

结合字典学习技术的ISAR稀疏成像方法

胡长雨 汪玲* 朱栋强

(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 南京 210016)

摘要: 鉴于稀疏ISAR成像方法的成像质量受到待成像场景的稀疏表示不准确的限制, 该文将字典学习(DL)技术引入到ISAR稀疏成像中, 以提升目标成像质量。该文给出基于离线DL和在线DL两种ISAR稀疏成像方法。前者通过已有同类目标ISAR图像进行学习, 获得更优稀疏表示, 后者在成像过程中从现有数据中通过优化获得稀疏表示。仿真和实测ISAR数据成像结果表明, 结合离线DL和在线DL的成像方法均可获得比现有方法更优的成像结果, 离线DL成像优于在线DL成像, 而且前者计算效率优于后者。

关键词: 逆合成孔径雷达; 稀疏成像; 稀疏表示; 字典学习; 压缩感知

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2019)07-1735-08

DOI: 10.11999/JEIT180747

Sparse ISAR Imaging Exploiting Dictionary Learning

HU Changyu WANG Ling ZHU Dongqiang

(Key Laboratory of Radar Imaging and Microwave Photonics of the Ministry of Education, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: In view of the imaging quality of sparse ISAR imaging methods is limited by the inaccurate sparse representation of the scene to be imaged, the Dictionary Learning (DL) technique is introduced into ISAR sparse imaging to get better sparse representation of the scene. An off-line DL based imaging method and an on-line DL based imaging method are proposed. The off-line DL imaging method can obtain a better sparse representation via a dictionary learned from the available ISAR images. The on-line DL imaging method can obtain the sparse representation from the data currently considered by jointly optimizing the imaging and DL processes. The results of both simulated and real ISAR data show that the on-line DL imaging method and the off-line dictionary imaging method are both able to better sparsely represent the target scene leading to better imaging results. The off-line DL based imaging method works better than the on-line DL based imaging method with respect to both imaging quality and computational efficiency.

Key words: Inverse Synthetic Aperture Radar (ISAR); Sparse imaging; Sparse representation; Dictionary Learning(DL); Compressive Sensing (CS)

1 引言

逆合成孔径雷达(Inverse Synthetic Aperture Radar, ISAR)可获得非合作目标的高分辨率精细图像, 是目标识别的重要手段。ISAR成像基于距离-多普勒(Range-Doppler, RD)原理^[1]。距离向高分辨通过发射大带宽信号和脉冲压缩技术获得, 方位向高分辨通过相干积累成像时间内的多普勒调制回波

信号获得。在小转角假设下, 通过简单的快速1维傅里叶变换(Fast Fourier Transform, FFT)即可获得方位向分辨。

除了传统的RD成像方法, 稀疏成像^[2]也可用于ISAR成像。稀疏成像是以场景稀疏性为约束条件的优化类成像方法。最早由Cetin等人^[3]提出合成孔径雷达(Synthetic Aperture Radar, SAR)稀疏成像方法, 之后出现了许多相关研究^[4-9]。与传统RD成像方法相比, 稀疏成像的结果具有超分辨率特性, 没有副瓣干扰, 图像的对比度更高。

2008年以来基于压缩感知(Compressive Sensing, CS)的成像方法也受到了许多研究者的关注^[10,11]。CS成像方法与稀疏成像方法类似, 都依赖于成像场景散射率分布本身稀疏或者在某个变换域存在稀

收稿日期: 2018-07-23; 改回日期: 2019-01-21; 网络出版: 2019-02-14

*通信作者: 汪玲 tulip_wling@nuaa.edu.cn

基金项目: 国家自然科学基金(61871217), 江苏省研究生科研与实践创新计划(KYCX18_0291)

Foundation Items: The National Natural Science Foundation of China (61871217), The Postgraduate Research & Practice Innovation Program of Jiangsu Province (KYCX18_0291)

疏表示的假设,但CS成像着重对欠采样数据的成像。由于CS成像同样基于稀疏假设,具有稀疏成像的图像特点,但只需极少数据,对系统简化或小型化,降低数据处理负担极有好处。

通常ISAR成像场景中背景的散射率较低,而待成像目标由散射较强的散射体组成,因此ISAR成像场景具备基本的稀疏性,大多数现有的ISAR稀疏成像方法也都假设目标场景是自然稀疏,能够重建目标图像。但是,成像结果相比传统RD成像结果过分强调点状特征,对于目标识别来说,重要部件的轮廓、边缘、纹理等其它特征也很重要,如何能更好地重建目标图像,弥补上述不足,值得研究。从根本上,简单的ISAR目标场景自然稀疏假设实际上限制了图像重建质量的提升。文献[12]针对这一问题进行了研究,通过构造特定的变换矩阵,并求出在该变换矩阵下的ISAR场景更好的稀疏表示,然后通过该稀疏表示重建出质量更高的ISAR图像。类似的思想在SAR成像中也有应用,例如文献[8]表明,SAR场景通过特定的变换矩阵变换到其它域,可以增强特定的特征,有助于提升SAR成像结果的质量。文献[9]将多个变换合成,形成超完备的稀疏表示,用于增强目标图像的多种特征。

通过上述分析可知,现有的ISAR稀疏成像方法,都是用预先设定的稀疏变换矩阵来求得目标场景的稀疏表示,由于稀疏变换矩阵缺少特定目标场景的先验信息,无法准确地得到特定目标场景准确的稀疏表示。针对这一问题,根据字典学习(Dictionary Learning, DL)理论,本文提出基于DL的ISAR成像方法。首先利用已有同类目标的ISAR图像构建训练数据库,然后通过训练样例学习一个经验字典,其中字典的原子是来自同类型目标图像的先验信息,而不是一些理论模型。因为经过学习的字典中含有同类型目标场景的先验信息,所以能通过该字典找到目标场景更准确的稀疏表示。

基于DL的稀疏表示已被用于图像重建和图像复原等任务,并取得了很好的效果。例如高维图信号处理[13],结构化数据分类[14],图像重建[15,16]等。最广泛使用的一种DL技术是K-SVD[17]算法,该算法基于训练样本,通过联合的机制来学习出最优的字典。本文采用K-SVD算法来学习用于ISAR成像的字典,学习过程能够融入同类型目标的先验信息。根据数据已有目标图像数据量不同,本文的字典可以在已有的大量的同类型样本上学习得到,然后将该字典加入到目标场景重建,这种方式称之为离线DL成像方法。此外,还可以将DL和目标场景重建构建为联合优化问题,并通过迭代优化方法求得最终的成像结果,这种方式称之为在线DL成像

方法。本文给出了两种成像方法的成像模型,并将两种DL成像方法的实验结果和正交匹配跟踪(Orthogonal Matching Pursuit, OMP)方法[18]实验结果进行对比分析。仿真和实测数据的成像结果表明,基于DL成像方法重建的目标场景比非DL的更好,离线DL成像方法的结果要优于在线DL成像方法的结果。

本文的结构安排如下:第2节给出ISAR成像模型。在第3节中,给出了基于离线DL和在线DL的两种雷达成像方法模型,详细介绍了两种成像模型的优化方法。第4节给出了仿真和实测ISAR数据成像结果,并且对成像结果进行了分析。第5节对本文内容进行了总结。

2 压缩感知ISAR成像模型

目标散射率与ISAR测量数据的关系表示为矩阵形式

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

其中, $\mathbf{G} \in \mathbb{C}^n$ 表示的是向量化的ISAR测量数据。假设雷达回波的距离向或快时间采样数为 N_r , 方位向或慢时间采样数为 N_a , 则 $n = N_r \times N_a$, $\sigma \in \mathbb{C}^n$ 表示的是向量化的待成像场景反射率函数, $\mathbf{H} \in \mathbb{C}^{n \times n}$ 表示的是观测矩阵, $\mathbf{n} \in \mathbb{C}^n$ 表示ISAR回波中的噪声。

在CS框架下,以远低于奈奎斯特采样率获得的较少数据进行成像,式(1)中的成像模型改写为

$$\mathbf{G}_s = \Psi\sigma + \mathbf{n}_s \quad (2)$$

其中, $\mathbf{G}_s \in \mathbb{C}^m$, 表示向量化的两维随机降采样得到的测量数据, $\Psi \in \mathbb{C}^{m \times n}$ 且 $m < n$, 表示的是测量矩阵,该矩阵是通过将 $\mathbf{H}$ 随机采样获得的部分傅里叶矩阵, $\mathbf{n}_s$ 为测量噪声。

测量矩阵 Ψ 满足RIP条件[9],且待成像目标场景满足稀疏假设,成像问题被描述为 l_1 范数最小化[19]问题

$$\hat{\sigma} = \underset{\sigma}{\operatorname{argmin}} \|\sigma\|_1, \quad \text{s.t.} \|\mathbf{G}_s - \Psi\sigma\|_2 \leq \epsilon \quad (3)$$

假设矩阵 $\mathbf{D}$ 表示稀疏变换,目标场景 σ 的稀疏表示记作 $\mathbf{w} = \mathbf{D}\sigma$, 其中向量 $\mathbf{w}$ 表示稀疏系数。则成像问题被描述为

$$\hat{\mathbf{w}} = \underset{\mathbf{w}}{\operatorname{argmin}} \|\mathbf{w}\|_1, \quad \text{s.t.} \|\mathbf{G}_s - \Psi\mathbf{D}\mathbf{w}\|_2 \leq \epsilon \quad (4)$$

成像时,先求解稀疏系数向量 $\mathbf{w}$, 然后再生成目标图像

$$\hat{\sigma} = \mathbf{D}\mathbf{w} \quad (5)$$

3 结合字典学习的成像方法

本节主要介绍本文提出的离线DL成像方法和在线DL成像方法,这两种方法都采用图像分块策

略，以提高字典学习速度和图像重建的速度和质量。令 $\sigma \in \mathbb{C}^n$ 表示向量化的图像，维数为 $n \times 1$ ， $\sigma_{ij} \in \mathbb{C}^{n_p}$ 表示图像 σ 上的第 (ij) 个图像块，维数为 $n_p \times 1$ ， (ij) 表示图像块 σ_{ij} 的左上角元素在图像 σ 中的位置。离线DL成像中，对训练样本图像执行分块操作，以获得的图像块作为学习样本进行字典学习，将学习得到的稀疏变换字典用于目标场景分块重建。在线DL成像方法中，构建场景分块重建与分块字典学习的联合优化模型，再通过迭代优化的方式求解。在得到最优字典的同时，获得基于该字典重建的图像块。需要注意的是，当重建步长小于图像块宽度，重建的图像块之间存在重叠，本文中，重叠区域的取值定义为各图像块在当前位置的平均值。

3.1 基于离线字典学习的成像方法

离线DL的优势在于能够从已有的同类型的目标场景图像中学习到大量的先验信息。离线DL问题表示为

$$\min_{D_p, w_{ij}^t} \sum_{ij} \|F_{ij} \sigma_t - D_p w_{ij}^t\|_2^2, \text{ s.t. } \forall ij \|w_{ij}^t\| \leq T_p \quad (6)$$

其中， σ_t 表示训练图像。 $F_{ij} \in \mathbb{C}^{n_p \times n}$ 表示从图像 σ_t 上提取出图像块 σ_{ij}^t 的操作，即， $\sigma_{ij}^t = F_{ij} \sigma_t$ 。 D_p 表示需要学习的字典， w_{ij}^t 为图像块 σ_{ij}^t 的稀疏表示， T_p 表示稀疏度。

本文采用K-SVD算法求解式(6)，其中的每一次迭代都包括两步：稀疏编码和码本更新。在稀疏编码过程中，字典 D_p 是固定的，使用OMP算法求得稀疏表示 w_{ij}^t 。在码本更新过程中，字典 D_p 每一列根据计算的稀疏表示残差大小依次更新。当稀疏度大于阈值时，稀疏编码结束，再执行一次码本更新，此时K-SVD算法收敛。将训练完毕的稀疏变换矩阵 D_p 作为学习好的字典，用于后续的图像重建过程。因为采用复数形式的ISAR图像训练字典，所以最终得到的字典为复数形式的稀疏变换矩阵。接着将 D_p 用于下一步的图像重建过程。

图像重建过程可以表示为

$$\min_{\sigma, w_{ij}} \sum_{ij} \|F_{ij} \sigma - D_p w_{ij}\|_2^2 + \lambda \|G_s - \Psi \sigma\|_2^2, \quad (7)$$

$$\text{ s.t. } \quad \forall ij \|w_{ij}\|_1 \leq T_p$$

其中， σ 为待重建的目标图像， w_{ij} 为待重建目标图像块的稀疏表示系数， G_s ， F_{ij} 和 Ψ 在上文已经介绍过， λ 是正则化参数，用来平衡数据保真度和稀疏度。式(7)中第1项计算的是稀疏表示和待重建图像块之间的表示误差，通过最小化表示误差实现由 $D_p w_{ij}$ 重构 σ_{ij} ，第2项计算的是数据保真度。

求解式(7)时，采用交替迭代的策略，每一次迭代都包括两步：估计 w_{ij} ，更新 σ 。首先构建如下优化问题估计 w_{ij}

$$\min_{w_{ij}} \sum_{ij} \|F_{ij} \Psi^H G_s - D_p w_{ij}\|_2^2, \quad (8)$$

$$\text{ s.t. } \quad \forall ij \|w_{ij}\|_1 \leq T_p$$

其中，上角标H代表厄米特矩阵变换。字典 D_p 是离线学习得到的。求解式(8)时，采用贪婪算法OMP算法。

求得字典 D_p 和稀疏系数 w_{ij} 后，代入式(7)中，则式(7)可以转换为最小二乘问题，等式两边同时对 σ 求导并令导数等于0，可以得到等式

$$\sum_{ij} F_{ij}^T F_{ij} \sigma + \lambda \Psi^H \Psi \sigma = \lambda \Psi^H G_s + \sum_{ij} F_{ij}^T D_p w_{ij} \quad (9)$$

其中， $\sum_{ij} F_{ij}^T F_{ij} \in \mathbb{C}^{n \times n}$ 是对角矩阵，对角线上的元素对应于图像像素的位置，对角线上的值等于在当前像素位置上有贡献的重建图像块数量。

为了降低计算的复杂度，本文假设图像分块时在图像边缘进行折回处理^[20]，即在图像右下角进行图像分块时，如果图像边缘的像素不够，则利用左上角的像素进行填补，分块步长近似为1。在上述假设下，对角矩阵 $\sum_{ij} F_{ij}^T F_{ij}$ 中对角线上的元素都相等，即 $\sum_{ij} F_{ij}^T F_{ij} = \beta I$ ，其中 $I \in \mathbb{C}^{n \times n}$ 是一个单位标示矩阵， β 表示在当前像素上有贡献的图像块数量。将式(2)代入式(9)，则 σ 可以通过式(10)得到

$$\sigma = \frac{\sum_{ij} F_{ij}^T D_p w_{ij}}{\beta} \quad (10)$$

其中， σ 为更新后得到的目标场景。

3.2 基于在线字典学习成像方法

在线DL成像方法是将求解稀疏变换字典的DL问题与场景图像块重建问题结合在一起，构建一个联合优化问题，然后通过迭代分步求解的策略求解。

在线DL成像问题可以表示为

$$\min_{\sigma, D_p, w_{ij}} \sum_{ij} \|F_{ij} \sigma - D_p w_{ij}\|_2^2 + \lambda \|G_s - \Psi \sigma\|_2^2, \quad (11)$$

$$\text{ s.t. } \quad \forall ij \|w_{ij}\| \leq T_p$$

从式(11)中可以看出，DL被加到图像重建的过程中，不再需要单独离线的DL。考虑到在线DL成像问题只有极少量的测量数据可用，DL可用

的训练数据少。因此,本文预先对字典进行初始化,从而使得DL更准确更有效,在提高字典 D_p 中原子的准确率的同时还可以加快DL的收敛。字典初始化在求解式(11)前完成。

令 $M \in \mathbb{C}^{n_p \times k}$ 表示图像块集合,其中, n_p 表示向量化的图像块, k 表示图像块的数量。令 $Z \in \mathbb{C}^{n_p \times l}$ 表示 M 中的一个子集,其中 l 表示从 M 中选择的图像块的数量,且 $l < k$ 。对 $B = ZZ^T$ 进行奇异值分解

$$B = U \Delta V^T \quad (12)$$

其中, Δ 表示的是对角阵,对角线元素是矩阵 B 的特征值, U 和 V 表示正交矩阵,列向量是矩阵 B 的特征向量。矩阵 U 的前 n_p 列作为字典 D_p 初始原子,从而完成字典的初始化。

在式(11)中有3个需要求解的未知参数: σ , D_p , w_{ij} 。本文采用迭代交替的方法来求解。每一次迭代过程中包括两步:联合优化 D_p 和 w_{ij} ,更新 σ 。在联合优化 D_p 和 w_{ij} 时,固定 σ ,并采取K-SVD策略求解,稀疏系数 w_{ij} 使用OMP算法求得,字典则按照3.1节中所述的方式更新。当稀疏度大于阈值时,K-SVD算法收敛,其中复数形式的稀疏变换矩阵停止更新,并作为当前迭代过程中的字典,加入到求解 σ 的计算过程中。更新 σ 时,固定其它参数值,利用共轭梯度算法^[15]估计 σ 。

4 ISAR数据成像结果及分析

本节给出采用离线DL和在线DL两种成像方法对飞机、船、卫星ISAR数据的成像结果及分析。飞机和船目标数据为实测ISAR数据。前者为C波段地基雷达,发射信号带宽400 MHz,后者为X波段岸基雷达,发射信号带宽170 MHz。两种数据都采用平均距离像最小熵法^[21]进行距离对准,采用改进的相位梯度自聚焦方法^[22]进行相位补偿。

本文采用两种评价方式评价离线DL和在线DL成像方法的成像结果。第1种评价方式称为基于“真值”的评价指标,第2种为传统的评价指标。基于“真值”的评价指标评价的是重建散射点的幅度和位置的准确率。传统的评价指标评价的是重建图像的质量。基于“真值”的评价方法是将不同图像重建算法重建的ISAR图像与理想情况下ISAR图像作对比,判断算法成像效果的优劣,而这理想情况下的ISAR图像即为真值。但是由于在ISAR成像系统中,目标为非合作目标,不可能得到目标的真实图像,所以本文把完整数据得到的高质量图像作为参考图,定义为“真值”。通过比较“真值”图和DL类方法重建的图像,对算法的性能进行评

价。基于“真值”的评价指标^[23]具体包括:虚警(False Alarm, FA),漏检(Missed Detection, MD)和相对均方根误差(Relative Root Mean Square Error, RRMSE)。FA用于评估错误重建的散射点数,MD表示未被重建出来的目标散射点数。RRMSE反映的是所有重建散射点幅度的重构误差。

传统的成像质量评估指标包括:目标杂波比(Target-to-Clutter Ratio, TCR),图像熵(ENTropy of the image, ENT)和图像对比度(Image Contrast, IC)。

4.1 实测飞机数据成像结果与分析

本节给出实测飞机目标数据的成像结果与分析。飞机目标原始数据大小为 100×80 ,通过2维随机降采样构造测量数据,降采样率为50%。对数据采用分块策略成像,分块步长为3,分块大小为 8×8 。飞机图像稀疏度通过文献^[24]中的方法估计得到,稀疏度为900。

为了验证DL类成像方法的有效性,将基于DL的成像结果与贪婪卡尔曼滤波(Greedy Kalman Filtering, GKF)^[9]方法和未加入字典的OMP方法^[18]的成像结果进行比较。这些方法的成像结果如图1所示。图1(a)为飞机目标全数据采用RD方法成像的结果。图1(b)、图1(c)、图1(d)和图1(e)分别是50%的降采样数据采用GKF、OMP、离线DL成像方法和在线DL成像方法的结果。

对比可知,DL类成像方法重建的结果要优于非学习的GKF和OMP成像方法重建的结果,旁瓣和虚假散射点更少,重建飞机轮廓更加完整。可见,DL类方法中采用的字典能够自适应于未知的目标场景,并寻找到未知目标场景在变换域中的最优稀疏表示系数,进而使得DL类方法重建的结果更准确。

对比图1(d)和图1(e)可知,离线DL成像方法重建的图像质量略优于在线DL成像方法重建的图像质量。前者成像结果中虚假散射点数更少,这是因为离线DL成像方法使用了大量同类型高质量的目标图像更新字典原子,使得字典的原子更加准确,进而能够以更小的残差表示出目标区域散射率,提高目标区域的重建质量。

进一步对比图1(a)、图1(d)和图1(e)可知,DL类方法利用50%数据重建的图像优于RD方法利用全数据重建的图像,重建结果中副瓣响应更少。

对图1的成像结果进行定量评价,将全数据的RD成像结果定义为“真值”图像,作为评价的参考基准。评价结果如表1所示。

从表1的FA和MD指标可知,与GKF和OMP




图 1 飞机目标全数据采用RD方法和50%数据采用CS 方法的成像结果

表 1 飞机目标成像性能评价

成像方法	FA	MD	RRMSE	TCR	ENT	IC	运算时间(s)
OMP	89	165	0.1923	57.0203	5.4631	8.0294	116.1757
GKF	86	103	0.2044	55.5930	5.3800	8.1449	1.0058e3
在线DL	74	75	0.1535	57.5629	5.3807	8.2103	52.5790
离线DL	64	70	0.1411	59.0322	5.3685	8.2868	24.8510

成像方法的结果相比，DL类成像方法重建得更准确，错误重建的散射点和未被重建的散射点数更少。离线DL成像方法结果优于在线DL方法成像结果，这与图1(d)和图1(e)的对比一致。对比RRMSE可知，与GKF和OMP方法相比，DL类方法结果的幅度误差更小，其中离线DL方法重建结果的幅度误差最小，优于在线DL方法重建的结果。

对比表1中TCR可知，DL类方法能够更好地重建目标区域散射点的位置。从ENT指标可知，GKF和DL类方法能够获得较小的ENT值，说明这两种方法能够更准确的重建目标场景的散射率。结合TCR和ENT可知，DL类方法能够更准确地重建目标区域散射点的位置。分析可知，GKF的ENT值略小于在线DL的ENT，但结合其它指标分析，GKF的结果中伴随着较多的虚假散射点，图像质量较差，所以在线DL的成像结果更好。IC指标表明DL类方法重建图像的对比度更高，这与从视觉上分析图1的结果一致。

由运算时间可知，DL类方法重建图像速度更快，这是由于贪婪算法的复杂度是非线性增长，且

与待重建向量维数有关，对图像分块的方式降低待重建向量的维数，进而可以降低DL类方法的复杂度，提高了重建效率。

4.2 仿真卫星目标成像结果与分析

本节给出仿真的卫星数据成像的结果。卫星数据是利用卫星工具包(Satellite Tool Kit, STK)生成卫星轨道数据进行回波模拟得到的。雷达波长为0.03 m，发射信号带宽为1 GHz，距离向采样频率为1.2 GHz，脉冲重复频率为400 Hz，成像积累2048个脉冲。仿真卫星目标数据大小为200×200，通过2维随机降采样方式得到测量数据，降采样率为25%。成像采用图像分块的策略，分块步长为3，图像块大小为8×8。稀疏度设置为923^[24]。图2给出了卫星数据成像结果。

对比图2(b)、图2(c)、图2(d)和图2(e)可知，DL类方法重建的图像质量要优于GKF和OMP方法重建的图像。DL类方法重建结果中虚假散射点更少，目标边缘和轮廓更加清晰(如图2中各子图右上角所示)。可见，通过字典学习可以获得更优的稀疏表示，进而提高成像质量。比较图2(d)和图2(e)

可知, 离线DL方法与在线DL方法性能相近, 前者图像重建效果稍好, 卫星整体轮廓更清晰。离线DL过程中使用了大量同类型卫星目标ISAR图像进行字典训练, 因此相比在线DL融入了更多先验信息, 有助于图像质量的提升。

表2为卫星数据成像结果的定量评价, 同样以RD成像结果作为基准, 即“真值”图像。从FA可以看出, DL类方法错误重建的散射点数较少, 随着训练样本的增加, 离线DL方法错误重建的散射点数最少。可以看到, GKF方法错误重建的散射点数小于在线DL方法的结果, 但继续比较MD值发现, DL类方法远优于GKF和OMP方法, 这是因为GKF和OMP强调稀疏重构, 所以MD值较大。综合FA和MD评价指标可知, DL类方法优于GKF和OMP方法。

对比RRMSE可知, DL类方法能够更准确的重建散射点的幅度, 其中离线DL方法结果的幅度重建误差最小。

分析TCR可知, DL类方法优于其它两类方法, 表明DL类方法能够更准确的重建目标区域散射点

的位置。但是, 由ENT和IC指标比较发现, GKF和OMP结果的ENT更小, IC更大。由图2(b)和图2(c)可见, GKF和OMP重建结果中, 未被重建的散射点数较多, 图像非常稀疏, 因此对应图像的熵小, 对比度大, 但图像质量并非最优。因此图像质量评价应综合多种指标来更为客观地衡量。对比运算时间, DL类成像方法的效率仍然明显高于GKF和OMP算法。

5 结论

本文提出了基于DL的ISAR稀疏成像方法。利用DL技术, 可以获得更准确的目标场景的稀疏表示。可以利用可用的ISAR数据进行离线的DL或者可自适应于测量数据的在线DL两种方法获得准确的稀疏表示字典, 并利用该字典重建目标场景。实测和仿真数据的实验结果表明, 与非学习的成像方法相比, 基于DL的成像方法可以获得更准确的目标场景的稀疏表示, 进而能够重建出高质量的目标图像。在DL的成像方法中, 离线DL加入了大量的同类型目标的先验信息, 进而成像效果更好。




图2 卫星目标全数据采用RD方法和25%数据采用CS方法的成像结果

表2 卫星目标成像性能评价

成像方法	FA	MD	RRMSE	TCR	ENT	IC	运算时间(s)
OMP	146	507	0.3736	63.2956	6.4209	9.8099	56.1323
GKF	140	478	0.2550	65.3382	6.3740	10.3843	1.6485e4
在线DL	142	161	0.1765	65.9163	6.6098	9.5039	19.2178
离线DL	122	147	0.1564	67.2506	6.6137	9.6094	4.1543

参 考 文 献

- [1] PRICKETT M J and CHEN C C. Principles of inverse synthetic aperture radar /ISAR/ imaging[C]. IEEE Electronics and Aerospace Systems Conference, New York, USA, 1980: 340–345.
- [2] GENG Minming, TIAN Ye, FANG Jian, *et al.* Implementation of GPU-based iterative shrinkage-thresholding algorithm in sparse microwave imaging[C]. Proceedings of 2012 IEEE International Geoscience and Remote Sensing Symposium, Munich, Germany, 2012: 3863–3866. doi: [10.1109/IGARSS.2012.6350569](https://doi.org/10.1109/IGARSS.2012.6350569).
- [3] CETIN M and KARL W C. Feature-enhanced synthetic aperture radar image formation based on nonquadratic regularization[J]. *IEEE Transactions on Image Processing*, 2001, 10(4): 623–631. doi: [10.1109/83.913596](https://doi.org/10.1109/83.913596).
- [4] 汪玲, 朱栋强, 马凯莉, 等. 空间目标卡尔曼滤波稀疏成像方法[J]. 电子与信息学报, 2018, 40(4): 846–852. doi: [10.11999/JEIT170319](https://doi.org/10.11999/JEIT170319).
WANG Ling, ZHU Dongqiang, MA Kaili, *et al.* Sparse imaging of space targets using Kalman filter[J]. *Journal of Electronics & Information Technology*, 2018, 40(4): 846–852. doi: [10.11999/JEIT170319](https://doi.org/10.11999/JEIT170319).
- [5] 徐宗本, 吴一戎, 张冰尘, 等. 基于L1/2正则化理论的稀疏雷达成像[J]. 科学通报, 2018, 63(14): 1306–1319. doi: [10.1360/N972018-00372](https://doi.org/10.1360/N972018-00372).
XU Zongben, WU Yirong, ZHANG Bingchen, *et al.* Sparse radar imaging based on L1/2 regularization theory[J]. *Chinese Science Bulletin*, 2018, 63(14): 1306–1319. doi: [10.1360/N972018-00372](https://doi.org/10.1360/N972018-00372).
- [6] HASANKHAN M J, SAMADI S, and CETIN M. Sparse representation-based algorithm for joint SAR image formation and autofocus[J]. *Signal, Image and Video Processing*, 2017, 11(4): 589–596. doi: [10.1007/s11760-016-0098-y](https://doi.org/10.1007/s11760-016-0098-y).
- [7] BI Hui, BI Guoan, ZHANG Bingchen, *et al.* Complex-image-based sparse SAR imaging and its equivalence[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5006–5014. doi: [10.1109/TGRS.2018.2803802](https://doi.org/10.1109/TGRS.2018.2803802).
- [8] SAMADI S, CETIN M, and MASNADI-SHIRAZI M A. Sparse representation-based synthetic aperture radar imaging[J]. *IET Radar, Sonar & Navigation*, 2011, 5(2): 182–193. doi: [10.1049/iet-rsn.2009.0235](https://doi.org/10.1049/iet-rsn.2009.0235).
- [9] WANG Ling, LOFFELD O, MA Kaili, *et al.* Sparse ISAR imaging using a greedy kalman filtering approach[J]. *Signal Processing*, 2017, 138: 1–10. doi: [10.1016/j.sigpro.2017.03.002](https://doi.org/10.1016/j.sigpro.2017.03.002).
- [10] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289–1306. doi: [10.1109/TIT.2006.871582](https://doi.org/10.1109/TIT.2006.871582).
- [11] BARANIUK R and STEEGHS P. Compressive radar imaging[C]. Proceedings of 2007 IEEE Radar Conference, Boston, USA, 2007: 128–133. doi: [10.1109/RADAR.2007.374203](https://doi.org/10.1109/RADAR.2007.374203).
- [12] WANG Lu, ZHAO Lifan, and BI Guoan. Structured sparse representation based ISAR imaging[C]. Proceedings of the 2014 15th International Radar Symposium, Gdansk, Poland, 2014: 1–5. doi: [10.1109/IRS.2014.6869264](https://doi.org/10.1109/IRS.2014.6869264).
- [13] YANKELEVSKY Y and ELAD M. Dictionary learning for high dimensional graph signals[C]. Proceedings of 2018 IEEE International Conference on Acoustics, Speech and Signal Processing, Calgary, Canada, 2018: 4669–4673.
- [14] YANKELEVSKY Y and ELAD M. Structure-aware classification using supervised dictionary learning[C]. Proceedings of 2017 IEEE International Conference on Acoustics, Speech and Signal Processing, New Orleans, USA, 2017: 4421–4425. doi: [10.1109/ICASSP.2017.7952992](https://doi.org/10.1109/ICASSP.2017.7952992).
- [15] SOĞANLUI A and CETIN M. Dictionary learning for sparsity-driven SAR image reconstruction[C]. Proceedings of 2014 IEEE International Conference on Image Processing, Paris, France, 2014: 1693–1697. doi: [10.1109/ICIP.2014.7025339](https://doi.org/10.1109/ICIP.2014.7025339).
- [16] JIANG Changhui, ZHANG Qiyang, FAN Rui, *et al.* Super-resolution CT image reconstruction based on dictionary learning and sparse representation[J]. *Scientific Reports*, 2018, 8(1): 8799. doi: [10.1038/s41598-018-27261-z](https://doi.org/10.1038/s41598-018-27261-z).
- [17] AHARON M, ELAD M, and BRUCKSTEIN A. rmK-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311–4322. doi: [10.1109/TSP.2006.881199](https://doi.org/10.1109/TSP.2006.881199).
- [18] PATI Y C, REZAIEFAR R, and KRISHNAPRASAD P S. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition[C]. Proceedings of the 27th Asilomar Conference on Signals, Systems and Computers, Pacific Grove, USA, 1993: 40–44. doi: [10.1109/ACSSC.1993.342465](https://doi.org/10.1109/ACSSC.1993.342465).
- [19] WANG Ling and LOFFELD O. ISAR imaging using a null space ℓ_1 minimizing Kalman filter approach[C]. Proceedings of the 2016 4th International Workshop on Compressed Sensing Theory and Its Applications to Radar, Sonar and Remote Sensing, Aachen, Germany, 2016: 232–236. doi: [10.1109/CoSeRa.2016.7745735](https://doi.org/10.1109/CoSeRa.2016.7745735).
- [20] AHARON M and ELAD M. Sparse and redundant modeling of image content using an image-signature-dictionary[J]. *SIAM Journal on Imaging Sciences*, 2008, 1(3): 228–247. doi: [10.1137/07070156X](https://doi.org/10.1137/07070156X).
- [21] ZHU Daiyin, WANG Ling, YU Yusheng, *et al.* Robust

- ISAR range alignment via minimizing the entropy of the average range profile[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(2): 204–208. doi: [10.1109/LGRS.2008.2010562](https://doi.org/10.1109/LGRS.2008.2010562).
- [22] 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 Ling, ZHU Daiyin, and ZHU Zhaoda. Study on ship imaging using SAR real data[J]. *Journal of Electronics & Information Technology*, 2007, 29(2): 401–404.
- [23] HU Changyu, WANG Ling, and LOFFELD O. Inverse synthetic aperture radar imaging exploiting dictionary learning[C]. Proceedings of 2018 IEEE Radar Conference, Oklahoma City, USA, 2018: 1084–1088. doi: [10.1109/RADAR.2018.8378712](https://doi.org/10.1109/RADAR.2018.8378712).
- [24] LOFFELD O, ESPETER T, and CONDE M H. From weighted least squares estimation to sparse CS reconstruction[C]. Proceedings of the 2015 3rd International Workshop on Compressed Sensing Theory and Its Applications to Radar, Sonar and Remote Sensing, Pisa, Italy, 2015: 149–153. doi: [10.1109/CoSeRa.2015.7330282](https://doi.org/10.1109/CoSeRa.2015.7330282).
- 胡长雨: 男, 1989年生, 博士生, 研究方向为逆合成孔径雷达稀疏成像.
- 汪 玲: 女, 1977年生, 教授, 博士生导师, 研究方向为合成孔径成像、逆合成孔径成像、无源成像、压缩感知成像和超分辨成像.
- 朱栋强: 男, 1993年生, 硕士生, 研究方向为基于压缩感知的ISAR成像.