{pk}\|_1^2 \leq c, \forall i \\ & \|w_i\|_1 \leq T_p \end{aligned} \quad (9)$$

其中第一项对应于基于图像块的稀疏表示与字典更新, 其作用是在学习过程中获得能够有效刻画目标结构的稀疏变换字典及其系数; 第二项用于衡量重建结果与观测数据之间的一致性, 从而保证模型的测量保真度; 第三项为自注意力正则化项, 通过在优化过程中施加全局结构约束, 引导字典原子的更新方向, 使其更好地适应目标的整体结构特征。 λ_2 为正则化参数, 用于平衡第三项在整体优化中的权重。

进一步引入正则化参数 β , 将式(9)改写为:

$$\begin{aligned} \min_{\sigma, D_p, \{w_i\}} & \sum_{i=1}^N \|\sigma_i - D_p w_i\|_2^2 + \lambda_1 \|G_s - \Psi \sigma\|_2^2 + \\ & \lambda_2 \sum_{k=1}^{n_p} \sum_{i \in \Omega_k} a_i^{(k)} \|e_i^{(k)} - d_{pk} w_{k,i}\|_2^2 + \beta \sum_{i=1}^N \|w_i\|_1 \|d_{pk}\|_1^2 \leq c \end{aligned} \quad (10) \text{ s.t.}$$

为求解式(10)中的变量 σ , D_p 和 $\{w_i\}_{i=1}^N$, 本文采用迭代式优化框架。在每一次外层迭代中, 依次更新 w_i 和 σ_i , 再根据新估计的图像块信息和稀疏系数来学习 D_p 。迭代完成后, 各图像块将按照其在数据提取阶段的索引映射回原始场景位置处。由于同一像素值通常由多个图像块共同贡献, 最终的成像结果通过对对应像素位置的多块重建取加权平均获得。

2.2.1 稀疏表示求解和目标图像重建

式(10)中的图像块重建问题属于凸优化问题。为此, 本文采用梯度上升策略来求解^[23]。该策略不仅能够保证每个子问题获得全局最优解, 还可以实现并行化处理, 从而在保证重建精度的前提下, 显著提升整体优化的收敛速度。

求解稀疏系数和目标图像时, 面向图像块的字典 D_p 保持不变, 则式(10)可改写为:

$$\{\hat{\sigma}, \{\hat{\mathbf{w}}_i\}\} = \min_{\sigma, \{\mathbf{w}_i\}} \sum_{i=1}^N \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \|\mathbf{G}_s - \Psi \sigma\|_2^2 + \lambda_2 \sum_{k=1}^{n_p} \sum_{i \in \Omega_k} a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_{pk} \mathbf{w}_{k,i}\|_2^2 + \beta \sum_{i=1}^N \|\mathbf{w}_i\|_1 \quad (11)$$

采用逐个系数向量的迭代更新方式, 对式(11)中的稀疏表示系数向量依次优化。更新当前系数向量时, 其余系数向量保持固定, 以确保优化过程的稳定性。

为了方便推导稀疏表示系数向量的解析解, 将式(11)中保真度约束项 $\|\mathbf{G}_s - \Psi \sigma\|_2^2$ 中的 \mathbf{G}_s 和 $\Psi \sigma$ 分别左乘 Ψ^T 可得 $\|\sigma - \mathbf{I}\|_2^2$, 其中 \mathbf{I} 为由 ISAR 回波数据在距离向与方位向随机降采样后, 通过两维快速傅里叶变换重建的粗糙目标场景图像。

根据文献^[14]中的附录 B 可知, ISAR 图像中散射点分布近似满足广义高斯分布, 并可以概率 1 近似得到如下结论:

$$\lim_{\substack{n \rightarrow \infty \\ K \rightarrow \infty}} \mathcal{P} \left\{ \left| \frac{1}{n} \|\sigma - \mathbf{I}\|_2^2 - \frac{1}{K} \sum_{i=1}^N \|\sigma_i - \mathbf{I}_i\|_2^2 \right| < \varepsilon \right\} = 1 \quad (12)$$

其中 $K = n_p \times N$, \mathbf{I}_i 为根据式(4)中的图像块提取方式从 \mathbf{I} 中提取的第 i 个图像块的估计值。

根据式(12)的结论, 可将 $\|\sigma - \mathbf{I}\|_2^2$ 写为向量的形式:

$$\|\sigma - \mathbf{I}\|_2^2 = \frac{n}{K} \sum_{i=1}^N \|\sigma_i - \mathbf{I}_i\|_2^2 \quad (13)$$

与此同时, 式(11)中的第三项可进一步松弛改写为:

$$\sum_{k=1}^K \sum_{i \in \Omega_k} a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_k \mathbf{w}_{k,i}\|_2^2 = \sum_{k=1}^K \sum_{i=1}^N a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_k \mathbf{w}_{k,i}\|_2^2 \quad (14)$$

式(14)中自注意力正则化项虽然只在部分索引 $\Omega_k \subset \{1, \dots, N\}$ 上参与目标函数的优化, 但因为稀疏系数 \mathbf{w}_i 本身在第一项(图像块重建项)中是全体图像块都参与的, 因此对所有 $i = 1, \dots, N$ 求解 \mathbf{w}_i 。即使某些 \mathbf{w}_i 没有在自注意力正则化项中出现, 它们依然必须通过图像块重建项被优化, 以确保所有图像块被良好重构。因此, 可以通过松弛结构索引空间到最大, 进而简化公式(11)。

将式(13)和式(14)代入式(11), 式(11)可改写为:

$$\{\hat{\sigma}, \{\hat{\mathbf{w}}_i\}\} = \min_{\sigma, \{\mathbf{w}_i\}} \sum_{i=1}^N \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \frac{n}{K} \sum_{i=1}^N \|\sigma_i - \mathbf{I}_i\|_2^2 + \lambda_2 \sum_{k=1}^{n_p} \sum_{i=1}^N a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_{pk} \mathbf{w}_{k,i}\|_2^2 + \beta \sum_{i=1}^N \|\mathbf{w}_i\|_1 \quad (15)$$

(a) 稀疏表示系数求解

在优化过程中, 稀疏表示系数向量 $\{\mathbf{w}_i\}_{i=1}^N$ 依次进行更新。当更新某一特定系数向量 \mathbf{w}_i 时, 其余系数向量 $\{\mathbf{w}_j\}_{j \neq i}$ 保持固定, 以确保每次更新的独立性和算法的收敛性。

用于更新 \mathbf{w}_i 的目标函数可通过改写式(15)得到:

$$\hat{\mathbf{w}}_i = \operatorname{argmin}_{\mathbf{w}_i} \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \frac{n}{K} \|\sigma_i - \mathbf{I}_i\|_2^2 + \lambda_2 \sum_{k=1}^{n_p} a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_{pk} \mathbf{w}_{k,i}\|_2^2 + \beta \sum_{j=1}^Q |w_i^{(j)}| \quad (16)$$

其中 $w_i^{(j)}$ 表示 \mathbf{w}_i 中的第 j 个系数。

在求解式(16)时, 不可避免的一步是将 $|w_i^{(j)}|$ 的取模符号去掉。本文用 $w_i^{(j)}$ (如果 $w_i^{(j)} > 0$), $-w_i^{(j)}$ (如果 $w_i^{(j)} < 0$) 或 0 (如果 $w_i^{(j)} = 0$) 来替代 $|w_i^{(j)}|$ 。因此, 可引入符号向量 θ 存放 $w_i^{(j)}$ 的符号, 则有 $\sum_{j=1}^Q |w_i^{(j)}| = \theta^T \mathbf{w}_i$ 。

其次, 将式(16)中自注意力正则项展开可得到:

$$\lambda_2 \sum_{k=1}^{n_p} a_i^{(k)} \|\mathbf{e}_i^{(k)} - \mathbf{d}_{pk} \mathbf{w}_{k,i}\|_2^2 = \mathbf{w}_i^T \mathbf{Q}_i \mathbf{w}_i - 2\mathbf{b}_i^H \mathbf{w}_i + C \quad (17)$$

其中 $\mathbf{w}_i^T \mathbf{Q}_i \mathbf{w}_i = \lambda_2 \sum_{k=1}^{n_p} a_i^{(k)} w_{k,i}^2 \|\mathbf{d}_{pk}\|_2^2$, $2\mathbf{b}_i^H \mathbf{w}_i =$

$2\lambda_2 \sum_{k=1}^{n_p} a_i^{(k)} w_{k,i} \mathbf{d}_{pk}^H \mathbf{e}_i^{(k)}$, $C = \lambda_2 \sum_{k=1}^{n_p} a_i^{(k)} \|\mathbf{e}_i^{(k)}\|_2^2$ 为常数项。

接着, 将式(17)代回式(16)中, 式(16)可改写为:

$$\hat{\mathbf{w}}_i = \operatorname{argmin}_{\mathbf{w}_i} \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \frac{n}{K} \|\sigma_i - \mathbf{I}_i\|_2^2 + \mathbf{w}_i^T \mathbf{Q}_i \mathbf{w}_i - 2\mathbf{b}_i^H \mathbf{w}_i + C + \beta \theta^T \mathbf{w}_i \quad (18)$$

定义 $h(\mathbf{w}_i) = \|\sigma_i - \mathbf{D}_p \mathbf{w}_i\|_2^2 + \lambda_1 \frac{n}{K} \|\sigma_i - \mathbf{I}_i\|_2^2 + \mathbf{w}_i^T \mathbf{Q}_i \mathbf{w}_i - 2\mathbf{b}_i^H \mathbf{w}_i + C + \beta \theta^T \mathbf{w}_i$, 并令 $\partial(h(\mathbf{w}_i))/\partial(\mathbf{w}_i) = 0$, 则可得到 $\hat{\mathbf{w}}_i$ 的估计值:

$$\hat{\boldsymbol{w}}_i = (\boldsymbol{D}_p^H \boldsymbol{D}_p + \boldsymbol{Q}\boldsymbol{E})^{-1} (\boldsymbol{\sigma}_i^H \boldsymbol{D}_p + \boldsymbol{b}_i^H - 1/2 \boldsymbol{\beta} \boldsymbol{\theta}^T) \quad (19)$$

其中 \boldsymbol{E} 为单位阵。

通过重复执行式(16)到式(19)的求解过程, 可求出其余待求解的稀疏表示系数向量 $\{\boldsymbol{w}_j\}_{j \neq i}$, 并最终得到所有稀疏表示系数向量的估计值 $\{\hat{\boldsymbol{w}}_i\}_{i=1}^N$ 。

(b) 目标图像重建

在完成稀疏表示系数向量 $\{\hat{\boldsymbol{w}}_i\}_{i=1}^N$ 的求解后, 可借助稀疏变换字典以及关系式 $\hat{\boldsymbol{\sigma}}_i = \boldsymbol{D}_p \hat{\boldsymbol{w}}_i$ 得到各图像块的估计结果 $\{\hat{\boldsymbol{\sigma}}_i\}_{i=1}^N$ 。随后, 根据每个图像块在数据提取阶段的索引信息, 将其放置回原始场景中的对应位置。对于重叠区域的像素, 采用逐像素的加权平均策略以融合来自不同图像块的贡献, 从而形成最终的目标场景重建图像。加权平均的过程表示为:

$$\hat{\boldsymbol{\sigma}} = \sum_{i=1}^N \mathcal{F}_i^T(\hat{\boldsymbol{\sigma}}_i) ./ \sum_{i=1}^N \mathcal{F}_i^T(\boldsymbol{B}) \quad (20)$$

其中 $\hat{\boldsymbol{\sigma}}$ 为最终重建的目标场景图像, 符号 “./” 表示逐元素的除法, $\boldsymbol{B} \in \mathbb{R}^{\sqrt{n_p} \times \sqrt{n_p}}$ 为标识矩阵, 其中所有元素的数值都取 1, 用于记录各像素被图像块覆盖的次数。

2.2.2 自注意力约束项引导的字典学习

将上一步估计得到的稀疏表示系数和目标场景 $\hat{\boldsymbol{\sigma}}$ 固定, 在此基础上, 字典学习问题可通过改写式(10)得到:

$$\min_{\boldsymbol{D}_p} \sum_{i=1}^N \|\boldsymbol{\sigma}_i - \boldsymbol{D}_p \boldsymbol{w}_i\|_2^2 + \lambda_2 \sum_{k=1}^{n_p} \sum_{i=1}^N a_i^{(k)} \|\boldsymbol{e}_i^{(k)} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i}\|_2^2$$

$$\|\boldsymbol{d}_{pk}\|_1 \leq c \quad (21) \text{ s.t.}$$

图像块字典学习问题本质上是含有二次约束的最小二乘问题。可以使用拉格朗日对偶上升策略对问题进行求解^[23], 该方法不依赖迭代, 因此具有更高的计算效率。

对式(21)构造其拉格朗日对偶函数。设向量 $\boldsymbol{\mu} = [\mu_1, \dots, \mu_k, \dots, \mu_{n_p}]$, 其中 μ_k 为与第 k 个不等式约束 $\|\boldsymbol{d}_{pk}\|_1 - c \leq 0$ 相关的拉格朗日乘子, 式(21)在 \boldsymbol{D}_p 取最小值时的拉格朗日对偶函数表示为:

$$\hat{\boldsymbol{D}}_p = \operatorname{argmin}_{\boldsymbol{D}_p} \sum_{i=1}^N \left\| \boldsymbol{\sigma}_i - \sum_{k=1}^{n_p} \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 +$$

$$\lambda_2 \sum_{k=1}^{n_p} \sum_{i=1}^N a_i^{(k)} \left\| \boldsymbol{e}_i^{(k)} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 + \sum_{k=1}^{n_p} \mu_k \left(\|\boldsymbol{d}_{pk}\|_1 - c \right) \quad (22)$$

采用逐原子更新策略, 这可确保自注意力正则化项对字典原子更新起到引导的作用。式(22)可以进一步改写为:

$$\hat{\boldsymbol{D}}_p = \operatorname{argmin}_{\boldsymbol{D}_p} \sum_{i=1}^N \left\| \boldsymbol{\sigma}_i - \sum_{j \neq k} \boldsymbol{d}_{pj} \boldsymbol{w}_{j,i} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 +$$

$$\lambda_2 \sum_{k=1}^{n_p} \sum_{i=1}^N a_i^{(k)} \left\| \boldsymbol{e}_i^{(k)} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 + \sum_{k=1}^{n_p} \mu_k \left(\|\boldsymbol{d}_{pk}\|_1 - c \right) \quad (23)$$

当更新原子 \boldsymbol{d}_{pk} 时, 字典 \boldsymbol{D}_p 中的其余原子固定不变。求解 \boldsymbol{d}_{pk} 的目标函数可通过简化式(23)得到:

$$\hat{\boldsymbol{d}}_{pk} = \operatorname{argmin}_{\boldsymbol{d}_{pk}} \sum_{i=1}^N (1 + \lambda_2 a_i^{(k)}) \left\| \boldsymbol{e}_i^{(k)} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 +$$

$$\mu_k \left(\|\boldsymbol{d}_{pk}\|_1 - c \right) \quad (24)$$

为了便于求解, 将式(24)中第二项近似为 L_2 范数, 即 $\|\boldsymbol{d}_{pk}\|_1 - c \approx \|\boldsymbol{d}_{pk}\|_2^2$, 式(24)可进一步简化为:

$$\hat{\boldsymbol{d}}_{pk} = \operatorname{argmin}_{\boldsymbol{d}_{pk}} \sum_{i=1}^N (1 + \lambda_2 a_i^{(k)}) \left\| \boldsymbol{e}_i^{(k)} - \boldsymbol{d}_{pk} \boldsymbol{w}_{k,i} \right\|_2^2 +$$

$$\mu_k \|\boldsymbol{d}_{pk}\|_2^2 \quad (25)$$

设 $\mathcal{L}(\boldsymbol{d}_{pk})$ 表示式(25)所示的目标函数, 并令 $\partial \mathcal{L}(\boldsymbol{d}_{pk}) / \partial \boldsymbol{d}_{pk} = 0$, 可得到 \boldsymbol{d}_{pk} 的解析解为:

$$\hat{\boldsymbol{d}}_{pk} = \frac{\sum_{i=1}^N (1 + \lambda_2 a_i^{(k)}) \boldsymbol{w}_{k,i} (\boldsymbol{e}_i^{(k)})^H}{\sum_{i=1}^N (1 + \lambda_2 a_i^{(k)}) \boldsymbol{w}_{k,i}^2 + \mu_k} \quad (26)$$

重复执行式(24)到式(26), 可得到 \boldsymbol{D}_p 中的其余字典原子 $\{\boldsymbol{d}_{pj}\}_{j \neq k}$ 的解析解。当 \boldsymbol{D}_p 中所有字典原子都被更新一遍后, 则 \boldsymbol{D}_p 完成一次更新。

3 实测数据成像结果及分析

将本文所提成像方法与 NNGM^[14]、GDL^[13] 和 DL^[12] 成像方法对比, 明确本文所提成像方法的优势。在 GDL 和 DL 成像方法中, 稀疏变换字典是利用 K-SVD 技术学习得到的。在 NNGM 成像方法中, 稀疏变换字典则是通过梯度上升策略完成更新的。所有方法均采用 8×8 的图像块大小与 6 个像

素的块间重叠长度。SAM-DL 方法中正则化参数 λ_1 、 λ_2 和 β 的最优取值分别为 0.32、0.9 和 0.35。

3.1 实测数据和评价指标

本节实验采用两类实测数据：一类为 YAK-42 飞机目标数据，另一类为船目标数据，用于评估 SAM-DL 成像方法在不同目标场景下的成像性能。YAK-42 飞机目标数据采集于 C 波段，雷达发射信号带宽为 400MHz；船目标数据采集于 X 波段，雷达发射信号带宽为 170MHz。船目标和飞机目标数据在目标类型与成像参数上存在差异，二者一起可以验证 SAM-DL 方法的跨目标类型的泛化能力和不同目标场景下稳定成像的性能。

两类实测数据均经过距离向脉压处理以获得距离像，随后利用平均距离像最小熵^[24]和相位梯度算法^[25]完成运动补偿。补偿完成后，再对数据按比例降采样以构建不同压缩比条件下的成像场景。具体而言，飞机目标数据的降采样率设为 15% 和 25%，船目标数据的降采样率设为 50%。两类数据的大小、降采样率及其对应的稀疏度如表 1 所示。

表 1 实测 YAK-42 飞机目标和船目标 ISAR 数据参数

数据	原始数据大小	降采样率	稀疏度
飞机数据	100 × 80	15%, 25%	900
船数据	96 × 96	50%	841

本节全部实验均在 MATLAB 2024a 环境下完成，实验平台配置为：Intel(R) Core(TM) i7-7700 CPU @ 3.60 GHz、8 GB 内存、Windows 11 操作系统。

为了从多个维度评价不同成像方法的成像质量，本节引入全局成像质量指标^[11]与局部等效点扩散函数(Point Spread Function, PSF)指标进行定量分析。全局评价指标包括：虚警(False Alarm, FA)、漏检(Missed Detection, MD)、相对均方根误差(Relative Root Mean Square Error, RRMSE)、目标杂波比(Target-to-Clutter Ratio, TCR)、图像熵(Entropy of The Image, ENT)、图像对比度(Image Contrast, IC)和成像时间 Time。其中，FA 和 MD 分别用于计算错误重建与遗漏的目标散射点数量，RRMSE 可衡量重建图像与参考图像之间的误差幅度。联合分析 TCR、ENT 和 IC 可讨论目标散射点位置和轮廓重建准确度。

此外，为进一步评价不同成像方法的局部聚焦

性能与旁瓣抑制能力，本文在实测 ISAR 成像结果中选取局部孤立强散射点。由于该类散射点的散射强度明显高于周围散射点，且受邻近散射点干扰较小，因此可将其局部响应近似视为等效点扩散函数(Point Spread Function, PSF)。在此基础上，进一步计算 -3dB 主瓣宽度和峰值旁瓣比(Peak SideLobe Ratio, PSLR)等 PSF 相关指标。其中，-3dB 主瓣宽度用于衡量成像分辨率与聚焦能力，而 PSLR 用于评价最大旁瓣抑制能力。

3.2 YAK-42 飞机数据成像结果与分析

图 1(a)给出了利用完整观测数据经 RD 算法获得的飞机目标参考图像。图 1(b) - 图 1(e)则分别展示了在 15% 测量数据的条件下，采用 SAM-DL、NNGM、GDL 和 DL 四种方法得到的稀疏重建结果。

由图 1(a)与图 1(b)可以看到，SAM-DL 方法在低压缩比条件下仍能恢复出具有可辨识结构特征的飞机目标，如图 1(a)和图 1(b)中浅蓝色圆圈区域所示。这说明本文所提成像方法是可行的。

进一步对比图 1(b)、图 1(c)、图 1(d)和图 1(e)可直观发现，SAM-DL、NNGM 与 GDL 的成像结果均明显优于 DL 方法的，飞机目标双翼及主体轮廓更清晰、背景更干净(见橙色圆圈区域)。这是因为这些方法除利用目标的通用特征外，还引入了局部结构特征，使得重建的目标轮廓更加完整。

继续对比图 1(b)、图 1(c)和图 1(d)可知，SAM-DL 的成像效果优于 NNGM 和 GDL 的。在 15% 测量数据条件下，SAM-DL 方法仍能相对成功地重建飞机机头，而 NNGM 与 GDL 方法则相对失效(见红色椭圆区域)，表明 SAM-DL 所利用的全局结构特征优于 NNGM 和 GDL 所利用的局部结构特征。

从图 2 可进一步观察到，当测量数据比例提高至 25% 时，SAM-DL、NNGM 与 GDL 方法可在机头位置重建出少量散射点，而 DL 方法仍无法形成有效成像(见红色椭圆区域)。同时，SAM-DL 成像结果中，机头区域的散射点更为稠密，这进一步验证了结构特征对目标轮廓重建的重要性，且全局结构特征优势更明显。

综合图 1 与图 2 可见，随着测量数据减少，NNGM 与 GDL 成像结果退化显著，而 SAM-DL 成像性能保持稳定，尤其在低压缩比条件下仍具备较高的成像鲁棒性。

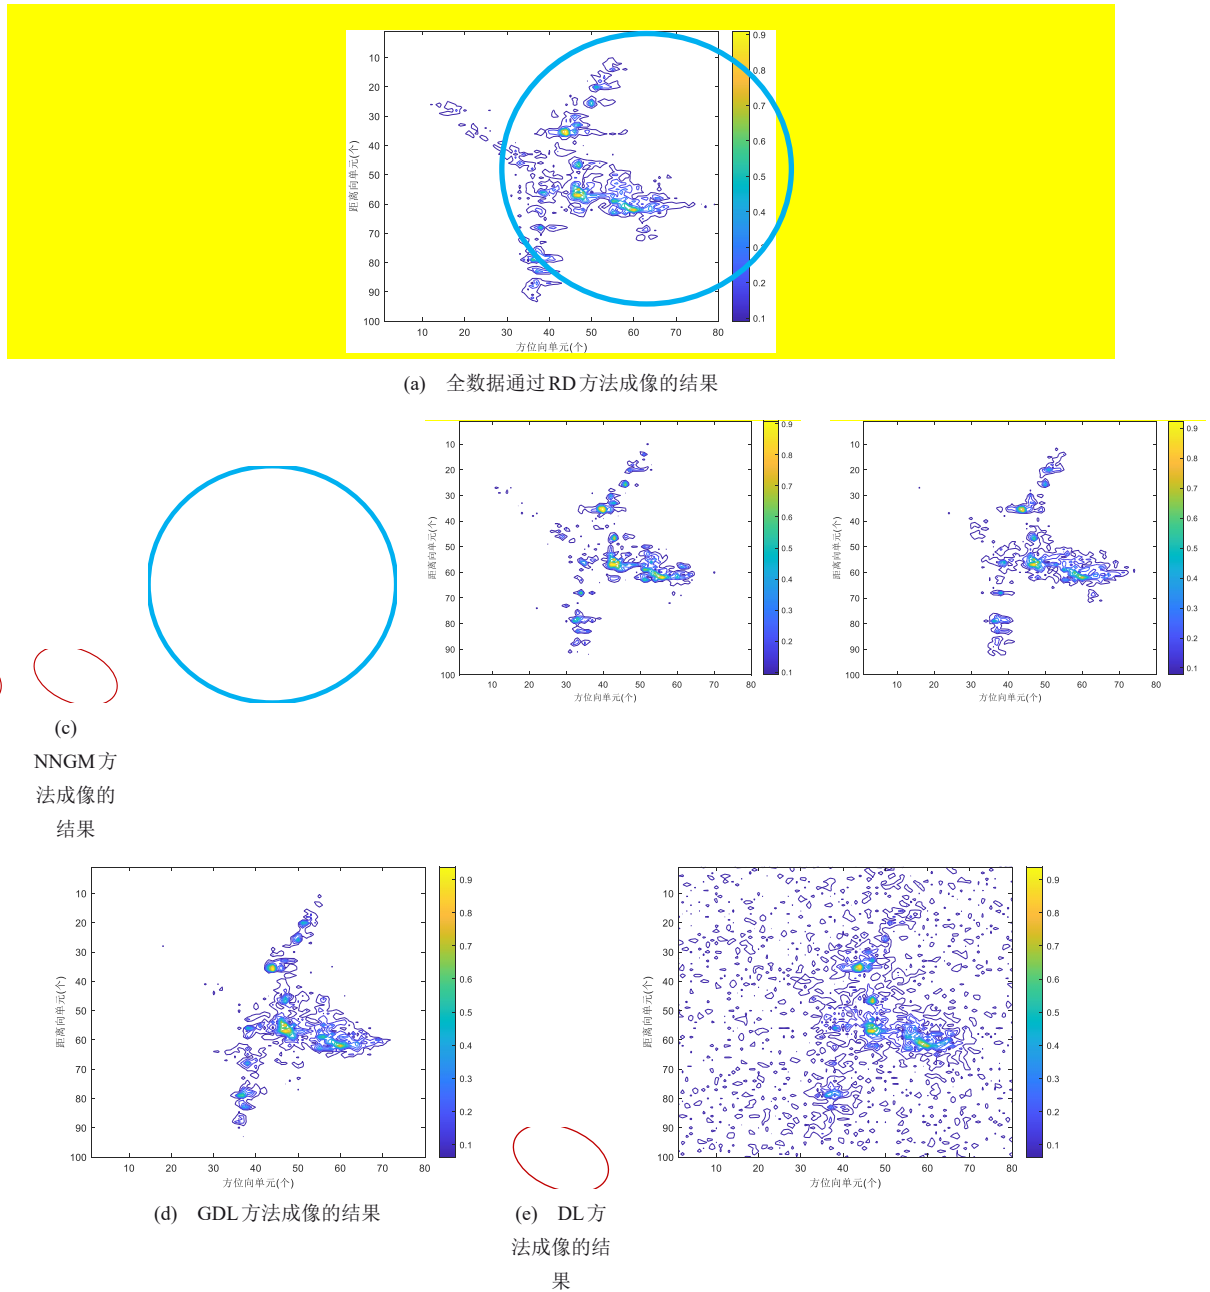


图1 全数据通过RD方法成像的结果和15%的数据通过不同稀疏成像方法获得的结果

为进一步量化图1与图2中各成像方法的性能表现, 本文将完整观测数据RD成像结果作为参考图像, 以此作为后续性能评估的基准。基于各稀疏成像方法的重建图像与参考图像之间的差异, 计算了FA、MD、RRMSE、TCR、ENT和IC等指标, 并将定量结果汇总于表2中。

从15%测量数据的结果来看, SAM-DL在大多数评价指标上均表现最佳。其中, FA和RRMSE值最低, 说明该方法重建的虚假散射点数最少且目标

区域散射点幅值重建误差最小。同时, SAM-DL成像结果的TCR和ENT值相对较高, 表明散射点位置重建精度更高, 图像轮廓更加完整。尽管DL方法的MD值最小, 意味着目标区域的散射点遗漏较少, 但其FA值高达604, 背景中存在大量虚假散射点, 导致成像结果严重失真, 整体图像质量远低于SAM-DL。总体而言, SAM-DL在兼顾低MD与低FA的同时, 实现了较高的成像质量与稳定性。SAM-DL成像结果获得最窄的-3dB主瓣宽度, 表

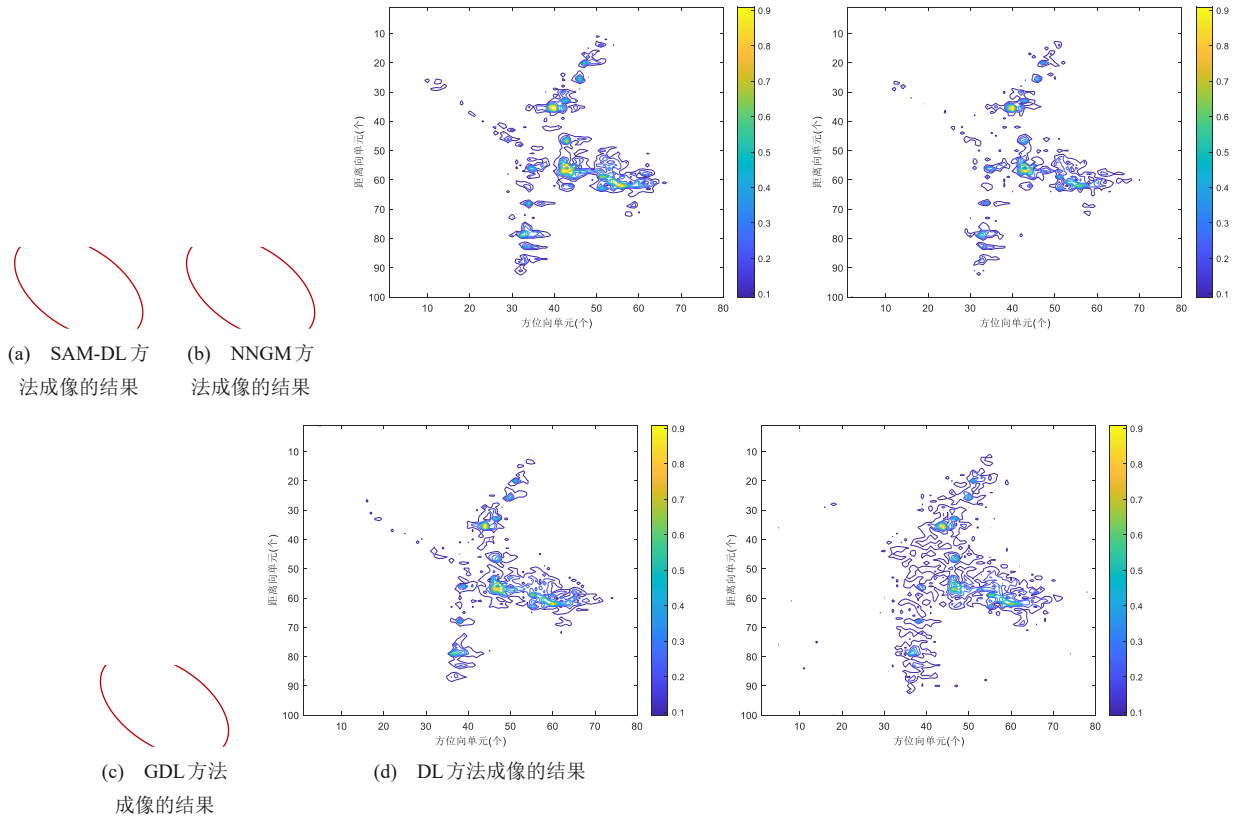


图2 25% YAK-42 飞机目标数据通过不同稀疏成像方法获得的结果

表 2.15 %和25% 飞机目标数据利用文中各方法成像结果定量评价

数据	成像方法	FA	MD	RRMSE	TCR	ENT	IC	-3dB 主瓣 宽度	PSLR(dB)	Time(s)
15% 飞机数据	SAM-DL	62	137	0.2869	50.5866	5.1495	8.5762	1.0317	9.9404	5.2305
	NNGM	94	217	0.3241	47.2281	5.8021	7.5482	1.0657	9.3401	2.0401
	GDL	148	236	0.3288	46.7725	5.9427	7.5298	1.1496	7.9662	2.6640
	DL	604	115	0.4347	40.5562	6.7912	6.8438	1.3117	4.1568	7.2204
25% 飞机数据	SAM-DL	37	85	0.2223	59.1437	5.0052	9.9773	1.0114	9.5018	5.3724
	NNGM	56	89	0.2271	58.8937	5.0238	9.9240	1.0343	3.5922	2.5562
	GDL	70	102	0.2878	57.1225	5.0482	9.5376	1.1138	7.3207	3.0271
	DL	170	173	0.3170	48.6525	5.4674	7.7229	1.3859	8.3812	7.6619

明 SAM-DL 成像方法的分辨率与局部聚焦能力最优。SAM-DL 成像结果的 PSLR 都最高, 说明 SAM-DL 成像方法能最有效地抑制旁瓣和虚假散射点。

当测量数据比例由 15% 提升至 25% 时, 所有方法的成像质量均有所改善, 但各方法之间仍存在显著差异。其中, SAM-DL 在 FA、MD 和 RRMSE 三项指标上均取得最优结果, 表明其有效减少了虚

假散射点, 更好地保留了目标散射点分布, 并显著降低了幅值误差。此外, SAM-DL 在 TCR、ENT 和 IC 指标上同样表现最佳, 进一步说明其在恢复机翼、机身等关键结构细节方面具有优势, 整体成像更加清晰与完整。相比之下, NNGM 和 GDL 虽在部分指标上有所提升, 但整体成像的结构保真度仍不及 SAM-DL 方法。-3dB 主瓣宽度和 PSLR 指标值则说明, SAM-DL 方法仍然能够保持最优的聚焦

性能，最强的旁瓣抑制能力。

此外，从 Time 指标可以看出，SAM-DL 方法在计算复杂度上略高于 NNGM 和 GDL。综合定量结果与图像表现可知，SAM-DL 在低采样率条件下仍能保持优异的成像性能，表现出更好的鲁棒性与轮廓重建能力。

3.3 船目标数据成像结果与分析

图 3(a)展示的是船目标全数据的 RD 成像结果。图 3(b)、图 3(c)、图 3(d)和图 3(e)分别展示的是 50% 船目标测量数据分别采用 SAM-DL、NNGM、GDL 和 DL 成像方法成像的结果。对比图 3(a)和图 3(b)可见，SAM-DL 成像方法仅需要 50% 数据，即可重建出主体区域完整的船目标。

对比图 3(b)、图 3(c)、图 3(d)和图 3(e)可知，SAM-DL 成像方法重建的结果要优于 NNGM、GDL 和 DL 成像方法重建的结果，SAM-DL 重建的船目标轮廓更加清晰，背景虚假散射点数更少。

各成像方法重建船目标图像的定量分析在表 3 中给出。从表中可以看出，SAM-DL 方法在多数指标上表现最佳。具体而言，SAM-DL 的 FA 和 MD 值均为最小，表明其成像结果中虚假散射点最少且目标区域遗漏的散射点数最低，能够相对完整地重建船目标结构。RRMSE 指标方面，SAM-DL 的值最低，说明其重建目标区域散射点的幅值误差最小。TCR 值最高且 ENT 值最小，进一步表明其重建的目标区域散射点位置最为准确。IC 值最高，说明成像对比度相对最佳，目标与背景区分度更强。SAM-DL 成像方法的 -3dB 主瓣带宽和 PSLR 最优，这反映 SAM-DL 成像方法目标散射点聚焦能力最强，能够最有效地抑制旁瓣。虽然 NNGM 在运算时间上表现最优，但其成像质量在多项关键指标上均略逊于 SAM-DL。综合来看，SAM 方法的成像性能最优。

3.4 SAM-DL 成像方法对不同信噪比 ISAR 数据

成像

为了验证所提成像方法对不同信噪比数据成像的性能，向实测飞机目标 ISAR 数据中添加不同功率的高斯白噪声，构造信噪比(Signal-to-Noise Ratio, SNR)为 4 和 2 的两组飞机目标 ISAR 数据。信噪比为 4 的飞机目标 ISAR 数据称为数据 2，信噪比为 2 的飞机目标 ISAR 数据称为数据 3，未添加高斯白噪声的飞机目标 ISAR 数据称为数据 1。

RD 方法对数据 1(无噪声)、数据 2(SNR 为 4)和数据 3(SNR 为 2)的全数据成像结果如图 4 所示。SAM-DL 成像方法对 25% 的数据 1、25% 的数据 2 和 25% 的数据 3 成像的结果如图 5 所示。

比较图 5(a)和图 5(b)可以看出，随着高斯白噪声的引入，SAM-DL 成像方法对目标成像质量会有所下降。对比图 5(b)和图 5(c)可见，SNR 的进一步降低并未显著加剧重建图像质量的恶化。这些结果表明，尽管 SAM-DL 成像方法对噪声较为敏感，但其整体成像性能仍相对稳定，在有噪声条件下仅表现出轻微退化。

4 结论

本文提出了一种基于 SAM-DL 的稀疏 ISAR 成像方法，旨在利用待成像目标的全局结构特征，提高目标轮廓的重建质量。与基于自相似性或图模型所表征的局部结构特征相比，SAM-DL 能够更有效地捕捉目标的全局结构特征。实测 ISAR 数据的成像结果表明，与现有的 NNGM 成像方法、GDL 成

像方法和 DL 成像方法相比，所提 SAM-DL 成像方法能够获得虚假散射点更少、目标背景更干净、目标轮廓更清晰的成像结果。尽管 SAM 的引入略微降低了 DL 类成像方法的成像效率，但其显著提升了成像目标轮廓的准确性和成像方法的稳健性，尤其是在低压缩比条件下表现更为突出。本文所提成像方法可适用于空中或者海面非合作目标稀

表 3.5 0% 船目标数据利用文中各方法成像结果定量评价

数据	成像方法	FA	MD	RRMSE	TCR	ENT	IC	-3dB 主瓣 宽度	PSLR(dB)	Time(s)
50% 船数据	SAM-DL	9	45	0.1549	70.1037	5.0261	9.3304	2.1697	3.3765	6.3027
	NNGM	11	52	0.1588	69.5844	5.0297	9.1561	2.4066	0.5515	3.5254
	GDL	20	55	0.2231	68.4828	5.1813	9.1454	3.0669	0.5957	4.1526
	DL	155	126	0.3354	53.6296	5.6388	7.3239	2.4919	3.1172	6.3620

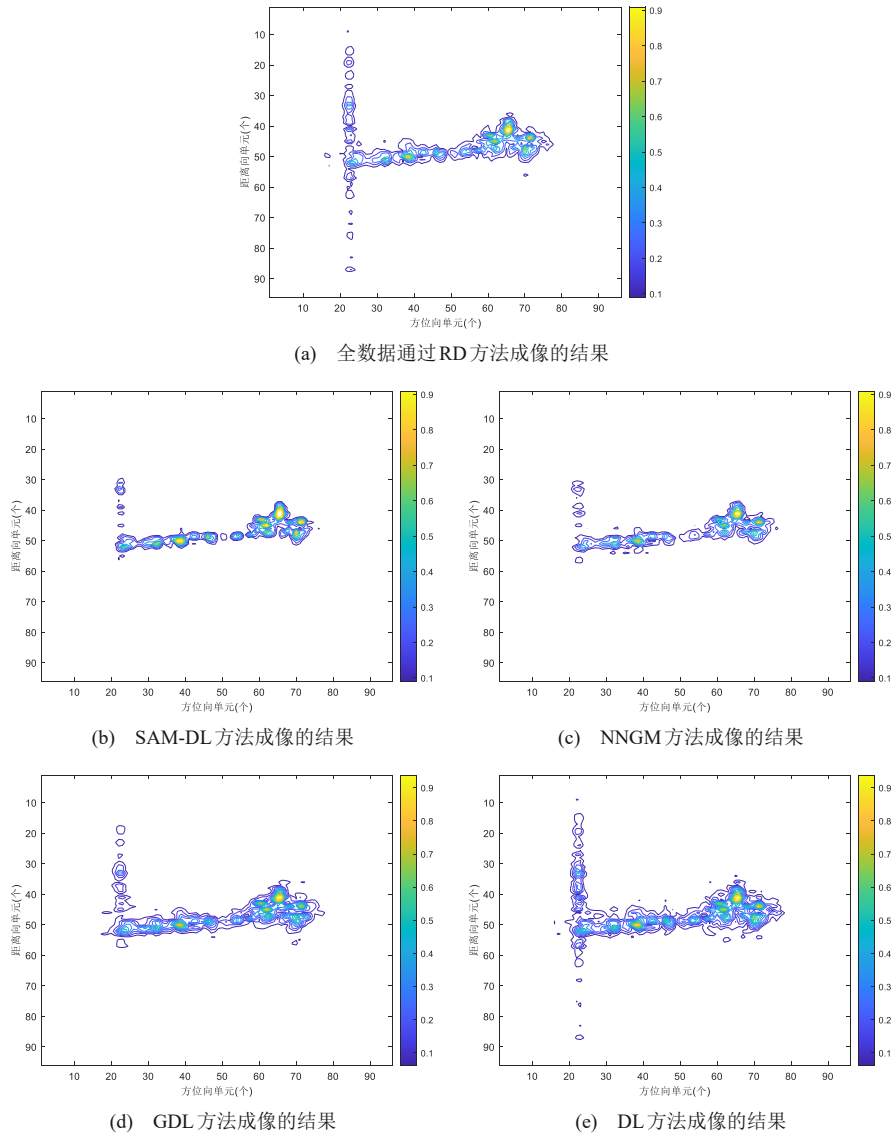


图3 全数据通过RD方法成像的结果和50%数据通过不同稀疏成像方法获得的结果




图4 RD成像方法对数据1、数据2和数据3成像的结果

疏ISAR成像任务。在兼顾工程可实现性与计算效率的同时,可获得目标轮廓相对完整、质量更优的成像结果。




图5 SAM-DL 成像方法对 25% 数据 1、25% 数据 2 和 25% 数据 3 成像的结果

参考文献:

- [1] 张群,张宏伟,倪嘉成,等.合成孔径雷达深度学习成像研究综述[J].信号处理,2023,39(09):1521-1551.
ZHANG Q, ZHANG H W, NI J C, et al. A survey of synthetic aperture radar imaging methods based on deep learning[J]. Journal of Signal Processing, 2023, 39(9): 1521-1551.
- [2] WU Y, LI R, MAI Y, et al. Rr-admm-net for sparse aperture ISAR imaging under low signal-to-noise ratio[J]. IEEE Transactions on Aerospace and Electronic Systems, 2026. (Early Access)
- [3] LV M, YANG J, WANG D, et al. A structural sparse ISAR imaging method with joint phase autofocusing[J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 1-5.
- [4] CETIN M, KARL W M. Feature-enhanced synthetic aperture radar image formation based on non-quadratic regularization[J]. IEEE Transactions on Image Processing, 2001, 10(4): 623 - 631.
- [5] HUANG Q, ZHANG L, WEI S, et al. Learned 2D-TwISTA for 2-D sparse ISAR imaging[J]. IEEE Geoscience and Remote Sensing Letters, 2025, 22: 1-5.
- [6] WANG L Z, WANG L, CONDE M H, et al. A fast total-variation driven network for sparse aperture ISAR imaging[J]. Digital Signal Processing, 2024, 151: 104515
- [7] 全英汇,吴耀君,邢孟道,等.基于稀疏恢复的雷达信号处理研究综述[J].雷达学报,2024,13(01):46-67.
QUAN Y H, WU Y J, XING M D, et al. A review of radar signal processing based on sparse recovery[J]. Journal of Radars, 2024, 13(01): 46 - 67.
- [8] YANG J, WANG Y. Sparse aperture inverse synthetic aperture radar imaging for maneuvering targets with migration through resolution cells correction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2025, 18: 4446-4472.
- [9] DONOHO D. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [10] ZHANG Y, BAI X, ZHOU F. High-resolution ISAR imaging of maneuvering targets based on 2-D complex fast sparse Bayesian learning[J]. IEEE Transactions on Radar Systems, 2025, 3: 995-1005.
- [11] WANG L, LOFFELD O, MA K L, et al. Sparse ISAR imaging using a greedy kalman filtering approach[J]. Signal Processing, 2017, 138(C): 1-10.
- [12] 胡长雨,汪玲,朱栋强.结合字典学习技术的 ISAR 稀疏成像方法[J].电子与信息学报,2019,41(7):1735-1742.
HU C Y, WANG L, ZHU D Q. Sparse ISAR imaging exploiting dictionary learning[J]. Journal of Electronics & Information Technology, 2019, 41(7): 1735-1742.
- [13] HU C Y, WANG L, ZHU D Y, et al. Inverse synthetic aperture radar sparse imaging exploiting the group dictionary learning[J]. MDPI Remote Sensing, 2021, 13(14): 2812-2833.
- [14] 胡长雨,陈春风,汪玲,等.结合最近邻图模型的稀疏 ISAR 成像方法[J].电子学报,2024,52(01):170-180.
HU C Y, CHEN C F, YI W Y, et al. Sparse ISAR imaging combined with nearest neighbor graph model[J]. Acta Electronica Sinica, 2024, 52(01): 170-180.
- [15] ZHANG C, ZHANG S, LIU Y, et al. Fast bayesian method for joint sparse ISAR imaging and motion compensation for uniform rotating targets[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62:1-18.
- [16] AHARON M, ELDA M, BRUCKSTEIN A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017): ACM Press, 2017:1-11.
- [18] ZHANG Z, WU Y, ZHOU J, et al. SG-Net: syntax guided transformer for language representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(6): 3285-3299.
- [19] JARQUIN-VASQUEZ H, ESCALANTE H J, MONTES-Y-GOMEZ M, et al. GHA: A gated hierarchical attention mechanism for the detection of abusive language in social media[J]. IEEE Transactions on Affective Computing, 2025, 16(2): 946-959.
- [20] ZHANG X, ZHOU Y, YANG G, et al. Anchor attention, small cache: code generation with large language models[J]. IEEE Transactions on Software Engineering, 2025, 51(6): 1866-1881.
- [21] ZAFAR A. Single stage adaptive multi-attention network for image restoration[J]. IEEE Transactions on Image Processing, 2024, 33: 2924-2935.
- [22] JIANG B, LIU Y, CHEN X, et al. Graph attention in attention network for image denoising[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2023, 53(11): 7077-7088.
- [23] PEI, X, DENG X, XIONG N N, et al. Complex graph analysis and representation learning: problems, techniques, and applications [J]. IEEE Transactions on Network Science and Engineering, 2024, 11(5): 4990-5007.

- [24] ZHU D Y, WANG L, YU Y S, et al. Robust ISAR range alignment via minimizing the entropy of the average range profile[J]. IEEE Geosciences and Remote Sensing Letters, 2009, 6(2): 204 - 208.
- [25] 汪玲, 朱岱寅, 朱兆达. 基于 SAR 实测数据的舰船成像研究[J]. 电子与信息学报, 2007, 29(2): 401-404.
- WANG L, ZHU D Y, ZHU Z D. Study on ship imaging using SAR real data[J]. Journal of Electronics and Information Technology, 2007, 29(2): 401-404.