

# 高分辨 SAR 目标复杂结构特征增强成像算法

黄博\*, 周劼, 江舸, 张海

(中国工程物理研究院电子工程研究所 四川 绵阳 621999)

**摘要:** 提出面向合成孔径雷达 (Synthetic Aperture Radar, SAR) 回波数据的复杂结构特征增强算法 (Complex Structure Feature Enhancement Algorithm, CEA), 面向 SAR 成像目标的复杂结构特征, 算法利用高阶方向全变分 (High-order Total Direction Variation, HOTDV) 正则算子表示, 面向 SAR 成像目标的稀疏特征, 算法用  $\ell_1$  正则算子表示。算法利用交替方向多乘法 (Alternating Direction Method of Multipliers, ADMM) 建立多正则约束优化框架, 设计复杂结构分裂变量和稀疏分裂变量, 并求出分裂变量解析更新解以实现 SAR 成像目标的复杂结构特征与稀疏特征的增强。多正则约束优化框架中的对偶分解保证多特征多任务处理能力, 增广拉格朗日项的使用则保证了算法的收敛性和稳健性。最后, 设计了仿真和实测 SAR 数据特征增强实验以验证算法的有效性, 对比多种传统结构特征增强算法以验证所提复杂结构特征增强算法的优越性。

**关键词:** 合成孔径雷达; 复杂结构特征增强; 高阶方向全变分; 交替方向多乘法; 近端算子; 相位误差补偿  
**文献标识码:** A

## Complex structure feature enhancement algorithm for high resolution SAR imaging

HUANG Bo\*, ZHOU Jie, JIANG Ge, ZHANG Hai

(Institute of Electronic Engineering, Chinese Academy of Engineering Physics, Mianyang 621999, China)

**Abstract:** A complex structure feature enhancement (CEA) algorithm was proposed, and in which the complex structure is represented by high-order total direction variation (HOTDV) regular operator, and the sparse feature of SAR imaging targets is represented by  $\ell_1$  regular operator. The algorithm uses Alternating Direction Method of Multipliers (ADMM) to establish a multi-regular constraint optimization framework, and designs complex structure splitting variables and sparse splitting variables. The analytic solutions of split variables are obtained to enhance the complex structure features and sparse features of SAR imaging targets. The thinking of "dual-decomposition" in the multi-regular constraint optimization framework guarantees the multi-feature processing capability, while the use of Augmented Lagrange term guarantees the convergence and robustness of the algorithm. Finally, simulation and measured SAR data complex structure feature enhancement experiments are designed to verify the effectiveness of the proposed algorithm, and several traditional structure feature enhancement algorithms are compared to verify the superiority of the proposed complex structural feature enhancement algorithm.

**Key words:** synthetic aperture radar (SAR), complex structure features enhancement (CEA), high-order total direction variation (HOTDV), alternating direction method of multipliers (ADMM), proximal mapping, phase error compensation

**PACS:** 84.40.Xb

## 引言

合成孔径雷达 (Synthetic Aperture Radar, SAR) 作为一种具备全天时、全天候工作能力的微波探测

手段, 其通过雷达天线的方位向运动累积, 而具有了高分辨二维/三维成像的独特优势, 因此成像结果也具有了空-时-频的多元特征<sup>[1-3]</sup>。高分辨 SAR 成

收稿日期: 2021-12-09, 修回日期: 2022-04-08

Received date: 2021-12-09, Revised date: 2022-04-08

基金项目: 国家自然科学基金委员会-中国工程物理研究院 NSAF 联合基金 (U2130202)

Foundation items: NSAF (U2130202)

作者简介 (Biography): 黄博 (1986-), 男, 四川绵阳人, 副研究员, 博士, 主要研究领域为雷达信号处理、雷达高度表设计

E-mail: vick123y@163.com

\* 通讯作者 (Corresponding author): E-mail: vick123y@163.com

像可以提取目标的结构特征,这些细节的结构信息对目标的探测和识别具有重要意义。然而,单一的正则约束下的目标特征增强已经不能满足高分辨率SAR复杂结构特征增强成像应用的需要<sup>[4]</sup>,面向雷达回波数据,在进行距离徙动校正,相位误差补偿后,合理地表征并增强成像目标的多元特征,对提升SAR目标检测和识别的精度至关重要<sup>[5]</sup>。

在SAR过程中,由于机载雷达与目标散射点之间的斜距随时间变化,使得来自同一目标散射点的回波信号在距离向分布于不同的距离单元内,造成了信号在方位向和距离向的耦合,形成距离徙动,进而导致直接成像结果无法满足分辨率要求。经典的距离徙动校正算法包括极坐标插值算法(PFA)<sup>[6]</sup>、反投影算法(BPA)<sup>[6]</sup>和距离多普勒算法(RDA)<sup>[7]</sup>。此外,受大气湍流等因素影响,雷达在运动过程中,存在未知位移,对地面动目标成像时,地面动目标也可能存在非理想位移,这种位移偏差以乘性相位误差的形式体现在SAR原始回波数据中,需要进行误差补偿。经典的相位误差补偿算法包括子孔径相关(Map Drift, MD)算法<sup>[8]</sup>、相位梯度自聚焦(Phase Gradient Autofocus, PGA)算法<sup>[9]</sup>和最小熵自聚焦(Minimum Entropy Autofocus, MEA)算法<sup>[10]</sup>等。

经过距离徙动校正和相位误差补偿后的目标进行特征增强可提升目标检测和识别的准确率。现在大多数成像算法,主要还是单纯地依赖宽带信号的相干处理,少数目标特征增强成像算法也仅仅在空域利用了若干简单的几何先验进行表征,导致成像结果对目标真实特征的恢复精度较低,同时降低了检测和识别精度,也带来了较高的运算复杂度。较为高效的增强目标特征方式为利用交替方向多乘子法(Alternating Direction Method of Multipliers, ADMM)<sup>[11]</sup>求解 $\ell_1$ 范数(Regularized Linear Regression, Lasso),该方法能有效实现成像目标的稀疏特征增强,但易在恢复过程中损失目标结构的连续性。因此考虑到成像目标的结构特征,经典的表征结构特征的正则约束项有全变分(Total Variation, TV)正则项<sup>[12]</sup>,其通过二维差分获取数据的梯度信息,惩罚目标结构的梯度变化捕捉目标结构变化,但其方向灵敏度差,且低阶差分已造成恢复数据的阶梯效应<sup>[13]</sup>。方向全变分(Directional Total Variation, DTV)正则项<sup>[13]</sup>在TV的基础上引入方向转移算子,更能贴合目标的结构变化,但是低阶差分仍不

能满足具有复杂结构的SAR成像目标结构表征。另外,单一的特征增强很难恢复结构复杂,信息丰富的高分辨SAR图像结果,因此需要考虑多种特征的联合增强。ADMM框架应用了对偶上升法,可以通过分解多个分裂变量,实现多个正则约束下的求解问题<sup>[5]</sup>。此外,ADMM框架引入了增广拉格朗日项,用以提升算法的收敛速度,为算法的效率和稳定提供保障。

高分辨合成孔径雷达(Synthetic Aperture Radar, SAR)成像可以提取目标的复杂结构,目标的复杂结构特征增强便于提高目标探测和识别等应用的准确率,然而单一的正则约束很难满足复杂结构特征的增强需求,因此需要多正则联合增强提取来实现目标复杂结构的增强。针对单一的正则约束已经不能满足高分辨率SAR复杂结构特征增强成像应用的需求问题,本文提出面向SAR回波数据的复杂结构特征增强算法(Complex Structure Feature Enhancement Algorithm, CEA)。面向SAR回波数据首先进行不可避免的距离徙动校正和乘性相位误差补偿,再构建基于交替方向乘子法的多正则约束目标求解框架,在全变分的基础上引入方向旋转因子和高阶运算形成高阶方向全变分正则项(High-order Total Direction Variation, HOTDV)以表征目标的复杂结构特征,引入 $\ell_1$ 正则项表征目标的稀疏特征,求解出对应正则项的近端算子和对应特征分裂变量的解析更新公式,以保证算法的稳健性和收敛速度。实验部分,应用了SAR仿真数据和实测数据来验证CEA算法的有效性,且利用相变分析法与其他传统特征增强算法进行比较以定量分析CEA算法的优越性。

## 1 回波信号模型

首先面向SAR模式,推导数据域回波信号表达式,并建立矩阵形式SAR回波信号模型。设定雷达载机以速度 $v$ 沿预定理想轨迹飞行,面向地面静止目标发射脉冲并接收回波信号。令 $\vec{r}$ 和 $\vec{x}$ 分别表示距离向和方位向单位矢量, $\mathbf{r}_s = (x_s, y_s)$ 表示任意第 $s$ 个静止目标散射点在方位向和距离向的矢量, $\mathbf{q}_0 = vt\vec{X}$ 为机载SAR天线相位中心的参考位置,其中 $t$ 为方位向慢时间变量, $\mathbf{R}_0 = \mathbf{R}_0\vec{r}$ 为载机到场景中心的斜距距离参考矢量,可得到静止目标距离载机的斜距表达式为

$$\begin{aligned} R(t) &= \left\| \mathbf{R}_0(t) + \mathbf{r}(t) - \mathbf{q}_0(t) \right\| \\ &= \left\| \mathbf{R}_0 - \mathbf{q}_0(t) \right\|_2 + \frac{\mathbf{R}_0 - \mathbf{q}_0(t)}{\left\| \mathbf{R}_0 - \mathbf{q}_0(t) \right\|_2} \mathbf{r} + \mathbf{O}(r), \end{aligned} \quad (1)$$

式中  $\mathbf{r} = x\vec{\mathbf{X}} + r\vec{\mathbf{r}}$  表示目标距离场景中心的偏移矢量,  $\mathbf{O}(\cdot)$  表示泰勒高阶展开项, 在远场假设背景下, 可忽略[14]。式(1)表示理想情况下目标到SAR相位中心的距离矢量, 但实际机载SAR工作过程中, 载机平台受大气绕流和导航误差等因素影响, 目标和载机之间会产生不可避免的相对位移误差。这种情况下, 设  $\Delta r(t)$  表示机载平台的运动偏差矢量在雷达波束方向的映射标量, 考虑发射信号的线性调频形式, 静止散射体的回波可以表示为

$$S_0(k, t) = \sum_p \eta_p \exp[-jkR_p(t)] \exp[jk\Delta r(t)] + \text{cn}(k, t) \quad (2)$$

式中  $k = 4\pi f/c$  表示距离波数变量,  $f$  为发射频率,  $c$  为光速,  $\text{cn}(k, t)$  表示未抑制的杂波噪声。由式(2)可见,  $k$  和  $t$  相互耦合, 造成距离徙动, 根据常规SAR处理流程, 可利用极坐标插值算法(Polar Formation Algorithm, PFA)[5]进行校正, 令  $k_x = R_0 k / \sqrt{R_0^2 + (vt)^2}$ ,  $k_y = -vtk / \sqrt{R_0^2 + (vt)^2}$ , 此外, 为了消除空间方位变量  $k_x$  对距离向波数  $k$  的依赖, 定义  $\tilde{t} = R_0 k_x / vk_0$  表示经过PFA插值处理后的方位时域变量,  $k_0 = 4\pi f_0/c$  表示波数中心, 此时式(2)可以表示为

$$S_0(\tilde{r}, \tilde{t}) = \sum_i \sin c(r - y_i) \exp(j2\pi \frac{2vx_i \tilde{t}}{\lambda R_0}) \exp(-j\Delta\varphi(\tilde{t})) + \text{cn}(\tilde{r}, \tilde{t}) \quad (3)$$

式中  $\tilde{r}$  表示距离向位置变量,  $\Delta\varphi(\tilde{t})$  表示距离向位置变量, 式(3)的回波信号可以以矩阵的形式表示为

$$\tilde{\mathbf{Y}} = \mathbf{EAX} + \mathbf{CN} \quad (4)$$

式中  $\tilde{\mathbf{Y}} \in \mathbf{C}^{N \times M}$  表示SAR回波复数据矩阵, 即式(3)中即推导得出的  $S_0(\tilde{r}, \tilde{t})$ ,  $M$  和  $N$  分别表示距离向分辨单元数和数据方位向采样点数,  $\mathbf{E} \in \mathbf{C}^{N \times M}$  表示乘性相位误差矩阵,  $\mathbf{X} \in \mathbf{C}^{N \times M}$  待恢复的目标数据矩阵,  $\mathbf{CN}$  为杂波和噪声,  $\mathbf{A} \in \mathbf{C}^{N \times M}$  为方位向傅里叶字典, 在SAR成像模式下, 表示为

$$\begin{aligned} \mathbf{A} &= [\mathbf{a}(f_d^1) \cdots \mathbf{a}(f_d^n)], \mathbf{a}(f_d^n) \\ &= [e^{-j2\pi f_d^n t_1} \cdots e^{-j2\pi f_d^n t_n}]^T \end{aligned} \quad (5)$$

式中  $f_d^n$  为方位多普勒频率,  $[\cdot]^T$  为矩阵转置操作符。

在进行多个正则项约束下的目标特征之前, 需要进行不可避免地相位误差补偿。最小熵自聚焦算法能在低信噪比的情况下保证补偿目标相位误

差的性能, 并较为准确地估计出相位误差[5], 可更新得到聚焦的SAR回波数据, 此时公式(4)中的误差字典  $\mathbf{E}$  得到补偿, 回波数据可表示为  $\mathbf{Y} = \mathbf{AX} + \mathbf{CN}$ , 并在此基础上进行多正则约束下的SAR目标特征增强。

## 2 复杂结构特征增强算法

### 2.1 ADMM多正则求解框架

在对经过运动误差补偿后的回波数据中目标矩阵  $\mathbf{X}$  的求解过程中, 添加正则化先验项  $\mu(\mathbf{X})$  进行约束可提高恢复图像的质量, 此时正则化逆问题的解为

$$\mathbf{X} = \arg \min_x \frac{1}{2} \left\| \mathbf{Y} - \mathbf{AX} \right\|_2^2 + \xi_1 \mu_1(\mathbf{X}) + \xi_2 \mu_2(\mathbf{X}) + \dots \quad (6)$$

式中  $\xi$  表示权重值。然而式(6)的求解过程往往复杂, 一方面最小化的过程可能是非平滑的, 另一方面多个正则项之间可能存在耦合。针对这一问题, 本文提出基于ADMM的多正则项协同学习框架, ADMM同时具备对偶上升的可分解性和多乘子的收敛性, 通过引入分解变量和对偶变量实现线性等式约束问题的求解, 处理问题形式如下

$$\begin{cases} \min_{\mathbf{X}, \mathbf{Z}} f(\mathbf{X}) + g(\mathbf{Z}) \\ \text{s.t. } \mathbf{KX} - \mathbf{Z} = \mathbf{C} \end{cases} \quad (7)$$

式中  $f(\mathbf{X}) = 1/2 \left\| \mathbf{Y} - \mathbf{AX} \right\|_2^2$  表示保真项, 限制恢复的误差值,  $g(\mathbf{Z}) = \sum_G \xi_g \mu_g(\mathbf{Z}_g)$  表示  $G$  个正则项的累加,  $\mathbf{Z} = [\mathbf{Z}_1 \cdots \mathbf{Z}_G]$  表示分裂变量组, 和目标变量  $\mathbf{X}$  之间的等式关系由参数矩阵  $\mathbf{K} = [\mathbf{K}_1 \cdots \mathbf{K}_G]$  和常数矩阵  $\mathbf{C}$  约束。同乘子法的处理过程, 针对问题(10)建立增广拉格朗日函数表示为

$$L(\mathbf{X}, \mathbf{Z}; \mathbf{U}) = f(\mathbf{X}) + g(\mathbf{Z}) + \mathbf{U}^H (\mathbf{KX} + \mathbf{Z} - \mathbf{C}) + \frac{\rho}{2} \left\| \mathbf{KX} + \mathbf{Z} - \mathbf{C} \right\|_F^2 \quad (8)$$

式中  $\mathbf{U}$  表示对偶变量矩阵,  $\rho$  为惩罚参数。为解决式(8)问题, ADMM进行迭代求解, 表示为

$$\begin{cases} \text{for } g = 1:G \\ \mathbf{Z}_g^{k+1} = \arg \min_{\mathbf{Z}_g} \xi_g \mu_g(\mathbf{Z}_g) + \frac{\rho}{2} \left\| \mathbf{KX}^{k+1} + \mathbf{Z}_g - \mathbf{C}_g \right\|_F^2 \\ \mathbf{D}_g^{k+1} = \mathbf{D}_g^k - \mathbf{KX}^{k+1} + \mathbf{Z}_g^{k+1} \\ \text{end} \\ \mathbf{Z}^{k+1} = [\mathbf{Z}_1^{k+1} \cdots \mathbf{Z}_G^{k+1}], \mathbf{D}^{k+1} = [\mathbf{D}_1^{k+1} \cdots \mathbf{D}_G^{k+1}] \\ \mathbf{X}^{k+1} = \arg \min_{\mathbf{X}} f(\mathbf{X}) + \frac{\rho}{2} \left\| \mathbf{KX} + \mathbf{Z}^k - \mathbf{D}^k \right\|_F^2 \end{cases} \quad (9)$$



式中  $k$  为算法迭代次数,  $\mathbf{D}$  表示  $\mathbf{U}$  缩放后的对偶变量组。由式(9)可见,基于ADMM的多正则化协同学习框架通过多分裂变量的引入,把面向  $\mathbf{X}$  的多正则项复杂逆问题转化成多个相对简单的面向  $\mathbf{Z}$  的子问题。进行到第  $k+1$  次迭代时,首先利用第  $k$  次  $\mathbf{Z}$  和  $\mathbf{D}$  的整合结果对  $\mathbf{X}$  进行更新,然后顺次进行子任务的更新,最后再进行整合,为第  $k+2$  次迭代做准备。

## 2.2 复杂结构特征表征与求解

依照式(9)所示基于ADMM的多正则约束优化框架,首先进行高阶方向变分(HOTDV)表针的目标复杂结构特征的更新,HOTDV正则项的表达式为

$$\|\mathbf{X}\|_{\text{HOTDV}}^Q = \sum_{q=1}^Q \alpha_{Q,q} \|\nabla^q \otimes \mathbf{X}\|_{2,1} = \|\nabla^q \otimes \mathbf{X}\|_{\alpha_{Q,q}}, \quad (10)$$

式中  $Q$  代表梯度的阶数,本文中取  $Q=3$ ,  $\alpha_{Q,q}$  表示不同阶数范数对应的权重值,  $\otimes$  表示 Hadamard 积操作符,  $\nabla$  表示梯度求解操作符。这里引入复杂结构特征分裂变量  $\mathbf{Z}_1$ , 结合HOTDV正则项的表达式,得到其更新求解公式为

$$\begin{aligned} \mathbf{Z}_1^{k+1} &= \arg \min_{\mathbf{Z}_1} \xi_1 \|\mathbf{Z}_1\|_{\text{HOTDV}}^Q + \frac{\rho}{2} \|\mathbf{K}\mathbf{X}^{k+1} + \mathbf{Z}_1 - \mathbf{C}_1\|_{\mathbf{F}}^2 \\ &= \arg \min_{\mathbf{Z}_1} \xi_1 \|\nabla^q \otimes \mathbf{X}\|_{\alpha_{Q,q}} + \frac{\rho}{2} \|\mathbf{K}\mathbf{X}^{k+1} + \mathbf{Z}_1 - \mathbf{D}_1^k\|_{\mathbf{F}}^2, \end{aligned} \quad (11)$$

式(11)中HOTDV范数的近端算子是软阈值,软阈值的提出是面向实数域的,为了应用到SAR回波复数,进行复数软阈值推导,取  $\mathbf{K}_1 = \mathbf{I}$  得到方向性结构特征解  $\mathbf{Z}_1$  的解析表达式,为

$$\begin{aligned} \mathbf{Z}_1^{k+1} &= \text{prox}_{\xi_1/\rho \|\nabla^q \otimes \mathbf{X}\|_{\alpha_{Q,q}}} [\mathbf{X}^{k+1} - \mathbf{D}_1^k] \\ &= \text{prox}_{\xi_1/\rho \|\nabla^q \otimes \mathbf{X}\|_{\alpha_{Q,q}}} [\mathbf{X}^{k+1} - \mathbf{D}_1^k], \end{aligned} \quad (12)$$

式(12)实现了复杂结构特征的求解,根据ADMM多正则约束优化框架(9),可以完成对偶变量  $\mathbf{D}_1$  的更新,表达式为

$$\mathbf{D}_1^{k+1} = \mathbf{D}_1^k - \mathbf{X}^{k+1} + \mathbf{Z}_1^{k+1}. \quad (13)$$

## 2.3 稀疏特征表征与求解

接下来,进行稀疏特征解  $\mathbf{Z}_2$  的求解,利用  $\ell_1$  表征稀疏特征,取  $\mathbf{K}_2 = \mathbf{I}$ , 得  $\mathbf{Z}_2$  的更新表达式为

$$\begin{aligned} \mathbf{Z}_2^{k+1} &= \arg \min_{\mathbf{Z}_2} \xi_2 \mu_2(\mathbf{Z}_2) + \frac{\rho}{2} \|\mathbf{X}^{k+1} + \mathbf{Z}_2 - \mathbf{D}_2^k\|_{\mathbf{F}}^2 \\ &= \arg \min_{\mathbf{Z}_2} \xi_2 \|\text{vec}(\mathbf{Z}_2)\|_1 + \frac{\rho}{2} \|\mathbf{X}^{k+1} + \mathbf{Z}_2 - \mathbf{D}_2^k\|_{\mathbf{F}}^2, \end{aligned} \quad (14)$$

$\ell_1$  范数的近端算子是软阈值,得到稀疏特征解的表

达式为

$$\begin{aligned} \mathbf{Z}_2^{k+1} &= \text{prox}_{\xi_2/\rho} [(\mathbf{X}^{k+1} - \mathbf{D}_2^k)] \\ &= \frac{\max \left[ \left( \left| (\mathbf{X}^{k+1} - \mathbf{D}_2^k) \right| - \frac{\xi_2}{\rho} \right), 0 \right] \cdot (\mathbf{X}^{k+1} - \mathbf{D}_2^k)}{\max \left[ \left( \left| (\mathbf{X}^{k+1} - \mathbf{D}_2^k) \right| - \frac{\xi_2}{\rho} \right), 0 \right] + \frac{\xi_2}{\rho}}, \end{aligned} \quad (15)$$

式中  $\xi_2/\rho$  是输入的阈值。得到  $\mathbf{Z}_2$ , 进而可以完成对偶变量  $\mathbf{D}_2$  的更新,表达式为

$$\mathbf{D}_2^{k+1} = \mathbf{D}_2^k - \mathbf{X}^{k+1} + \mathbf{Z}_2^{k+1}. \quad (16)$$

## 2.4 岭回归

最后,需要全面利用分离变量和对偶变量的解析解完成目标变量  $\mathbf{X}$  的更新。将保真度项带入公式,可将  $\mathbf{X}$  的解简化为岭回归问题,展开得到  $\mathbf{X}$  的函数

$$\begin{aligned} \mathbf{X}_2^{k+1} &= \arg \min_{\mathbf{X}} \{1/2 \|\mathbf{A}\mathbf{X} - \mathbf{Y}\|_{\mathbf{F}}^2 + \\ &\quad \frac{\rho}{2} \|\mathbf{X} - \mathbf{Z}^{k+1} - \mathbf{D}^{k+1}\|_{\mathbf{F}}^2\} \\ &= \arg \min_{\mathbf{X}} \{1/2 \text{Tr}[(\mathbf{A}\mathbf{X} - \mathbf{Y})(\mathbf{A}\mathbf{X} - \mathbf{Y})^H] + \\ &\quad \frac{\rho}{2} \text{Tr}[(\mathbf{X} - \mathbf{Z}^{k+1} - \mathbf{D}^{k+1})(\mathbf{X} - \mathbf{Z}^{k+1} - \mathbf{D}^{k+1})^H]\} \end{aligned} \quad (17)$$

式中  $\mathbf{H}$  为复数矩阵的共轭转置运算符,  $\text{Tr}[\cdot]$  为矩阵迹运算符。公式(17)是凸函数,因此  $\mathbf{X}$  的最优值可以通过矩阵求导获得,得到目标变量  $\mathbf{X}$  更新表达式为

$$\begin{aligned} \mathbf{X}^{k+1} &= [\mathbf{A}^H \mathbf{Y} + \rho(\mathbf{Z}^{k+1} - \mathbf{D}^{k+1})] \cdot (\mathbf{I} + \rho \mathbf{G}\mathbf{I})^{-1} \\ &= [\mathbf{A}^H \mathbf{Y} + \rho_1(\mathbf{Z}^{k+1} - \mathbf{D}^{k+1}) + \rho_2(\mathbf{Z}_2^{k+1} - \mathbf{D}_2^{k+1})] \\ &\quad \cdot (\mathbf{I} + \rho \mathbf{G}\mathbf{I})^{-1} \mathbf{I} \end{aligned} \quad (18)$$

式中  $\rho_1$  和  $\rho_2$  分别是两组特征的权重值。得到的目标变量  $\mathbf{X}$  融合了复杂结构特征和稀疏特征解析解,使得在有效抑制噪声等干扰的情况下,既增强稀疏特征,突出强散射点的信息,又有效地保留和突出了结构特征,且得益于框架的可分解性与多乘子的引入等优点,相较于传统的稀疏恢复算法稀疏贝叶斯(Sparse Bayesian Learning, SBL)算法<sup>[15]</sup>等,本算法的计算复杂度大大减少,使得算法的计算效率得到了保障。

## 2.5 算法流程

综上可总结复杂结构特征增强算法(CEA)流程如表1所示。本文所提复杂结构特征增强算法面向SAR回波数据,为实现成像目标的多特征增强,首

先进行了回波数据的相位误差补偿,在 ADMM 多正则优化框架下,建立复杂结构特征分裂变量  $Z_1$ , 稀疏特征分裂变量  $Z_2$  以及对应偶分裂变量  $D_1$  和  $D_2$ 。首先进行由高阶方向全变分正则项表征的目标复杂结构特征求解以及对偶变量  $D_1$  求解,再进行由  $\ell_1$  正则项表征稀疏特征求解以及对偶变量  $D_2$  求解。两个特征解的更新表达式均为解析形式,可保证算法的稳健性和运算效率。最后,算法汇总调和形成分裂变量组和对偶变量组以进行目标变量  $X$  的更新。通过判断残差是否满足迭代停止准则,若不满足,则继续循环,若满足,则跳出循环,并输出经过复杂结构特征和稀疏特征协同增强后的图像数据结果  $X$ 。

### 3 实验分析

为了验证所提 CEA 算法用于具有复杂结构特征的 SAR 目标恢复性能,本文利用仿真 SAR 复数数据、Sandia 实测数据和 Yak 实测数据对本文所提算法以及基于  $\ell_1$  范数正则化模型的 Lasso 算法<sup>[16]</sup>、基于 TV 范数正则化模型的 TV-ADMM 算法<sup>[12]</sup>和基于 DT-GV 范数正则化模型的 DTGV-ADMM 算法<sup>[17]</sup>进行了数据恢复成像对比实验,并利用相变分析法进行定量对比试验,从多个角度定性定量分析本文所提

表 1 CEA 算法流程

|   |
|---|
| <b>步骤 1</b> 对 SAR 回波数据进行预处理,距离徙动校正及相位误差补偿。  |
| <b>步骤 2</b> 设定初值 $X^0 = Z^0 = D^0 = 0, G=2, k=0$ , 设定迭代停止准则, 开始循环。  |
| <b>步骤 3</b> 进行对 $Z_1, D_1, Z_2$ 和 $D_2$ 的顺次更新运算:  |
| for $g=G$   |
| $Z_1^{k+1} = (E^{k+1})^H A^H Y, D_1^{k+1} = D_1^k - X^{k+1} + Z_1^{k+1}$ , 式(12)-(13)                         |
| $Z_2^{k+1} = \text{pron}_{\lambda_2, \rho} [W^{k+1}], D_2^{k+1} = D_2^k - X^{k+1} + Z_2^{k+1}$ , 式(15)-(16)   |
| end   |
| $Z^{k+1} = [Z_1^{k+1} Z_2^{k+1}], D^{k+1} = [D_1^{k+1} D_2^{k+1}]$  |
| <b>步骤 4</b> 根据式(12)进行对 $X$ 的更新运算  |
| $X^{k+1} = [A^H E^H Y + \rho_1 (Z_1^k - D_1^k) + \rho_2 (Z_2^k - D_2^k)] \cdot (A^H A + \rho G I)^{-1}$ 式(18) |
| <b>步骤 5</b> 若满足停止准则, 则跳至 <b>步骤 6</b> , 结束迭代。否则裂变量 $k = k + 1$ , 并跳至 <b>步骤 2</b> 。                             |
| <b>步骤 6</b> 输出联合多特征增强图像数据 $X$ 。   |

CEA 算法在增强目标复杂结构特征和稀疏特征的有效性和优越性。

#### 3.1 仿真 SAR 复数数据成像对比实验

为了验证本文所提 CEA 算法面向 SAR 数据在轮廓等多特征联合增强方便的有效性以及相对传统稀疏重建算法在复杂结构特征增强上的优越性, 首先进行 SAR 仿真数据实验, 实验数据大小  $300 \times$




图 1 仿真实验对比图 (a) 参考图, (b) 散焦噪声图, (c) Lasso 结果图, (d) TV-ADMM 结果图, (e) DTGV-ADMM 结果图, (f) CEA 结果图

Fig. 1 Comparison diagrams of simulation experiments (a) Reference, (b) defocusing noise, (c) Lasso, (d) TV-ADMM, (e) DTGV-ADMM, (f) CEA

300,模拟了SAR目标的复杂结构进行随机复数赋值。实验进行了Lasso、TV-ADMM、DTGV-ADMM和本文所提算法处理结果对比,并计算了恢复图像结果与参考图像之间的相关度(COR)来定量对比算法性能,其中相关度 $R_{XY^k} = \text{Cov}(X, X^k) / \sigma_X \sigma_{X^k}$ ,式中 $X^k$ 表示迭代得到的恢复图像结果, $X$ 表示参考图像; $\text{Cov}$ 和 $\sigma$ 分别表示协方差和标准差运算符。图1(a)为仿真图像参考图,用以对比,成像目标的结构多样化,且具有层次性。图1(b)为模拟的回波数据成像结果,把参考数据变换到距离压缩域,在方位向上设定了大小为10弧度的乘性相位误差,且添加了信噪比为0dB的加性高斯白噪声。在利用最小熵自聚焦算法进行相位误差补偿后,图1(c)、(d)和(e)分别为Lasso、TV-ADMM、DTGV-ADMM处理结果,明显看出,在噪声并没有得到很好压制的情况下,目标的结构已经开始丢失,虽然DTGV相对比Lasso和TV能更好地保留目标结构,但是因为低阶梯度的约束,导致成像结果结构方向化明显,三者与原图的相关度分别为0.8364、0.8280和0.8556。图1(f)为本文所提CEA算法的恢复结果,可见目标的复杂结构得以良好地恢复,与此同时,背景噪声也得到了有效地压制,计算所得COR为0.9010。由以上对比分析得出,本文所提算法在面向具有复杂结构特征的目标有着优越的恢复性能,能较好地增

强目标的复杂结构特征和稀疏特征。

### 3.2 SAR实测数据恢复成像对比实验

本组实验选用美国Sandia实验室公布的SAR实测复数据图像来验证本文所提CEA算法在增强成像目标复杂结构特征和稀疏特征的性能。数据由Ka波段雷达获取,成像分辨率达0.1m,数据大小为400\*701。对比算法包括Lasso、TV-ADMM和DTGV-ADMM算法,其对应的恢复结果如图2所示,其中图2(a)为直接应用距离多普勒(Range Doppler, RD)成像结果,可以看出受背景噪声影响,图像对比度差,虚线目标结构较模糊。图2(b)是应用Lasso算法所得到的稀疏特征增强实验结果,可以看出,背景噪声得到抑制,地面虚线场景的成像对比度高,目标易于辨别,但是在压制噪声的同时,牺牲了目标弱散射点的信息,破坏了目标结构的完整性。图2(c)和(d)分别为TV-ADMM和DTGV-ADMM算法恢复结果所成图像,可见因为有TV正则项和DTGV正则项的约束,目标的结构相比较Lasso算法得以较好地保留,相对比更为复杂的结构,TV和DTGV都较适合最为正则项约束结构方向性强的目标恢复。图2(e)是使用本文所提CEA算法处理得到的结果,明显地,背景噪声得到了很好的抑制,且目标结构完整保留,轮廓清晰,验证了本文所提算法在稀疏特征和结构特征协同增强上的有效性和




图2 SAR实测实验对比图 (a) RD结果图, (b) Lasso结果图, (c) TV-ADMM结果图, (d) DTGV-ADMM结果图, (e) CEA结果图

Fig. 2 Comparison diagrams of SAR measurements (a) RD, (b) Lasso, (c) TV-ADMM, (d) DTGV-ADMM, (e) CEA



优越性。

### 3.3 ISAR 实测数据恢复成像对比实验

本组实验选用 Yak-42 逆合成孔径雷达 (Inverse Synthetic Aperture Radar, ISAR) 数据为例来验证本文所提 CEA 算法在增强成像目标复杂结构特征和稀疏特征的性能。仿真了各种信噪比 (SNR)，并采用 Lasso-ADMM、DTGV-ADMM 和 CEA 算法进行比较。实验结果如图 3 所示。其中，图 3(a) 为直接应用距离多普勒 (Range Doppler, RD) 成像结果，用以对比。图 3(b1)、(b2) 和 (b3) 分别为模拟信噪比分别为 -2 dB、0 dB 和 2 dB 的成像结果。图 3(c1)、(c2) 和 (c3) 分别为应用 Lasso 算法所得到的稀疏特征增强实验结果，显然，在未能完全压制噪声的情况下，飞机结构已经开始丢失，破坏了机身完

整性。图 3(d1)、(d2) 和 (d3) 分别为应用 DTGV-ADMM 算法得到的恢复结果，恢复所得的飞机结构方向化明显。图 3(e1)、(e2) 和 (e3) 为应用本文所提 CEA 算法处理成像结果，对比表明，所提出 CEA 算法能够恢复最完整的飞机结构特征，并对背景噪声进行最低水平的抑制。

### 3.4 相变分析实验

为定性、定量评估本文所提 CEA 算法在恢复 SAR 成像数据时对目标复杂结构特征和稀疏特征的增强性能，本组实验采用相变分析法进行 DTGV-ADMM 算法和 CEA 算法的对比实验 (TV-ADMM 等算法明显劣势，相变分析不再比较)。相变分析法的原理是不同参数设定下通过进行多次独立同分布的蒙特卡洛实验来比较不同算法的恢复性能，通

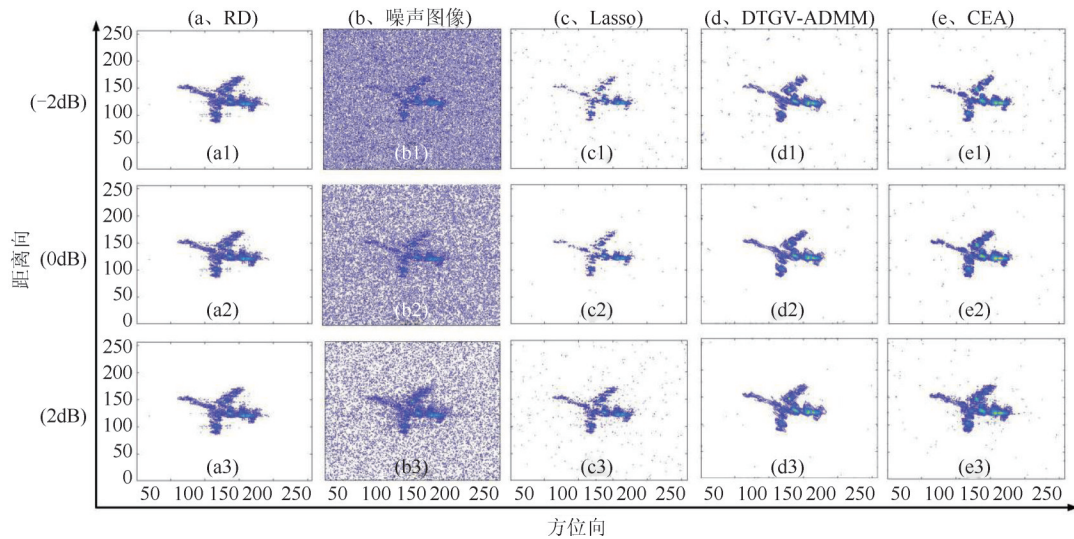


图 3 ISAR 实测实验对比图 (a) RD 结果图, (b) 散焦噪声图, (c) Lasso 结果图, (d) DTGV-ADMM 结果图, (e) CEA 结果图  
Fig. 3 Comparison diagrams of ISAR measurements (a) RD, (b) Defocusing noise, (c) Lasso, (d) DTGV-ADMM, (e) CEA




图 4 相变分析实验 (a) 降采样率 (USL)-信噪比, (b) 稀疏度 (SP)-降采样率

Fig. 4 Experiments of phase transition analysis (a) under sampling (USL)-Signal to Noise Ratio (SNR), (b) sparsity (sp)-under sampling (USL)

过计算恢复图像结果与原参考图像的相关度来定量反映算法的性能优劣。实验所用仿真数据采用图1所示数据,首先固定稀疏度(SP),分别在降采样率(USL)为0.5和1时,以信噪比为自变量进行目标恢复,实验结果如图4(A)所示,可以看出,随着信噪比的增大,两种算法恢复出的目标结果与参考图像结果相关度越来越大,CEA算法在降采样率为0.5或1的情况下,性能都优于DTGV-ADMM算法。在固定信噪比为0dB,进行稀疏度与降采样率的相变实验,恢复结果如图4(B)所示。综上实验,可以验证CEA算法在恢复具有复杂结构特征目标的性能较优越。

#### 4 总结

针对单一的正则约束已经不能满足高分辨率SAR复杂结构特征增强成像应用的需求问题,提出面向SAR回波数据的复杂结构特征增强算法(CEA),算法首先对SAR目标进行误差补偿,再基于ADMM多正则协同优化框架,用高阶方向全变分正则项表征目标复杂结构特征,用 $\ell_1$ 正则项表征目标稀疏特征,并利用近端算法求解两个特征的解析表达式,保证了算法的稳健性和收敛效率。两个特征的增强过程灵活可调和。实验上,本文利用多组仿真、实测SAR图像数据在不同算法下进行对比实验,定性又定量的验证了所提CEA算法面向提升目标复杂结构特征协同稀疏特征的有效性和优越性。

#### References

- [1] HUANG Bo, ZHOU Jie, JIANG Ge. Joint feature enhancement for high resolution SAR imaging based on total variation regularization[J]. *J. Infrared Millim. Waves* (黄博,周劫,江舸.基于全变分的高分辨SAR联合特征增强成像算法. *红外与毫米波学报*), 2021, **40**(5):664-672.
- [2] ZHANG Ye, YANG Xiao, JIANG Xin-Rui, et al. Attitude direction estimation of space target parabolic antenna loads using sequential terahertz ISAR images[J]. *J. Infrared Millim. Waves* (张野,杨潇,江新瑞,等.基于太赫兹ISAR图像序列的空间目标抛物面天线载荷指向估计. *红外与毫米波学报*), 2021, **40**(4):496-507.
- [3] JIANG Ge, LIU Jie, JING Wen, et al. A range-doppler algorithm for holographic radar imaging [J]. *J. Infrared Millim. Waves* (江舸,刘杰,经文,等.基于距离多普勒概念的全息雷达成像算法. *红外与毫米波学报*), 2017, **36**(03):367-375.
- [4] Yao X-W, Han J-W, Cheng G, et al. Semantic annotation of satellite images via joint multi-feature learning with diversity constraint[C]. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing, 2016: 5441-5444.
- [5] Yang L, Li P-C, Zhang S, et al. Cooperative multitask learning for sparsity-driven sar imagery and nonsystematic error autocalibration [J]. *IEEE Transactions on Geoscience & Remote Sensing*. 2020, **58**(7):5132-5147.
- [6] Miao Y-X, Wu J-Y, Gao H-Y. Comparison between resolution features of BPA and PFA through wavenumber domain analysis for general spotlight SAR[C]. 2019 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Yokohama, Japan, 2019:2969-2972.
- [7] Wang J, Wen Y-Y, Wang W-D, et al. Research of side-lobe suppression of RDA and CSA imaging algorithms [C]. 2015 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Ningbo, 2015: pp. 1-5.
- [8] Linnehan R, Miller J, Ayman A. Map-drift autofocus and scene stabilization for video-SAR [C]. 2018 IEEE Radar Conference. Oklahoma City, 2018:1401-1405.
- [9] MAO Xin-Hua, HE Xue-Li, LI Dan-Qi. Knowledge-aided 2-d autofocus for spotlight sar range migration algorithm imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, **56**(9):5458-5470.
- [10] Thomas K J, Kharbouch A A. Monotonic iterative algorithms for SAR image restoration [C]. 2006 IEEE International Conference on Image Processing. Atlanta, GA, 2006:645-648.
- [11] Boyd S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers [J]. *Foundations and Trends in Machine Learning*. 2011, **3**(1):1-122.
- [12] Güven H E, Güngör A, Çetin M. An augmented Lagrangian method for complex-valued compressed SAR imaging [J]. *IEEE Transactions on Computational Imaging*. 2016, **2**(3):235-250.
- [13] Parisotto S, Lellmann J, Masnou S, et al. Higher-order total directional variation. Part I: Imaging applications [J]. 2018, DOI:10.48550/arXiv.1812.05023.
- [14] Yang L, Zhao L F, Bi G A, et al. SAR ground moving target imaging algorithm based on parametric and dynamic sparse bayesian learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*. 2016, **54**(2):2254-2267.
- [15] Wang L, Zhao L, Bi G, et al. Enhanced ISAR imaging by exploiting the continuity of the target scene [J]. *IEEE Transactions on Geoscience and Remote Sensing*. 2014, **52**(9):5736-5750.
- [16] Bi H, Zhang B, Zhu X X, et al. L1-Regularization-based SAR imaging and CFAR detection via complex approximated message passing [J]. *IEEE Transactions on Geoscience and Remote Sensing*. 2017, **55**(6):3426-3440.
- [17] Kongskov R D, Dong Y, Knudsen K. *Directional total generalized variation regularization* [M]. Springer, Cham, 2017.