

## 组合字典下超宽带穿墙雷达自适应稀疏成像方法

晋良念<sup>\*①②</sup> 申文婷<sup>②</sup> 钱玉彬<sup>②</sup> 欧阳缮<sup>②</sup>

<sup>①</sup>(广西无线宽带通信与信号处理重点实验室 桂林 541004)

<sup>②</sup>(桂林电子科技大学信息与通信学院 桂林 541004)

**摘要:**针对现有超宽带穿墙雷达稀疏成像算法大多只采用点目标稀疏基表示模型和稀疏优化的正则化参数不能被自适应调整以及目标位置不在划分网格上带来虚假像的问题,该文提出一种基于贝叶斯证据框架的自适应稀疏成像方法。该方法首先利用组合字典独立稀疏表示场景中的点目标和扩展目标,然后在建立的偏离网格稀疏表示模型的基础上分层最大化各参数的似然函数,用第1层推理结合共轭梯度算法估计组合字典的各稀疏表示系数,用第2层推理估计正则化参数和目标的偏离网格量,最终通过迭代优化参数的设置得到问题的求解。仿真和实验结果表明,该方法不仅同时自适应增强穿墙场景中的点目标和扩展目标,还消除了偏离网格目标引起的虚假像。

**关键词:**超宽带穿墙雷达稀疏成像;组合字典;证据框架;参数自适应调整

中图分类号: TN957.52

文献标识码: A

文章编号: 1009-5896(2016)05-1047-08

DOI: 10.11999/JEIT150884

## Adaptive Sparse Imaging Approach for Ultra-wideband Through-the-wall Radar in Combined Dictionaries

JIN Liangnian<sup>①②</sup> SHEN Wenting<sup>②</sup> QIAN Yubin<sup>②</sup> OUYANG Shan<sup>②</sup>

<sup>①</sup>(Guangxi Key Laboratory of Wireless Wideband Communication & Signal Processing, Guilin 541004, China)

<sup>②</sup>(Institute of Information and Communication, Guilin University of Electronic Technology, Guilin 541004, China)

**Abstract:** The existing algorithms of ultra-wideband through-the-wall radar sparse imaging mostly adopt point target model. Also the regularization parameter of sparse optimization can not be adjusted adaptively, and the ghost imaging can be produced if the targets are not positioned at the pre-discretized grid location. To deal with the above issues, an adaptive sparse imaging algorithm based on Bayesian evidence framework is proposed, which represents sparsely the scene with the point targets and the extended targets by combination of appropriate dictionaries, and maximizes hierarchically the likelihood function of all parameters as well. The first-level inference of the Bayesian, combined with conjugate gradient algorithm, is adopted to estimate the sparse representation coefficients of the combined dictionaries. The second-level inference of the Bayesian is adopted to estimate the regularization parameter as well as the targets' off-grid shifts. Therefore, the problem can be solved through iterative optimizing the parameter setting. The simulation and experimental results show that the proposed method can not only adaptively enhance the characteristics of both the point targets and the extended targets, but also mitigate ghosts caused by off-grid targets.

**Key words:** Ultra-wideband through-the-wall radar sparse imaging; Combined dictionaries; Evidence framework; Adaptive adjustment of parameters

### 1 引言

穿墙雷达成像 (Through-the-wall Radar

Imaging, TWRI)是一种能够穿透建筑物对隐藏目标进行成像的新型技术,在执法、火灾救援、应急救援和军事行动等领域备受关注<sup>[1,2]</sup>。为了获得良好的探测性能,成像技术是关键。现有文献大多采用后向投影(Back Projection, BP)算法、延时求和(Delay-And-Sum, DAS)等算法<sup>[3,4]</sup>,尽管可以利用较少的先验信息就能够快速而简单地实现目标的成像,但是它们不仅需要进行大量的数据采样、存储和处理,而且这些成像算法自身就存在主瓣较宽且旁瓣较高的问题。

事实上,与整个成像区域相比, TWRI 场景中

收稿日期: 2015-07-23; 改回日期: 2016-02-18; 网络出版: 2016-03-30

\*通信作者: 晋良念 jinglingling5653@sina.com.cn

基金项目: 国家自然科学基金(61461012), 广西区自然科学基金(2013GXNSFAA019329, 2013GXNSFAA019004), 认知无线电与信息处理教育部重点实验室 2015 主任基金项目(CRKL150107)

Foundation Items: The National Natural Science Foundation of China (61461012), Guangxi Natural Science Foundation (2013GXNSFAA019329, 2013GXNSFAA019004), Cognitive Radio and the Ministry of Education Key Laboratory of Information Processing, 2015 the Fund Project of director (CRKL150107)

感兴趣的目标仅占据相对较少的空间位置(即具有空间稀疏性),所以 TWRI 实质上也是一个稀疏信号重建问题。近年来,国内外学者已将压缩感知(Compressive Sensing, CS)理论应用于 TWRI 中,不仅减少了数据的采集时间、采集量和存储代价,还可以获得高分辨成像<sup>[5-7]</sup>。仿真和实验结果表明,当真实目标的位置位于网格点上,稀疏成像效果较好,而当真实目标位置偏离网格(off-grid),稀疏成像将出现严重的散焦现象,其目标的周围产生了较多的虚假像。文献[6]通过建立点目标偏离网格稀疏表示模型,提出了一种基于  $L_{21}$  范数惩罚项的快速迭代收缩门限算法(Fast Iterative Shrinkage Thresholding Algorithm, FISTA)来联合估计目标的后向散射系数和网格偏离量,较好地解决了偏离网格问题,但是算法的性能易受人工参数设置的影响,在实际应用中很难正确地被选择。文献[7]提出了一种基于修正贝叶斯压缩感知的自适应稀疏成像方法,在迭代过程中联合估计散射系数、正则化参数和偏离量,克服了 FISTA 算法性能受人工参数设置的影响,充分保证了 CS 基矩阵的匹配,性能优于文献[6]。但以上方法用于人体或平板介质等这样的扩展目标的稀疏成像时必将出现目标图像的边缘轮廓不清晰,同质区域不平滑的问题。文献[8]使用 2D 图像空间梯度构建一阶差分算子来刻画轮廓边缘信息,然后采用拉格朗日乘子法迭代求解散射系数和正则化参数,实现了扩展目标的自适应稀疏成像,结果能够较好地保持扩展目标的轮廓边缘。但同样会因为偏离网格的问题使得轮廓边缘会出现不连续的情况,这样不利于后续的目标检测与识别。

综上所述,针对点目标和扩展目标共存的复杂穿墙场景而言,既要做到点目标的高分辨成像,又要保持扩展目标的轮廓边缘信息,所以必须解决点目标和扩展目标的稀疏表示问题以及网格偏离带来的影响。本文一方面由表征不同目标类型稀疏性的原子形成完备字典分别稀疏表示点目标和扩展目标<sup>[9]</sup>。另一方面使用一阶泰勒级数展开建立解决偏离网格问题的信号模型。我们发现,基于上述两种情况所建立的穿墙稀疏表示模型与证据框架的模型等效<sup>[10]</sup>,因此本文从贝叶斯证据框架入手,分层贝叶斯推理迭代估计组合字典的稀疏表示参数、正则化参数和目标偏离网格量。与上述方法相比,本文方法引入组合字典可以有效地解决点目标和扩展目标同时增强的问题,同时引入证据框架的贝叶斯推理实现了参数的自适应选择。

## 2 稀疏表示模型

根据文献[7],采用  $K$  个收发共置天线单元合成

与墙体平行的线性阵列,构建离散成像空间回波模型:

$$\mathbf{r} = (\mathbf{A} + \mathbf{B}_x \mathbf{A}_x + \mathbf{B}_y \mathbf{A}_y) \boldsymbol{\sigma} + \mathbf{n}' \quad (1)$$

其中,  $\mathbf{r}$  和  $\mathbf{n}'$  分别代表  $K$  个天线的接收数据堆叠形成的信号矢量和噪声矢量,  $\boldsymbol{\sigma}$  代表成像空间大小为  $M$  的矢量,  $\mathbf{A}$  代表成像空间与  $K$  个天线之间的传播模型矩阵,  $\mathbf{B}_x$  和  $\mathbf{B}_y$  分别代表成像空间偏离网格目标与  $K$  个天线之间在  $x$  轴和  $y$  轴上的传播模型矩阵,  $\mathbf{A}_x$  和  $\mathbf{A}_y$  分别代表  $x$  轴和  $y$  轴上由偏离网格矢量  $\boldsymbol{\delta}_x$ ,  $\boldsymbol{\delta}_y$  构造的对角矩阵。构造  $\mathbf{A}$ ,  $\mathbf{B}_x$  和  $\mathbf{B}_y$  的关键之一是计算天线到预设网格点间的双程传播时延。以第  $m$  个网格为例<sup>[11]</sup>:

$$\tau_{k,m} = 2\sqrt{(x_k - x_m)^2 + (y_k - y_m)^2} / c + 2d \left( \sqrt{\varepsilon_w - \sin^2 \theta_{k,m}} - \cos \theta_{k,m} \right) / c \quad (2)$$

式中,  $d$  和  $\varepsilon_w$  分别代表墙体的厚度和相对介电常数,  $\tau_{k,m}$  为传播时延,  $x_m$  和  $y_m$  为网格的位置,  $x_k$  和  $y_k$  为第  $k$  个天线的位置,  $c$  为电磁波传播速度,  $\theta_{k,m} \approx \arctan(|x_k - x_m| / |y_k - y_m|)$ 。除此之外,矩阵  $\mathbf{B}_x$  和  $\mathbf{B}_y$  的每一元素还事关  $\frac{\partial \tau_{k,m}}{\partial x_m}$  和  $\frac{\partial \tau_{k,m}}{\partial y_m}$  的计算,分两种情况考虑:

(1) 当  $x_k = x_m$  时,  $\theta_{k,m} = 0$ , 则

$$\frac{\partial \tau_{k,m}}{\partial x_m} = 0, \quad \frac{\partial \tau_{k,m}}{\partial y_m} = \frac{-2(y_k - y_m)}{c|y_k - y_m|} \quad (3)$$

(2) 当  $x_k \neq x_m$  时,  $\theta_{k,m} \neq 0$ , 则

$$\begin{aligned} \frac{\partial \tau_{k,m}}{\partial x_m} &= \frac{-2(x_k - x_m)}{c\sqrt{(x_k - x_m)^2 + (y_k - y_m)^2}} + 2 \frac{d}{c} \left( \frac{-\sin \theta_{k,m} \cos \theta_{k,m}}{\sqrt{\varepsilon_w - \sin^2 \theta_{k,m}}} + \sin \theta_{k,m} \right) \\ &\quad \cdot \left( \frac{|y_k - y_m|}{(x_k - x_m)^2 + (y_k - y_m)^2} \times \frac{x_k - x_m}{|x_k - x_m|} \right) \quad (4a) \\ \frac{\partial \tau_{k,m}}{\partial y_m} &= \frac{-2(y_k - y_m)}{c\sqrt{(x_k - x_m)^2 + (y_k - y_m)^2}} + 2 \frac{d}{c} \left( \frac{-\sin \theta_{k,m} \cos \theta_{k,m}}{\sqrt{\varepsilon_w - \sin^2 \theta_{k,m}}} + \sin \theta_{k,m} \right) \\ &\quad \cdot \left( \frac{|x_k - x_m|}{(x_k - x_m)^2 + (y_k - y_m)^2} \times \frac{y_k - y_m}{|y_k - y_m|} \right) \quad (4b) \end{aligned}$$

将式(1)的  $\boldsymbol{\sigma}$  在表征不同目标类型的组合字典上进行稀疏分解<sup>[9]</sup>。令  $I$  为组合字典的个数,  $\boldsymbol{\Psi}_i$  为第  $i$  个字典矩阵,  $\boldsymbol{\alpha}_i$  为第  $i$  个字典的稀疏表示系数矢量。假设  $\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_I$  相互独立,且满足 Laplace

分布, 则

$$p(\boldsymbol{\alpha}|\boldsymbol{\lambda}) = \prod_{i=1}^I p(\boldsymbol{\alpha}_i|\lambda_i) = \left[ \prod_{i=1}^I z_1(\lambda_i) \right] \exp\left[-\sum_{i=1}^I \frac{\lambda_i}{2} \|\boldsymbol{\alpha}_i\|_{p_i}^{p_i}\right] \quad (5)$$

式中,  $\boldsymbol{\lambda} = \{\lambda_1, \lambda_2, \dots, \lambda_I\}$ ,  $\lambda_i$  为控制参数,  $\boldsymbol{\alpha} = \{\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_I\}$ ,  $z_1(\lambda_i) = (\lambda_i/4)^M$ ,  $\|\cdot\|_{p_i}^{p_i}$  表示  $p_i$  范数,  $p_i \leq 1$ 。根据 CS 理论, 稀疏采样方法之一是随机选择天线单元和随机被选择天线单元的接收数据<sup>[12]</sup>, 则由此建立的综合考虑偏离网格和多类目标特性表征的稀疏成像模型可以表示为

$$\mathbf{y} = \sum_{i=1}^I \Phi(\mathbf{A} + \mathbf{B}_x \boldsymbol{\Lambda}_x + \mathbf{B}_y \boldsymbol{\Lambda}_y) \Psi_i \boldsymbol{\alpha}_i + \mathbf{n} \quad (6)$$

式中,  $\Phi \in R^{N \times KL}$  为测量矩阵,  $\mathbf{n} = \Phi \mathbf{n}'$ ,  $\mathbf{y} = \Phi \mathbf{r}$ 。

### 3 证据框架下的自适应稀疏成像方法

令  $\mathbf{A}' = \mathbf{A} + \mathbf{B}_x \boldsymbol{\Lambda}_x + \mathbf{B}_y \boldsymbol{\Lambda}_y$ ,  $\mathbf{n}$  服从零均值, 方差为  $\beta^{-1}$  的高斯噪声矢量, 则式(6)  $\mathbf{y}$  的似然函数为

$$p(\mathbf{y}|\boldsymbol{\alpha}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) = \frac{1}{z_2(\beta)} \exp\left[-\frac{\beta}{2} \left\| \mathbf{y} - \sum_{i=1}^I \Phi \mathbf{A}' \Psi_i \boldsymbol{\alpha}_i \right\|_2^2\right] \quad (7)$$

式中,  $z_2(\beta) = (2\pi/\beta)^{N/2}$ 。观察式(6),  $\mathbf{A}$ ,  $\mathbf{B}_x$ ,  $\mathbf{B}_y$  和  $\Psi_i$  已知,  $\boldsymbol{\alpha}$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  未知, 它们需要进行联合估计。可以看出, 这里的  $\boldsymbol{\lambda}$  控制着  $\boldsymbol{\alpha}$  的分布形式,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  决定了  $\boldsymbol{\alpha}$  的估计。依据贝叶斯证据框架的思想, 我们将  $\boldsymbol{\alpha}$  视为参数,  $\boldsymbol{\lambda}$ ,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  视为超参数, 第 1 层推理用于估计  $\boldsymbol{\alpha}$ , 第 2 层推理用于估计  $\boldsymbol{\lambda}$ ,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$ 。文献[10]的分析和仿真表明, 使用两层循环对参数和超参数进行自适应估计不仅可以收敛, 而且只需要少量的迭代次数就能收敛。

#### 3.1 参数 $\boldsymbol{\alpha}$ 的估计

在第 1 层推理中, 给定超参数  $\boldsymbol{\lambda}$ ,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$ , 通过最大化后验概率  $p(\boldsymbol{\alpha}|\mathbf{y}, \boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y)$  优化参数  $\boldsymbol{\alpha}$ 。根据贝叶斯准则有

$$p(\boldsymbol{\alpha}|\mathbf{y}, \boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) \propto p(\mathbf{y}|\boldsymbol{\alpha}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) p(\boldsymbol{\alpha}|\boldsymbol{\lambda}) \quad (8)$$

将式(5)和式(7)代入式(8), 两边取对数, 得到关于  $\boldsymbol{\alpha}$  的等价优化问题:

$$\left\{ \hat{\boldsymbol{\alpha}}_1^{(l)}, \hat{\boldsymbol{\alpha}}_2^{(l)}, \dots, \hat{\boldsymbol{\alpha}}_I^{(l)} \right\} = \arg \min_{\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_I} \beta \left\| \mathbf{y} - \sum_{i=1}^I \Phi \mathbf{A}' \Psi_i \boldsymbol{\alpha}_i \right\|_2^2 + \sum_{i=1}^I \lambda_i \|\boldsymbol{\alpha}_i\|_{p_i}^{p_i} \quad (9)$$

式中,  $l$  表示循环迭代次数的序号。当  $p_i \leq 1$  时,  $\|\boldsymbol{\alpha}_i\|_{p_i}^{p_i}$  在原点周围是不可微分的, 而且由于场景的稀疏性,  $\boldsymbol{\alpha}$  存在局部极值, 所以我们引入较小的正常数进行平滑处理。式(9)的最优化问题转换为

$$\min_{\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_I} f(\boldsymbol{\alpha}) = \beta \left\| \mathbf{y} - \sum_{i=1}^I \Phi \mathbf{A}' \Psi_i \boldsymbol{\alpha}_i \right\|_2^2 + \sum_{i=1}^I \lambda_i \left[ \sum_{k=1}^{N_i} (|(\boldsymbol{\alpha}_i)_k|^2 + \varepsilon)^{p_i/2} \right] \quad (10)$$

式中,  $\varepsilon$  为较小的正常数,  $N_i$  为  $\boldsymbol{\alpha}_i$  的元素个数,  $(\boldsymbol{\alpha}_i)_k$  为  $\boldsymbol{\alpha}_i$  的第  $k$  个元素,  $f(\boldsymbol{\alpha})$  为代价函数。一般情况下,  $f(\boldsymbol{\alpha})$  不能直接计算  $\boldsymbol{\alpha}$  的闭式解, 本文采用共轭梯度(CG)方法<sup>[13]</sup>。首先, 计算  $f(\boldsymbol{\alpha})$  关于  $\boldsymbol{\alpha}_i$  的梯度矢量  $\mathbf{g}_{\boldsymbol{\alpha}_i}$ ,

$$\mathbf{g}_{\boldsymbol{\alpha}_i} = \mathbf{G}(\boldsymbol{\alpha}_i) \boldsymbol{\alpha}_i - 2\beta (\Phi \mathbf{A}' \Psi_i)^T \left[ \mathbf{y} - \sum_{\substack{j=1 \\ j \neq i}}^I \Phi \mathbf{A}' \Psi_j \boldsymbol{\alpha}_j \right] \quad (11)$$

式中,  $\mathbf{G}(\boldsymbol{\alpha}_i) = 2\beta (\Phi \mathbf{A}' \Psi_i)^T (\Phi \mathbf{A}' \Psi_i) + \lambda_i p_i \boldsymbol{\Lambda}(\boldsymbol{\alpha}_i)$ ,  $\boldsymbol{\Lambda}(\boldsymbol{\alpha}_i) = \text{diag} \left\{ 1 / \left( |(\boldsymbol{\alpha}_i)_k|^2 + \varepsilon \right)^{1-p_i/2} \right\}$ 。定义矩阵  $\mathbf{G}(\boldsymbol{\alpha})$ , 其对角元素  $[\mathbf{G}(\boldsymbol{\alpha})]_{ii} = \mathbf{G}(\boldsymbol{\alpha}_i)$ , 非对角元素  $[\mathbf{G}(\boldsymbol{\alpha})]_{ij} = 2\beta (\Phi \mathbf{A}' \Psi_i)^T (\Phi \mathbf{A}' \Psi_j)$ ;  $\boldsymbol{\eta} = [2\beta (\Phi \mathbf{A}' \Psi_1)^T \mathbf{y}, \dots, 2\beta (\Phi \mathbf{A}' \Psi_I)^T \mathbf{y}]^T$ ,  $\tilde{\boldsymbol{\alpha}} = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_I]^T$ ,  $\mathbf{g} = [\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_I]^T$ , 则  $f(\boldsymbol{\alpha})$  关于  $\tilde{\boldsymbol{\alpha}}$  的梯度矢量  $\mathbf{g}$  可以表示为

$$\mathbf{g} = \mathbf{G}(\tilde{\boldsymbol{\alpha}}) \tilde{\boldsymbol{\alpha}} - \boldsymbol{\eta} \quad (12)$$

而  $f(\boldsymbol{\alpha})$  关于  $\boldsymbol{\alpha}$  的 Hesse 矩阵  $\mathbf{H}$  近似为

$$\mathbf{H} \approx \mathbf{G}(\tilde{\boldsymbol{\alpha}}) \quad (13)$$

令 CG 算法中的第  $k$  次迭代的梯度矢量为  $\mathbf{g}_k$ , Hesse 矩阵为  $\mathbf{H}_k$ , 则  $\tilde{\boldsymbol{\alpha}}_k$  的迭代表达式为

$$\tilde{\boldsymbol{\alpha}}_{k+1} = \tilde{\boldsymbol{\alpha}}_k + \eta_k \mathbf{d}_k \quad (14)$$

式中,  $\eta_k = \|\mathbf{g}_k\|_2^2 / \mathbf{d}_k^T \mathbf{H}_k \mathbf{d}_k$  表示  $\tilde{\boldsymbol{\alpha}}_k$  迭代的步长,  $\mathbf{d}_k = -\mathbf{g}_k + \beta_{k-1} \mathbf{d}_{k-1}$  表示共轭搜索的方向,  $\beta_{k-1} = \|\mathbf{g}_k\|_2^2 / \|\mathbf{g}_{k-1}\|_2^2$  表示搜索步长。式(14)的收敛条件是  $\|\eta_k \mathbf{d}_k\|_2 \leq \nu$  ( $\nu$  是一个非常小的正实数), 迭代收敛的结果为  $\tilde{\boldsymbol{\alpha}}^{(l)}$ 。

#### 3.2 超参数 $\boldsymbol{\lambda}$ , $\beta$ , $\boldsymbol{\delta}_x$ 和 $\boldsymbol{\delta}_y$ 的估计

在第 2 层推理中, 通过最大化后验概率  $p(\boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y | \mathbf{y})$  求解  $\boldsymbol{\lambda}$ ,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$ 。根据贝叶斯准则有

$$p(\boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y | \mathbf{y}) \propto p(\mathbf{y} | \boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) p(\boldsymbol{\lambda}) p(\beta) p(\boldsymbol{\delta}_x) p(\boldsymbol{\delta}_y) \quad (15)$$

式中,  $p(\boldsymbol{\lambda})$ ,  $p(\beta)$ ,  $p(\boldsymbol{\delta}_x)$  和  $p(\boldsymbol{\delta}_y)$  分别为  $\boldsymbol{\lambda}$ ,  $\beta$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  的先验概率。假设  $p(\boldsymbol{\lambda})$  的独立分量  $p(\lambda_i)$  满足 Jeffery 分布,  $p(\beta)$  满足一种很宽的平坦分布<sup>[10]</sup>,  $p(\boldsymbol{\delta}_x)$  和  $p(\boldsymbol{\delta}_y)$  满足边界区域范围内的均匀分布, 则求解式(15)的最大化问题就转换为最大化似然函数  $p(\mathbf{y} | \boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y)$ 。根据边缘概率密度函数性质可知

$$p(\mathbf{y}|\boldsymbol{\lambda}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) = \int p(\mathbf{y}|\boldsymbol{\alpha}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) p(\boldsymbol{\alpha}|\boldsymbol{\lambda}) d\boldsymbol{\alpha} \quad (16)$$

令  $\gamma_i = \lambda_i / \beta$ ,  $\boldsymbol{\gamma} = \{\gamma_1, \gamma_2, \dots, \gamma_I\}$ , 则  $\boldsymbol{\gamma} = \boldsymbol{\lambda} / \beta$ 。将式(5)和式(7)代入式(16), 被积分项变为

$$p(\mathbf{y}|\boldsymbol{\alpha}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) p(\boldsymbol{\alpha}|\boldsymbol{\lambda}) = \left[ \prod_{i=1}^I z_1(\gamma_i \beta) / z_2(\beta) \right] \exp\left\{-\frac{1}{2} L(\mathbf{y}, \boldsymbol{\alpha}|\boldsymbol{\gamma}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y)\right\} \quad (17)$$

$$\text{式中 } L(\mathbf{y}, \boldsymbol{\alpha}|\boldsymbol{\gamma}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) = \beta \left\| \mathbf{y} - \sum_{i=1}^I \boldsymbol{\Phi} \mathbf{A}' \boldsymbol{\Psi}_i \boldsymbol{\alpha}_i \right\|_2^2 + \sum_{i=1}^I \gamma_i Q(\boldsymbol{\alpha}_i), \quad Q(\boldsymbol{\alpha}_i) = \sum_{k=1}^N \left( |(\boldsymbol{\alpha}_i)_k|^2 + \varepsilon \right)^{p_i/2}。 \text{为了}$$

方便计算式(16), 将式(17)的  $L(\mathbf{y}, \boldsymbol{\alpha}|\boldsymbol{\gamma}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y)$  在  $\hat{\boldsymbol{\alpha}}^{(l)}$  点处进行泰勒级数展开, 将其代入, 两边取对数, 整理可得

$$\begin{aligned} \ln p(\mathbf{y}|\boldsymbol{\gamma}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) &= -\frac{1}{2} L(\mathbf{y}, \hat{\boldsymbol{\alpha}}^{(l)}|\boldsymbol{\gamma}, \beta, \boldsymbol{\delta}_x, \boldsymbol{\delta}_y) + \sum_{i=1}^I \ln Z_1(\gamma_i \beta) \\ &\quad - \ln Z_2(\beta) + \frac{M}{2} \ln 2\pi - \frac{1}{2} M \beta - \frac{1}{2} \ln |\mathbf{G}(\hat{\boldsymbol{\alpha}}^{(l)})| \quad (18) \end{aligned}$$

**3.2.1  $\boldsymbol{\gamma}$  和  $\beta$  的估计** 显然,  $p(\gamma_i)$  与  $p(\lambda_i)$  概率分布相同, 所以  $p(\gamma_i) \propto 1/\gamma_i$ 。将式(15)两边取对数, 代入  $\lambda_i = \gamma_i \beta$ ,  $p(\gamma_i)$  和式(18), 对  $\gamma_i$  求导, 令其为 0, 可得

$$\gamma_i^{(l+1)} = 2 \left( M - \sum_{k=1}^M \frac{\gamma_i^{(l)}}{\gamma_i^{(l)} + \rho_{i,k} / p_i} \right) / \left[ \beta Q(\hat{\boldsymbol{\alpha}}_i^{(l)}) \right], \quad i = 1, 2, \dots, I \quad (19)$$

式中  $\rho_{i,k}$  为矩阵  $\mathbf{B}_i = \boldsymbol{\Lambda}^{-1/2} (\hat{\boldsymbol{\alpha}}_i^{(l)}) [(\boldsymbol{\Phi} \mathbf{A}' \boldsymbol{\Psi}_i)^T (\boldsymbol{\Phi} \mathbf{A}' \boldsymbol{\Psi}_i)] \boldsymbol{\Lambda}^{-1/2} (\hat{\boldsymbol{\alpha}}_i^{(l)})$  的特征值。同理可得,

$$\begin{aligned} \beta^{(l+1)} &= 2M \left\{ \left\| \mathbf{y} - \sum_{i=1}^I \boldsymbol{\Phi} \mathbf{A}' \boldsymbol{\Psi}_i \hat{\boldsymbol{\alpha}}_i^{(l)} \right\|_2^2 \right. \\ &\quad \left. + \sum_{i=1}^I \gamma_i^{(l)} \left( Q(\hat{\boldsymbol{\alpha}}_i^{(l)}) - \frac{M}{2} \right) + M \right\} \quad (20) \end{aligned}$$

**3.2.2  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  的估计** 与  $\boldsymbol{\lambda}$  和  $\beta$  类似, 根据式(18)和式(15), 求解  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  的优化问题等价于

$$\{\boldsymbol{\delta}_x, \boldsymbol{\delta}_y\} = \arg \min_{\boldsymbol{\delta}_x, \boldsymbol{\delta}_y} \left\| \mathbf{y} - \sum_{i=1}^I \boldsymbol{\Phi} \mathbf{A}' \boldsymbol{\Psi}_i \hat{\boldsymbol{\alpha}}_i^{(l)} \right\|_2^2 \quad (21)$$

将  $\mathbf{A}' = \mathbf{A} + \mathbf{B}_x \boldsymbol{\Lambda}_x + \mathbf{B}_y \boldsymbol{\Lambda}_y$ ,  $\boldsymbol{\sigma} = \sum_{i=1}^I \boldsymbol{\Psi}_i \hat{\boldsymbol{\alpha}}_i^{(l)}$  代入式(21), 将  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  的代价函数进行变形可得

$$\begin{aligned} &\left\| \mathbf{y} - \boldsymbol{\Phi} (\mathbf{A} + \mathbf{B}_x \boldsymbol{\Lambda}_x + \mathbf{B}_y \boldsymbol{\Lambda}_y) \boldsymbol{\sigma} \right\|_2^2 \\ &= \left\| (\mathbf{y} - \boldsymbol{\Phi} \mathbf{A} \boldsymbol{\sigma}) - \boldsymbol{\Phi} \mathbf{B}_x \text{diag}(\boldsymbol{\sigma}) \boldsymbol{\delta}_x \right. \\ &\quad \left. - \boldsymbol{\Phi} \mathbf{B}_y \text{diag}(\boldsymbol{\sigma}) \boldsymbol{\delta}_y \right\|_2^2 \quad (22) \end{aligned}$$

这样, 式(21)的优化问题变为

$$\begin{aligned} \{\boldsymbol{\delta}_x, \boldsymbol{\delta}_y\} &= \arg \min_{\boldsymbol{\delta}_x, \boldsymbol{\delta}_y} \left\{ \boldsymbol{\delta}_x^T \mathbf{P}_x \boldsymbol{\delta}_x + \boldsymbol{\delta}_y^T \mathbf{P}_y \boldsymbol{\delta}_y \right. \\ &\quad \left. + \boldsymbol{\delta}_x^T \mathbf{P}_{xy} \boldsymbol{\delta}_y + \boldsymbol{\delta}_y^T \mathbf{P}_{yx} \boldsymbol{\delta}_x - \mathbf{v}_x \boldsymbol{\delta}_x \right. \\ &\quad \left. - \mathbf{v}_y \boldsymbol{\delta}_y - \boldsymbol{\delta}_y^T \mathbf{v}_y^T - \boldsymbol{\delta}_x^T \mathbf{v}_x^T \right\} \quad (23) \end{aligned}$$

这里,  $\mathbf{P}_x = (\boldsymbol{\Phi} \mathbf{B}_x)^T (\boldsymbol{\Phi} \mathbf{B}_x) \odot \boldsymbol{\sigma} \boldsymbol{\sigma}^T$ ,  $\mathbf{P}_y = (\boldsymbol{\Phi} \mathbf{B}_y)^T (\boldsymbol{\Phi} \mathbf{B}_y) \odot \boldsymbol{\sigma} \boldsymbol{\sigma}^T$ ,  $\mathbf{P}_{xy} = (\boldsymbol{\Phi} \mathbf{B}_x)^T (\boldsymbol{\Phi} \mathbf{B}_y) \odot \boldsymbol{\sigma} \boldsymbol{\sigma}^T$ ,  $\mathbf{P}_{yx} = (\boldsymbol{\Phi} \mathbf{B}_y)^T (\boldsymbol{\Phi} \mathbf{B}_x) \odot \boldsymbol{\sigma} \boldsymbol{\sigma}^T$ ,  $\mathbf{v}_x = (\mathbf{y} - \boldsymbol{\Phi} \mathbf{A} \boldsymbol{\sigma})^T (\boldsymbol{\Phi} \mathbf{B}_x) \text{diag}(\boldsymbol{\sigma})$ ,  $\mathbf{v}_y = (\mathbf{y} - \boldsymbol{\Phi} \mathbf{A} \boldsymbol{\sigma})^T (\boldsymbol{\Phi} \mathbf{B}_y) \text{diag}(\boldsymbol{\sigma})$ 。分别对  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  求导, 令其为零, 可得

$$\boldsymbol{\delta}_x^{(l+1)} = (\mathbf{P}_x + \mathbf{P}_x^T)^{-1} (2\mathbf{v}_x - (\mathbf{P}_{xy} + \mathbf{P}_{yx}^T) \boldsymbol{\delta}_y^{(l)}) \quad (24)$$

$$\boldsymbol{\delta}_y^{(l+1)} = (\mathbf{P}_y + \mathbf{P}_y^T)^{-1} (2\mathbf{v}_y - (\mathbf{P}_{yx} + \mathbf{P}_{xy}^T) \boldsymbol{\delta}_x^{(l)}) \quad (25)$$

$$\mathbf{A}^{(l+1)} = \mathbf{A} + \mathbf{B}_x \text{diag}(\boldsymbol{\delta}_x^{(l+1)}) + \mathbf{B}_y \text{diag}(\boldsymbol{\delta}_y^{(l+1)}) \quad (26)$$

### 3.3 算法实现

因 Spike 字典是包含一个转移单元样本的, 而这些样本来自于感兴趣的场景中的一个固定网格中每一个可能位置, 它能够较好地稀疏表示点目标; 轮廓波(contourlet)字典是正交离散曲波的, 它没有大量的输出系数问题, 它可以有效地稀疏表示扩展目标的轮廓等细节部分, 所以选择 spike-contourlet 组合字典即可<sup>[10]</sup>。这样迭代过程中的参数包括  $\boldsymbol{\alpha}_1$ ,  $\boldsymbol{\alpha}_2$ ,  $\gamma_1$ ,  $\gamma_2$ ,  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$ 。算法流程如表 1 所示, 循环迭代式(14)的 CG 算法、式(18)到式(20), 式(24)到式(26), 直到满足收敛条件, 最后输出  $\boldsymbol{\delta}_x$ ,  $\boldsymbol{\delta}_y$  和  $\hat{\boldsymbol{\alpha}}$ , 并用  $\boldsymbol{\delta}_x$  和  $\boldsymbol{\delta}_y$  修正得到目标的真实位置。当然, 参数的初始值对迭代估计结果有一定的影响, 为了使参数更为接近收敛, 首先采用 BP 算法得到  $\boldsymbol{\sigma}$  的初始值  $\boldsymbol{\sigma}_0$ , 然后采用快速匹配追踪算法<sup>[14]</sup>将  $\boldsymbol{\sigma}_0$  在 Spike 字典  $\boldsymbol{\Psi}_1$  和 Contourlet 字典  $\boldsymbol{\Psi}_2$  上分解, 分解系数作为初始值  $\boldsymbol{\alpha}_1^{(0)}$ ,  $\boldsymbol{\alpha}_2^{(0)}$ 。

表 1 算法流程

初始化:	$l = 0, \boldsymbol{\sigma}_0, \boldsymbol{\alpha}_1^{(0)}, \boldsymbol{\alpha}_2^{(0)}, \gamma_1^{(0)}, \gamma_2^{(0)}, \beta^{(0)}, \boldsymbol{\delta}_x^{(0)}, \boldsymbol{\delta}_y^{(0)}, \varepsilon, \varepsilon_0, \mathbf{v}$
步骤 1	根据式(18)、式(19)和式(20)分别估计 $\gamma_1^{(l+1)}, \gamma_2^{(l+1)}$ 和 $\beta^{(l+1)}$ , 并计算 $\lambda_1^{(l+1)}, \lambda_2^{(l+1)}$
步骤 2	根据式(24)和式(25)估计偏移矩阵 $\boldsymbol{\delta}_x^{(l+1)}, \boldsymbol{\delta}_y^{(l+1)}$ , 根据式(26)修正 $\mathbf{A}^{(l+1)}$
步骤 3	根据式(14)的共轭梯度(CG)算法迭代估计 $\hat{\boldsymbol{\alpha}}^{(l+1)}$ , 直至 CG 算法收敛
步骤 4	令 $l = l + 1$ , 当 $\ \hat{\boldsymbol{\alpha}}^{(l+1)} - \hat{\boldsymbol{\alpha}}^{(l)}\ _2^2 / \ \hat{\boldsymbol{\alpha}}^{(l)}\ _2^2 < \varepsilon_0$ 算法终止, 否则返回步骤 1
输出参数:	作为对应位置的目标后向散射系数 $\boldsymbol{\sigma} = \sum_{i=1}^2 \boldsymbol{\Psi}_i \hat{\boldsymbol{\alpha}}_i$ , 并显示 2D 图像。

从算法流程可知，每一次外循环迭代过程中都包括计算  $\hat{\alpha}^{(l)}$  的 CG 内循环、计算  $\gamma_1^{(l)}$  和  $\gamma_2^{(l)}$  的矩阵  $B_1$  和  $B_2$  的特征值分解以及计算  $\delta_x^{(l)}$  和  $\delta_y^{(l)}$  的矩阵求逆。由此看来，相比传统的成像算法计算复杂度高。因此，我们必须寻求参数求解过程中所需的快速实现方法以降低运算量。(1)采用文献[15]的方法对特征值进行快速求解，解决直接求特征值比较费时且占用大量的存储空间的问题。(2)采用文献[7]的方法将每步迭代得到的  $\alpha_1$  和  $\alpha_2$  的元素分别按照降序进行排列，然后根据预设的门限值确定非零元素的个数  $Q$  和对应的位置集合  $Z$ ，这样就从  $M$  维向量  $\delta_x^{(l)}$  和  $\delta_y^{(l)}$  的计算降为与位置集合  $Z$  对应的  $Q$  维。

### 4 仿真与实验结果分析

#### 4.1 仿真结果分析

利用 XFDTD 电磁仿真软件产生仿真数据，13 个天线单元均匀分布在  $x$  轴方向  $-0.6 \sim 0.6$  m 上，其发射的信号为一阶高斯微分窄脉冲信号，中心时刻和有效宽度均为 1 ns。如图 1(a)所示的仿真模型中，墙体的相对介电常数为 6.2、电导率为 0.01 S/m；圆柱体目标的相对介电常数为 52、电导率为 1.2 S/m、中心位置为(0.1 m, 1.1 m)、半径为 0.2 m，3 个点目标(用 1, 2, 3 标识)的中心位置分别为  $(-0.4 \text{ m}, 0.6 \text{ m})$ ,  $(-0.3 \text{ m}, 0.7 \text{ m})$ ,  $(-0.2 \text{ m}, 0.8 \text{ m})$ 。图 1(b)为仿真数据的 B-Scan 图，包括天线耦合波、

墙体回波、目标回波和杂波。图 1(c)为采用平均去噪、滤波以及子空间投影方法<sup>[2]</sup>进行预处理后的 B-Scan 图。从这些图可以看出，经过预处理后，圆柱体前沿的回波时延约为 8 ns，当换算为距离值时恰好与图 1 中的位置对应。

假设随机选择其中的 10 个天线单元，每个接收天线随机选择 200 个数据采样点(一般要占据所有采样点的 10%~30%)。基于图 1(c)预处理后的 B-scan 数据，运用 BP 成像算法得到  $\sigma_0$ ，然后在组合字典上进行分解得到  $\alpha_1^{(0)}$ ,  $\alpha_2^{(0)}$ 。令其它的初始值  $\beta^{(0)}$  为 1000,  $\gamma_1^{(0)}$  和  $\gamma_2^{(0)}$  为  $5 \times 10^{-5}$ ,  $\delta_x^{(0)}$  和  $\delta_y^{(0)}$  为  $M$  维的零向量以及  $\epsilon$ ,  $\epsilon_0$  和  $\nu$  为  $10^{-5}$ ,  $p_1$  和  $p_2$  为 1, 迭代次数  $L$  为 15。参数  $\lambda_1, \lambda_2, \beta, \Delta_x, \Delta_y$  和代价函数值随迭代次数的变化情况如图 2 所示。图中，定义  $\Delta_x^{(l)} = \frac{\|\delta_x^{(l)} - \delta_x^{(l-1)}\|_2}{\|\delta_x^{(l-1)}\|_2}$ ,  $\Delta_y^{(l)} = \frac{\|\delta_y^{(l)} - \delta_y^{(l-1)}\|_2}{\|\delta_y^{(l-1)}\|_2}$ 。可以看出，初始值的设定对收敛的影响很小，各参数经过几次迭代后就趋于收敛，更有趣的是代价函数值的变化表现为单调下降。图 3 给出了 BP 成像结果和迭代过程的成像结果。可以看出，随着迭代次数的增加，虚像减少，聚焦图像越来越清晰，目标特征越来越明显，这与前面的理论分析一致。

采用文献[7]、文献[8]和本文方法进行成像比较，如图 4 所示。图中的虚线框代表真实目标的位置。文献[7]采用点目标稀疏模型进行优化成像使得点目

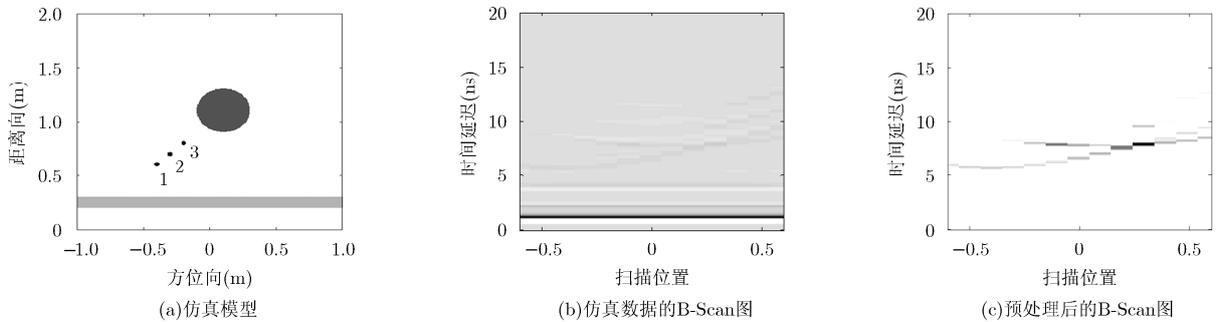


图1 仿真模型及 B-scan 图

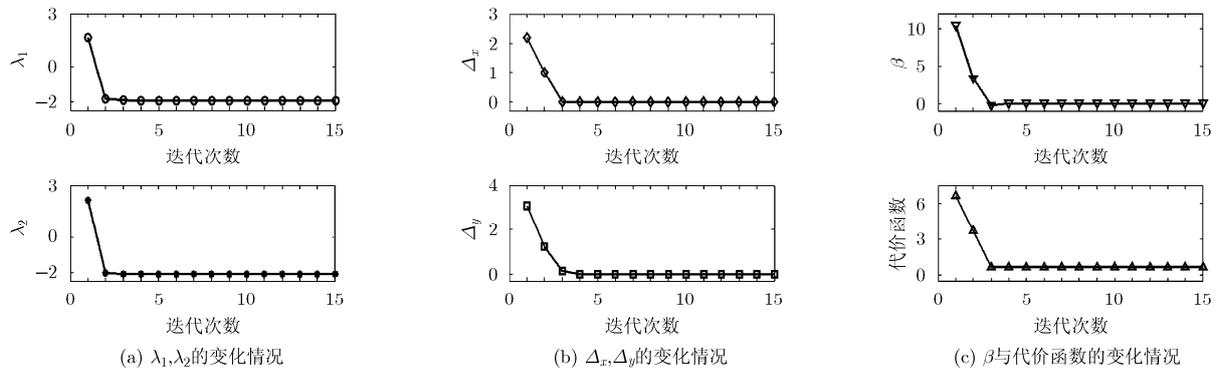


图2 迭代过程中参数的变化情况

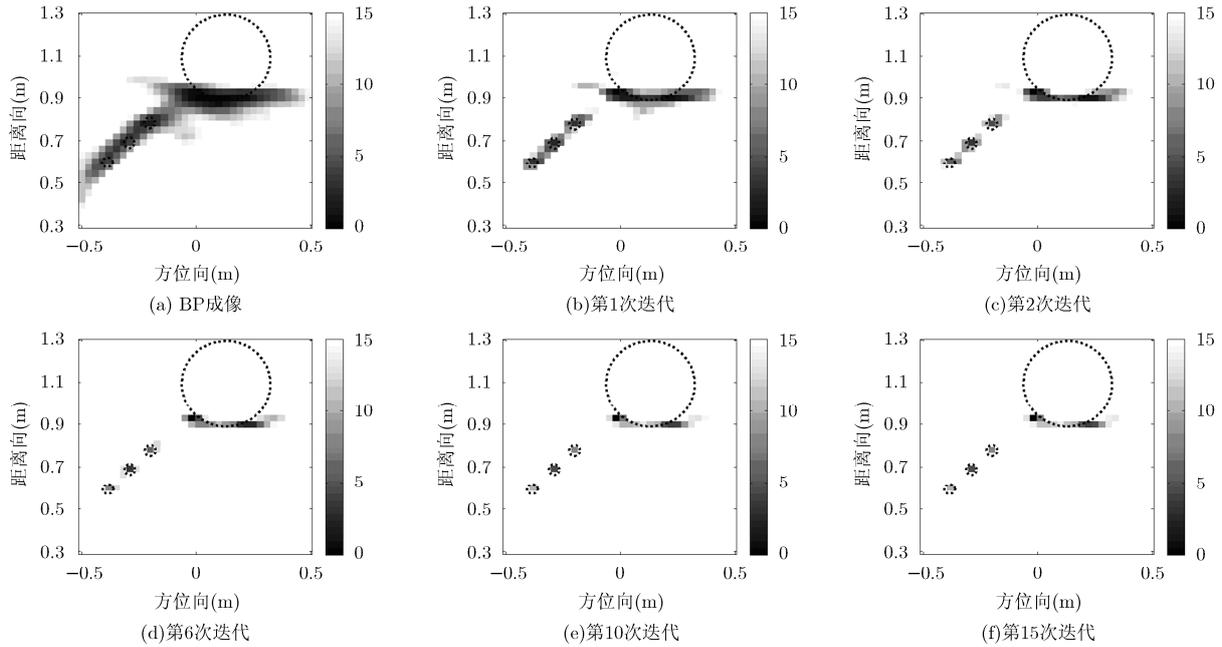


图3 迭代过程中成像结果的变化图

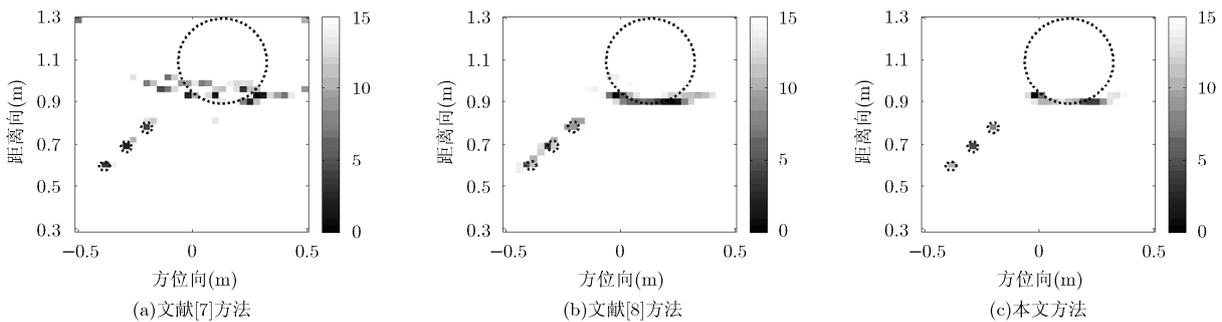


图4 仿真场景的成像结果比较

标成像变得清晰，虽然能大致判定扩展目标所处的位置，但是它的轮廓不连续，且存有较多的虚假像。文献[8]采用差分算子能够较好地凸显扩展目标的边缘轮廓，但无法增强点目标的特性，同时也无法消除偏离网格存在而产生的虚假像。本文算法不仅同时增强了点目标的散射特性和扩展目标的轮廓边缘特性，而且偏移网格的校正也很好解决了目标没落在划分网格上时产生的虚假目标问题，与前面的方法相比成像效果明显改善。

为直观比较各算法的成像性能，采用目标杂波比(Target-to-Clutter Ratio, TCR)、一阶差分均值法(Mean of First Order Difference, MFOD)、图像的熵(ENTopy of the full image, ENT)和程序运行时间(Program Running Time, PRT)分别评估其点目标散射特性、扩展目标的轮廓特性、整幅图的复杂程度<sup>[10]</sup>以及各算法在同一设备上运行需要的时间，如表2所示。TCR 定量评估点目标成像的聚焦

表2 TCR、MFOD、ENT与PRT比较

算法		文献[7]	文献[8]	本文方法
TCR(dB)	点目标 1	21.82	13.37	16.07
	点目标 2	21.63	14.80	19.75
	点目标 3	19.20	11.60	16.55
MFOD	圆柱体	0.08	0.04	0.05
ENT	全图	0.62	0.62	0.42
PRT(s)	程序	607.89	69.03	200.31

度，其值越大，聚焦度越高；MFOD 定量评估分布目标区域的平滑性，其值越小，检测区域像素值越接近，区域越平滑；ENT 整体评估全图的复杂度，其值越小整幅图的杂波越小；PRT 整体评估算法运行时间，其值越小，运行时间越短。从中可以看出，文献[7]的 TCR 值最高，点目标散射特性保存的最好，但是 MFOD 和 PRT 值很大，说明平滑性不够、

耗时长。文献[8]的 MFOD 和 PRT 值小，说明扩展目标的轮廓特性强且运行速度较快，但是 TCR 变小，ENT 变大，说明点特性无法保证，且杂波有所增加。本文方法的 TCR, MFOD 和 ENT 值都最佳，说明本文成像整体杂波少，偏移网格的位置得到了校正，点目标的散射特性和扩展目标的轮廓特性同时得到增强，但代价是 PRT 值有所增加，运算时间相对文献[8]成像有所增大。

### 4.2 实验结果分析

在实验场景中，墙体为实心砖墙，其厚度为 0.20 m，相对介电常数为 6.4；实验对象是人体目标，站在墙后 1.10 m 处。使用美国 GSSI 公司的探地雷达 SIR-20 搭建实验平台，选用 1 GHz 的喇叭天线，架高 1.4 m，贴着墙壁，从 -0.5 m 处到 0.5 m 水平移动，共扫描 21 点。图 5(a)给出了测量数据的 B-scan 图，图中天线耦合波、墙体回波和背景杂波淹没了人体的回波，使得人体的位置难以确定，因此成像之前必须对数据进行预处理。预处理后的 B-scan 图如图 5(b)所示，第 10 个测点位置接收到的人体散射回波数据如图 5(c)所示。

图 6 是实验场景数据的成像结果比较，图中的长方形虚线框代表胸腔的真实位置，圆形虚线代表

胳膊的真实位置。从图 6 可以看出，文献[7]点目标稀疏成像得到的是离散的点，没能凸显人体的外形轮廓，且周围还有虚假点目标像；文献[8]相对文献[7]能保证人体的轮廓信息，但是旁边存在较多的旁瓣且点目标的散射特性没法保证；本文方法是在 BP 成像的基础上进行参数自适应估计稀疏成像的，在迭代的过程中能自适应地估计出正则化参数、噪声和目标的偏移网格矢量的最优解，满足收敛条件后，所得图像不仅杂波减少，而且人体胸腔的轮廓特性和胳膊的散射特性同时得到了增强。

### 5 结束语

本文提出的组合字典下超宽带穿墙雷达自适应稀疏成像方法，解决了复杂穿墙场景中点目标和扩展目标同时增强以及这些目标偏移网格的问题。XFDTD 仿真数据和实验数据的处理结果表明：组合字典、偏离网格模型以及证据框架分层推理的运用能够在自适应增强多类目标特性的同时，也消除了偏离网格对目标成像的影响。在今后的工作中，继续探索此框架下的快速算法，并将其扩展到 3D 成像以及室内隐藏动目标成像检测中，致力于将该方法更完善地应用于更复杂真实的环境中。

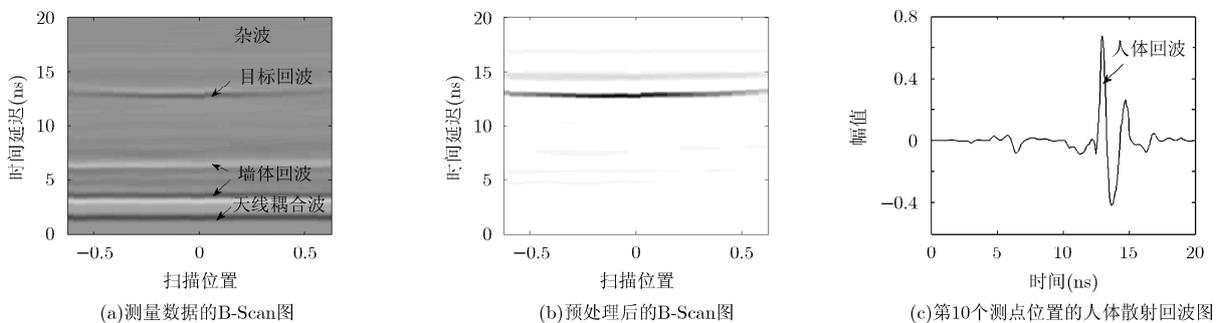


图 5 测量数据及预处理结果

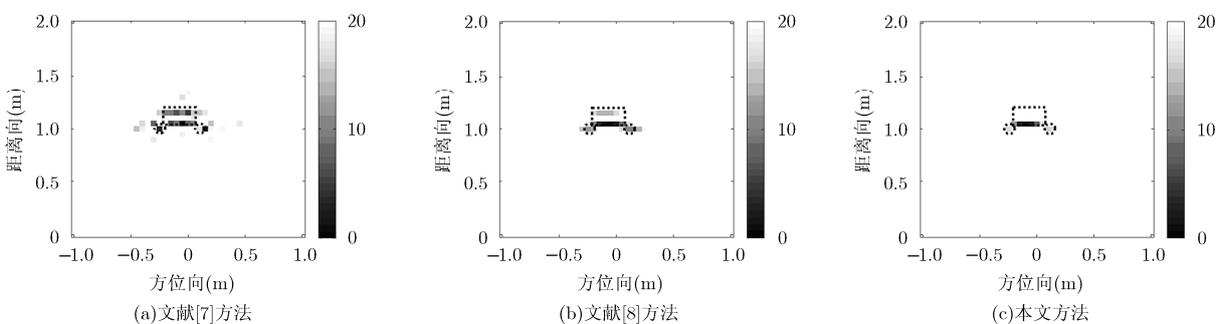


图 6 实验场景的成像结果比较

### 参考文献

[1] LI G and BURKHOLDER R J. Hybrid matching pursuit for

distributed through-wall radar imaging[J]. *IEEE Transactions on Antennas and Propagation*, 2015, 63(4):

- 1701-1711. doi: 10.1109/TAP.2015.2398115.
- [2] TIVIVE F H C, BOUZERDOUM A, and AMIN M G. A subspace projection approach for wall clutter mitigation in through-the-wall radar imaging[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(4): 2108-2122. doi: 10.1109/TGRS.2014.2355211.
- [3] JIA Yong, CUI Guolong, KONG Lingjiang, *et al.* Multichannel and multiview imaging approach to building layout determination of through-wall radar[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(5): 970-974. doi: 10.1109/LGRS.2013.2283778.
- [4] AMIN M G and AHMAD F. Change detection analysis of human moving behind walls[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2013, 49(3): 1410-1425.
- [5] WU Qisong, ZHANG Y D, AHMAD F, *et al.* Compressive sensing based high-resolution polarimetric through-the-wall radar imaging exploiting target characteristics[J]. *IEEE Antennas and Wireless Propagation Letters*, 2014, 99: 1-4. doi: 10.1109/LAWP.2014.238087.
- [6] XIA Shugao and LIU Fengshan. Off-grid compressive sensing through-the-wall radar imaging[J]. *Proceedings of SPIE*, 2014, 9077: 90771F-1-8.
- [7] 晋良念, 钱玉彬, 刘庆华, 等. 超宽带穿墙雷达偏离网格目标稀疏成像方法[J]. *仪器仪表学报*, 2015, 36(4): 743-748.  
JIN Liangnian, QIAN Yubin, LIU Qinghua, *et al.* Off-grid target sparse imaging method for ultra-wideband through-the-wall radar[J]. *Chinese Journal of Scientific Instrument*, 2015, 36(4): 743-748.
- [8] BROWNE K E, BURKHOLDER R J, and VOLAKIS J L. Fast optimization of through-wall radar images via the method of lagrange multipliers[J]. *IEEE Transactions on Antennas and Propagation*, 2013, 61(1): 320-328. doi: 10.1109/TAP.2012.2220321.
- [9] SAMADI S, ÇETIN M, and MASNADI-SHIRAZI M A. Multiple feature-enhanced SAR imaging using sparsity in combined dictionaries[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(4): 821-825. doi: 10.1109/LGRS.2012.2225016.
- [10] LIU Hongchao, JIU Bo, LIU Hongwei, *et al.* An adaptive ISAR imaging method based on evidence framework[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(6): 1031-1035. doi: 10.1109/LGRS.2013.2281194.
- [11] JIN T, CHEN B, and ZHOU Z. Imaging-domain estimation of wall parameters for autofocusing of through-the-wall SAR imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(3): 1836-1843. doi: 10.1109/TGRS.2012.2206395.
- [12] LAGUNAS E, AMIN M G, AHMAD F, *et al.* Joint wall mitigation and compressive sensing for indoor image reconstruction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(2): 891-906. doi: 10.1109/TGRS.2012.2203824.
- [13] PANT J and KRISHNAN S. Reconstruction of ECG signals for compressive sensing by promoting sparsity on the gradient[C]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Vancouver, 2013: 993-997.
- [14] 安芹力, 冯有前, 高大化, 等. 组合正交基字典稀疏分解快速匹配追踪算法[J]. *电子设计工程*, 2011, 19(2): 78-80.  
AN Qinli, FENG Youqian, GAO Dahua, *et al.* A quick MP algorithm of sparse decomposition by overcomplete dictionary combined orthogonal bases[J]. *Electronic Design Engineering*, 2011, 19(2): 78-80.
- [15] SHENG F and JIAO D. A deterministic-solution based fast eigenvalue solver with guaranteed convergence for finite-element based 3-D electromagnetic analysis[J]. *IEEE Transactions on Antennas and Propagation*, 2013, 61(7): 3701-3711 doi: 10.1109/TAP.2013.2258315.
- 晋良念: 男, 1974年生, 副教授, 博士, 研究方向为自适应信号处理、超宽带雷达隐藏目标成像与识别。
- 申文婷: 女, 1990年生, 硕士生, 研究方向为室内隐藏运动目标成像检测技术。
- 钱玉彬: 男, 1990年生, 硕士生, 研究方向为超宽带穿墙雷达稀疏成像方法。
- 欧阳缙: 男, 1960年生, 教授, 博士生导师, 研究方向为雷达信号处理、自适应信号处理以及通信处理等。