

# 衍射层析模型下穿墙雷达三维学习成像方法

卞梁<sup>1</sup>, 晋良念<sup>1,2</sup>, 刘庆华<sup>1</sup>

(1. 桂林电子科技大学信息与通信学院, 广西桂林 541004;

2. 广西无线宽带通信与信号处理重点实验室, 广西桂林 541004)

**摘要:** 针对现有穿墙雷达三维稀疏成像中, 存在网格时延构建字典矩阵所需内存过大以及凸优化稀疏成像算法阈值参数不确定影响重建图像质量的问题, 提出了一种基于衍射层析稀疏模型的学习近似消息传递三维成像方法。该方法在衍射层析成像算法上通过构造快速傅里叶变换算子来建立三维成像稀疏模型, 然后修正近似消息传递算法求解稀疏解, 并将其迭代过程映射成多层神经网络, 最后通过数据驱动自适应学习多层神经网络中的可调参数, 从而实现三维学习成像。仿真和实验数据处理结果表明, 该方法不仅减小了系统所需内存, 还避免了参数的人工调整对成像质量的影响。

**关键词:** 穿墙雷达; 三维衍射层析成像; 快速傅里叶变换算子; 学习近似消息传递算法

**中图分类号:** TN957.52   **文献标志码:** A   **文章编号:** 1672-2337(2021)06-0669-08

## Three-Dimensional Learning-Imaging Method of Through-the-Wall Radar with Diffraction Tomography Model

BIAN Liang<sup>1</sup>, JIN Liangnian<sup>1,2</sup>, LIU Qinghua<sup>1</sup>

(1. School of Information and Communication, Guilin University of Electronic Technology, Guilin 541004, China;

2. Key Laboratory of Guangxi Wireless Broadband Communication and Signal Processing, Guilin 541004, China)

**Abstract:** The existing three-dimensional sparse imaging of through-the-wall radar has too much memory required to construct the dictionary matrix with grid delay. Moreover, the uncertain threshold parameters of convex optimization sparse imaging algorithms affect the quality of reconstructed images. A three-dimensional imaging method of learning approximate message passing with diffraction tomography sparse model is proposed in this paper. A three-dimensional imaging sparse model is firstly built by constructing a fast Fourier transform operator for the diffraction tomography algorithm. Subsequently, we modify the approximate message passing algorithm to reconstruct its sparse solution, and map iterative process of sparse solution into a multilayer neural network. Finally, we use data-driven adaptive learning of the adjustable parameters in the multilayer neural network to achieve three-dimensional learning-imaging. Simulation and experimental data processing results show that this method not only reduces the memory required by the system, but also avoids the impact of manual adjustment of parameters on imaging quality.

**Key words:** through-the-wall radar; three-dimensional diffraction tomography; fast Fourier transform operator; learning approximate message passing algorithm

## 0 引言

超宽带穿墙雷达三维成像不仅能提供距离向和方位向上的目标位置信息, 还能提供俯仰等多维度的信息, 满足了建筑内部的结构特征、人体目标的姿势等信息的需求。其现有的三维成像有

后向投影算法<sup>[1]</sup>和衍射层析(Diffraction Tomographic, DT)算法<sup>[2-3]</sup>等。但是这些成像算法不仅需要进行大量的数据采样、存储和处理, 而且所成像还存在主瓣较宽、旁瓣较高的问题。

为此, 国内外学者已将压缩感知(Compressive Sensing, CS)理论应用于穿墙雷达成像(Through-the-Wall Radar Imaging, TWRI)中, 不仅减少了

收稿日期: 2020-12-18; 修回日期: 2021-01-28

基金项目: 国家自然科学基金(No. 61861011, 61461012); 广西自然科学基金(No. 2017GXNSFAA198050); 广西无线宽带通信与信号处理重点实验室2020年主任基金项目; 桂林电子科技大学研究生教育创新计划资助项目(No. 2020YCX023)

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。文献[4]首次将CS应用于穿墙场景中,利用稀疏随机矩阵的采样方法可在随机的采样天线中随机选择频点以减少数据采集量。在此基础上,文献[5]通过正交匹配追踪(OMP)算法对墙后目标成像,提高了成像质量和减少了旁瓣干扰。由于OMP重构算法易受到信号信噪比影响导致成像质量较差,文献[6]在贝叶斯算法的基础上通过噪声先验信息,同时考虑扩展目标像素间的结构信息,对目标进行高分辨成像。考虑到贝叶斯算法复杂度高,计算量大,文献[7]在低秩稀疏约束下提出了一种基于奇异值和 $l_1$ 范数的快速软阈值迭代(FISTA)的凸优化算法重构,该算法具有计算量小、收敛速度快的特点。但是,这种稀疏重构方法的字典矩阵是通过目标到成像网格的时延构建的,对于三维成像,字典矩阵所需内存太大,难以提供硬件需求;而且它往往需要预先确定阈值参数,而恰当地选择该参数对重建图像质量具有非常重要的影响。

目前,深度神经网络(Deep Neural Networks, DNNs)已经在图像去噪、图像复原等领域展现出优势。而模型驱动<sup>[8-9]</sup>作为DNNs中特殊的一类,将凸优化算法中的单次迭代过程映射为网络结构的每一层,进而利用少量的样本即可学习出最优参数。此外,因网络结构的显示表达,所以也保证了高质量的图像重建。鉴于此,本文基于这种模型驱动的思路,通过衍射层析成像算法构造快速傅里叶变换算子,避免了字典矩阵的构建,减少了所需内存;通过修正近似消息传递(Approximate

Message Passing, AMP)算法进行重构,并将其迭代过程映射成多层神经网络,最后通过数据驱动学习近似消息传递算法中可调参数,实现高分辨、高效率的三维图像的重建。

## 1 信号模型

如图1所示,使用收发天线共置的雷达系统平行于前墙的方向对墙后目标进行探测。系统发射步进频率信号,扫频范围从 $f_0$ 开始,步进频率为 $\Delta f$ ,频率点数为 $K$ ;采用 $M$ 行 $N$ 列二维收发共置天线阵列,天线空间坐标向量记为 $(x_R, y_R, z_R)$ 。空间区域被分成3个区域,区域0和区域2为自由空间,区域1为墙体,自由空间的介电常数和磁导率记为 $\epsilon_0$ 和 $\mu_0$ ,墙体介电常数和磁导率记为 $\epsilon_b$ 和 $\mu_b$ ,所述隐蔽目标位于区域2中;设 $x$ 方向为方位向, $y$ 方向为高度向, $z$ 方向为距离向,墙体的厚度为 $d$ 。

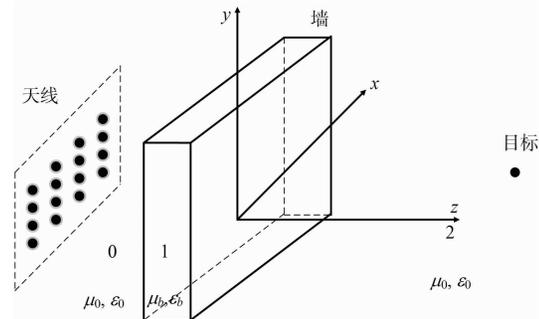


图1 穿墙雷达探测场景

根据文献[2]和[3],图1所示场景的衍射层析三维成像表达式为

$$\mathbf{O}(x, y, z) = \int dk \int dk_x \int dk_y \frac{j64z\bar{\mathbf{E}}(k_x, k_y, k) \exp(j\sqrt{4k^2 - k_x^2 - k_y^2}(z - z_R - d))}{k^2 \pi^2 \zeta_0 \left| \mathbf{F}\left(\frac{k_x}{2}, \frac{k_y}{2}, k\right) \right|^2 (4k^2 - k_x^2 - k_y^2)} \cdot \exp(j\sqrt{4k_1^2 - k_x^2 - k_y^2}d) \exp(jk_x x + jk_y y) \quad (1)$$

式中, $\mathbf{O}(x, y, z)$ 代表目标像函数, $k = 2\pi f/c$ 代表自由空间波数(这里的 $c$ 为光速), $k_x$ 代表方位向波数, $k_y$ 代表高度向波数, $k_z$ 代表距离向波数, $\zeta_0 = 120\pi$ 代表自由空间中的波阻抗, $\mathbf{F}(k_x, k_y, k)$ 代表并矢函数,即

$$\mathbf{F}(k_x, k_y, k) = \frac{T^{\text{TM}}}{k^2 k_\rho^2 k_{0z}} \begin{bmatrix} k_x^2 k_{0z}^2 & k_x k_y k_{0z}^2 & k_x k_{0z} k_\rho^2 \\ k_x k_y k_{0z}^2 & k_y^2 k_{0z}^2 & k_y k_{0z} k_\rho^2 \\ k_x k_{0z} k_\rho^2 & k_y k_{0z} k_\rho^2 & k_\rho^4 \end{bmatrix} +$$

$$\frac{T^{\text{TE}}}{k_\rho^2 k_{0z}} \begin{bmatrix} k_y^2 & -k_x k_y & 0 \\ -k_x k_y & k_x^2 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

式中, $k_\rho^2 = k_x^2 + k_y^2$ , $k_{0z} = \sqrt{k^2 - k_\rho^2}$ , $T^{\text{TE, TM}} = \frac{(1 - (R^{\text{TE, TM}})^2)}{1 - (R^{\text{TE, TM}})^2 \exp(j2k_{1z}d)}$ 。这里 $T^{\text{TE, TM}}$ 中的 $R^{\text{TE}} = \frac{k_{0z} - k_{1z}}{k_{0z} + k_{1z}}$ , $R^{\text{TM}} = \frac{\epsilon_b k_{0z} - k_{1z}}{\epsilon_b k_{0z} + k_{1z}}$ ;  $R^{\text{TM}}$ 和 $R^{\text{TE}}$ 中的 $k_{1z} = \sqrt{k_1^2 - k_\rho^2}$ ,其中的 $k_1 = k \sqrt{\epsilon_b}$ 表示墙体介质

的波数。此外,式(1)中的 $\bar{\mathbf{E}}(k_x, k_y, k)$ 为

$$\bar{\mathbf{E}}(k_x, k_y, k) = \int \mathbf{E}(x_R, y_R, k) \cdot \exp(-jk_x x_R - jk_y y_R) dx_R dy_R \quad (2)$$

式中的 $\mathbf{E}(x_R, y_R, k)$ 代表全采样回波散射数据。可以看出,式(2)的右边部分实际上是一个二维空域傅里叶变换,可用算子 $F_{2D}(\cdot)$ 表示,即 $\bar{\mathbf{E}}(k_x, k_y, k) = F_{2D}[\mathbf{E}(x_R, y_R, k)]$ 。接下来,令

$$\mathbf{J}(k_x, k_y, k, z) = \frac{j^{256z} \exp(j\sqrt{4k^2 - k_x^2 - k_y^2}(z - z_R - d) + j\sqrt{4k_1^2 - k_x^2 - k_y^2}d)}{\xi_0 k^2 \left| F\left(\frac{k_x}{2}, \frac{k_y}{2}, k\right) \right|^2 (4k^2 - k_x^2 - k_y^2)}$$

则式(1)可以简化为

$$\mathbf{O}(x, y, z) = \int dk_x \int dk_y \frac{1}{4\pi^2} F_{2D}[\mathbf{E}(x_R, y_R, k)] \cdot \mathbf{J}(k_x, k_y, k, z) \exp(jk_x x + jk_y y)$$

这里,等式右边的第2和第3个积分项也是一个二维空域傅里叶逆变换,则式(2)就继续简化为

$$\mathbf{O}(x, y, z) = \int dk F_{2D}^{-1}\{F_{2D}[\mathbf{E}(x_R, y_R, k)] \cdot \mathbf{J}(k_x, k_y, k, z)\} \quad (3)$$

由于使用步进频率雷达信号,自由空间波数 $k$ 积分可以转化为求和形式,则式(3)可进一步变为

$$\mathbf{O}(x, y, z) = \sum_k F_{2D}^{-1}\{F_{2D}[\mathbf{E}(x_R, y_R, k)] \cdot \mathbf{J}(k_x, k_y, k, z)\} \quad (4)$$

可以看出,式(4)是将回波散射数据变换为目标图像。因此,我们可以借鉴文献[10]的方法,将其利用傅里叶变换反演,得到衍射层析成像正向变换,即

$$\mathbf{E}(x_R, y_R, k) = \sum_z F_{2D}^{-1}\{F_{2D}[\mathbf{O}(x, y, z)] \cdot \mathbf{J}^{-1}(k_x, k_y, k, z)\} \quad (5)$$

令快速傅里叶变换算子 $\Psi(\cdot) = \sum_z F_{2D}^{-1}[F_{2D}(\cdot) \mathbf{J}^{-1}(k_x, k_y, k, z)]$ ,将式(5)可以表示为矩阵的形式,即

$$\mathbf{E} = \Psi(\mathbf{O}) \quad (6)$$

式中,假设 $\mathbf{O}$ 与 $\mathbf{E}$ 的维度相同,均为 $M \times N \times K$ ;当 $\mathbf{O}$ 和 $\mathbf{E}$ 的维度在不等的情况可以通过补零来实现。

在压缩感知理论框架下,对频点和阵元位

置进行随机降采样,但对阵元位置进行随机选取后要对未被选取的阵元作补零处理,则式(6)改写为

$$\mathbf{Y} = \Phi \mathbf{E} = \Phi \Psi(\mathbf{O}) + \mathbf{N} \quad (7)$$

式中, $\mathbf{Y} \in C^{M \times N \times K'}$  ( $K' \ll K$ )为随机降采样得到的测量数据, $\Phi \in C^{K' \times K}$ 为随机测量矩阵, $\mathbf{N} \in C^{M \times N \times K'}$ 为高斯白噪声。对于整个成像空间,目标在空间中满足稀疏性,即 $\mathbf{O}$ 满足稀疏性。通过求解 $l_1$ 范数的最优化问题,可得到目标像 $\mathbf{O}$ 的稀疏估值 $\hat{\mathbf{O}}$ ,其目标函数是

$$\hat{\mathbf{O}} = \arg \min_{\mathbf{O}} \frac{1}{2} \|\mathbf{Y} - \Phi \Psi(\mathbf{O})\|_2^2 + \lambda \|\mathbf{O}\|_1 \quad (8)$$

式中, $\lambda$ 为正则化参数。

## 2 算法描述

### 2.1 LAMP网络构建

对于式(8),可以采用AMP算法<sup>[11]</sup>求解。但是,其迭代过程还必须考虑衍射层析模型中的快速傅里叶变换算子 $\Psi$ ,所以得到修正的AMP算法为

$$b_t = \frac{1}{M} \|\hat{\mathbf{O}}_{t-1}\|_0 \quad (9)$$

$$\mathbf{D}_t = \mathbf{Y} - \Phi \Psi(\hat{\mathbf{O}}_{t-1}) + b_t \mathbf{D}_{t-1} \quad (10)$$

$$\lambda_t = \frac{\alpha}{\sqrt{M}} \|\Psi^H \Phi^H(\mathbf{D}_t)\|_2 \quad (11)$$

$$\hat{\mathbf{O}}_t = \eta_{st} (\hat{\mathbf{O}}_{t-1} + \Psi^H(\Phi^H \mathbf{D}_t); \lambda_t) \quad (12)$$

式中, $\Psi^H$ 为 $\Psi$ 的共轭转置算子,由式(4)可得

$$\Psi^H(\cdot) = \sum_k F_{2D}^{-1}[F_{2D}(\cdot) \mathbf{J}(k_x, k_y, k, z)]$$

$\hat{\mathbf{O}}_t$ 为第 $t$ 次迭代目标像估值; $\mathbf{D}_t$ 为第 $t$ 次迭代残差值; $b_t$ 为残差系数; $\lambda_t$ 为阈值参数, $\alpha_t$ 为阈值可调参数; $\eta_{st}$ 为复数软阈值函数<sup>[12]</sup>。以上迭代过程,需要首先通过上一次目标像 $\hat{\mathbf{O}}_{t-1}$ 计算残差系数 $b_t$ ,接着结合上一次的残差 $\mathbf{D}_{t-1}$ 对残差更新得到 $\mathbf{D}_t$ ,然后用 $\mathbf{D}_t$ 求解阈值参数 $\lambda_t$ ,最后根据软阈值函数更新目标像得到 $\hat{\mathbf{O}}_t$ 。

根据文献[11]的模型驱动学习方法,我们将式(9)~(12)的AMP迭代过程映射成多层神经网络,然后通过数据驱动进行学习,即所谓的学习近似消息传递算法(Learning Approximate Message Passing, LAMP)。LAMP的网络结构如图2所示,设定有 $T$ 层。根据式(9)~(12)的迭代过程,它的每一

层应设计成如图 3 所示的 3 个隐层,分别是残差层、算子更新层和非线性变换层,具体如下:

1) 残差层:对上一层残差  $D_{t-1}$  进行更新,输出本层的残差  $D_t$ 。为简化网络结构,将式(9)代入式(10),可得

$$D_t = Y - \Phi\Psi(\hat{O}_{t-1}) + \frac{1}{M}\|\hat{O}_{t-1}\|_0 D_{t-1} \quad (13)$$

2) 算子更新层:利用  $\hat{O}_{t-1}$  和  $D_t$  作为输入,输出本层的非线性输入参数  $R_t$  和阈值参数  $\lambda_t$ ,具体

计算为

$$R_t = \hat{O}_{t-1} + \Psi^H(\Phi^H D_t) \quad (14)$$

$$\lambda_t = \frac{\alpha_t}{\sqrt{M}} \|\Psi^H(\Phi^H D_t)\|_2 \quad (15)$$

3) 非线性变换层:利用  $R_t$  和  $\lambda_t$  作为输入,采用非线性变换输出本层的图像估值  $\hat{O}_t$ ,这里选取的非线性收缩函数<sup>[11]</sup>是

$$\eta(R_t; \lambda_t) = \text{sign}(R_t) \text{ReLU}\{|R_t| - \lambda_t\} \quad (16)$$

式中,ReLU为整流线性单元。

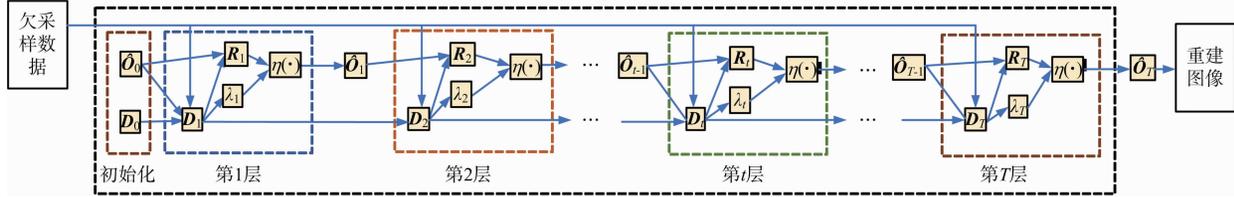


图 2 LAMP 网络结构

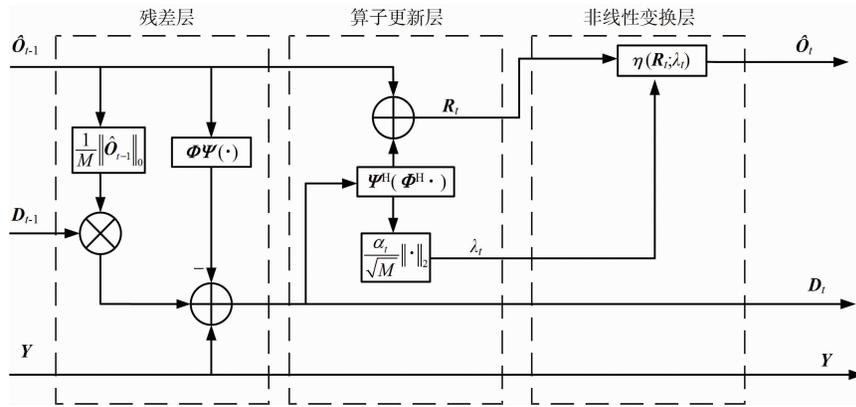


图 3 第  $t$  层 LAMP 的内部结构

## 2.2 LAMP 网络训练

纵观图 2 和图 3,我们可以看出整个网络结构中需要学习的参数有  $\alpha_1, \alpha_2$  到  $\alpha_T$ 。令  $\hat{\Theta}$  为学习参数的估值  $\hat{\alpha}_1$  到  $\hat{\alpha}_T$  集合,我们采用批量梯度下降法进行训练<sup>[8]</sup>,并以归一化均方误差函数作为损失函数,通过反向传播和 Adam 方法更新网络参数。其中,损失函数的具体形式为

$$\begin{cases} L(\Theta) = \frac{1}{N} \sum_{n=1}^N \frac{\|f(\Theta) - \tilde{O}_n\|_2}{\|\tilde{O}_n\|_2} \\ \hat{\Theta} = \text{argmin}(L(\Theta)) \end{cases} \quad (17)$$

式中,  $N$  表示训练样本数,  $n$  为第  $n$  个样本,  $f(\Theta)$  为网络输出的重构结果,  $\tilde{O}_n$  表示第  $n$  个样本的目标图像,  $L(\Theta)$  表示归一化的均方误差。基于式(17)的损失函数,采用 Adam 方法进行求解<sup>[13]</sup>,其更新参数过程为

$$\begin{cases} g_i = \nabla_{\Theta} L(\hat{\Theta}_{i-1}) \\ m_i = \beta_1 m_{i-1} + (1 - \beta_1) g_i, v_i = \beta_2 v_{i-1} + (1 - \beta_2) g_i^2 \\ \hat{m}_i = \frac{m_i}{(1 - \beta_1^i)}, \hat{v}_i = \frac{v_i}{(1 - \beta_2^i)} \\ \hat{\Theta}_i = \hat{\Theta}_{i-1} - \frac{\gamma \hat{m}_i}{(\sqrt{\hat{v}_i} + \kappa)} \end{cases} \quad (18)$$

式中,  $i$  为第  $i$  次训练,  $g_i$  为损失函数的梯度,  $\beta_1, \beta_2$  为矩估计的指数衰减率,  $\beta_1, \beta_2 \in [0, 1)$ ,  $m_i$  为偏差的一阶矩估计,  $v_i$  为偏差的二阶矩估计,  $\beta_1^i$  为  $\beta_1$  的  $i$  次方,  $\beta_2^i$  为  $\beta_2$  的  $i$  次方,  $\hat{m}_i$  为偏差修正的一阶矩估计,  $\hat{v}_i$  为偏差修正的二阶矩估计,  $\gamma$  为学习率,  $\kappa$  为趋近 0 的值(避免分母为 0)。这里,因 Adam 方法利用梯度的一阶矩估计和二阶矩估计动态调整每个参数的学习率,适用于求解式(8)涉及的带噪声数据和稀疏问题。

### 3 算法复杂度分析

从前文可知,衍射层析算法构建的压缩感知模型与文献[4]构建的压缩感知模型区别在于字典矩阵的构建。对于模型空间复杂度,一般字典矩阵的大小为天线数 $\times$ 频点数 $\times$ 成像网格数<sup>[4]</sup>,即矩阵维度为 $MNK \times MNK$ (假设目标像 $\mathbf{O}$ 与回波数据具有相同大小);对于本文的衍射层析模型而言,快速傅里叶变换算子的 $\mathbf{J}$ 决定了它的大小, $\mathbf{J}$ 的维度降为 $MNK \times K$ ,明显小于字典矩阵所占内存。对于模型时间复杂度,字典矩阵构建时间采用大 $O$ 记法可以表示为 $O(M^2 N^2 K)$ ,衍射层析模型构建时间为 $O(MNK^2)$ ;对于凸优化算法运行时间主要体现在计算 $\Psi(\mathbf{O})$ 上,文献[4]计算所需 $M^2 N^2 K^2 + MNK$ 次,本文如表1所示,总体小于文献[4]所需时间。

表1 衍射层析模型运行次数

计算方法	运行次数
方位向 FFT	$5MNK \log_{10} M$
高度向 FFT	$5MNK \log_{10} N$
方位向 IFFT	$5MNK \log_{10} M$
高度向 IFFT	$5MNK \log_{10} N$
匹配滤波器	$MNK$
与系数 $\mathbf{J}$ 相乘	$MNKK$
沿频率求和	$MNKK$

## 4 仿真与实验数据结果分析

### 4.1 仿真数据测试结果分析

根据图1所示的场景,成像空间是墙体右边的1 m(长) $\times$ 1 m(宽) $\times$ 1 m(高)的区域。假设由 $71 \times 71$ 个天线单元的二维面阵组成,阵元距离墙体2 m,发射信号是载波频率为4 GHz、带宽为2 GHz的步进频率连续波信号。墙体厚度为0.2 m,介电常数为4.5。所有点目标均设置在空间内的任意位置,目标数目被随机设定为1~4,另外信噪比又设为-5,-1,0,1和5 dB等多种情况,一共生成400组样本,每个样本包含50%降采样回波数据和生成的一幅目标图像。实验平台在配置为Intel i7,24 GB RAM,GTX1050Ti的电脑上完成,所提LAMP网络利用Python torch编写实现。

假设LAMP网络层数 $T=4$ ,其初值 $\hat{\mathbf{O}}_0=0$ ,

$\mathbf{D}_0=0, \Theta=1, \mathbf{m}_0=0, \mathbf{v}_0=0, \beta_1=0.9, \beta_2=0.999, \gamma=0.1$ 。每次训练数据为20组,共计训练50次,经过训练后得到的 $\Theta=[11.3697, 11.1859, 11.1698, 11.1681]$ 。图4显示了训练50次时均方误差曲线图,从图中可以看出,随着训练次数增加,均方误差变化趋于平缓,说明网络成像结果与目标像趋近,训练结果趋于稳定,网络收敛。

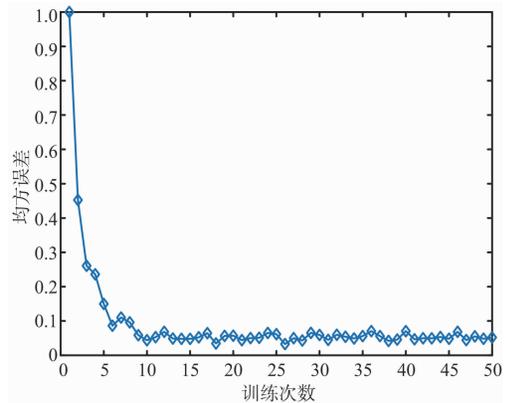


图4 均方误差

下面,设验证场景为放置在空间坐标为(0.3, 0.5, 0.5), (0.7, 0.5, 0.5)的点目标,其对应反射系数均为0.5,信噪比为0 dB,对数据50%降采样。LAMP网络成像结果如图5所示,左上图为沿距离向 $z=0.5$  m处方位-高度切片图,右上图为沿高度向 $y=0.5$  m处方位-距离切片图,左下图为沿方位向 $x=0.3$  m处距离-高度切片图,右下图为三维立体图,可以看出在没有手工调整阈值参数的情况下,成像网络得到的重建图像去除了旁瓣和杂波,准确对点目标成像。

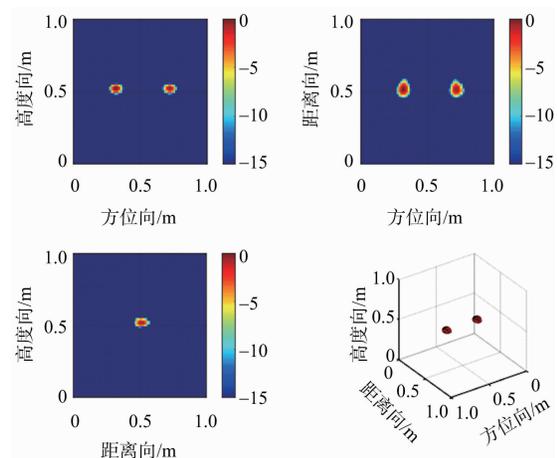
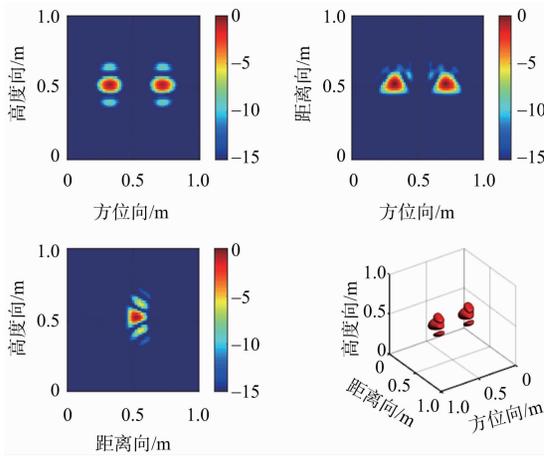


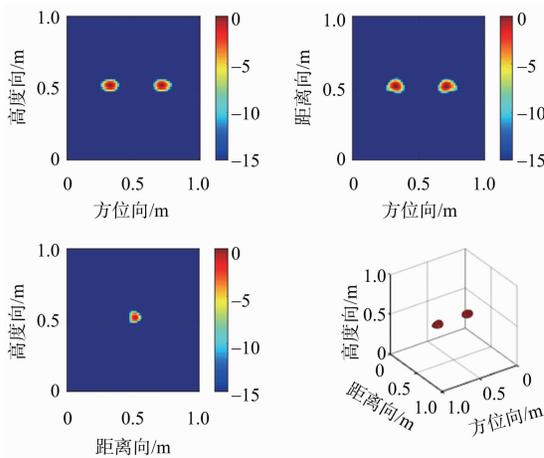
图5 LAMP网络成像结果

图6给出了不同算法的成像结果对比。其中图6(a)为DT算法成像结果,图6(b)为迭代软阈

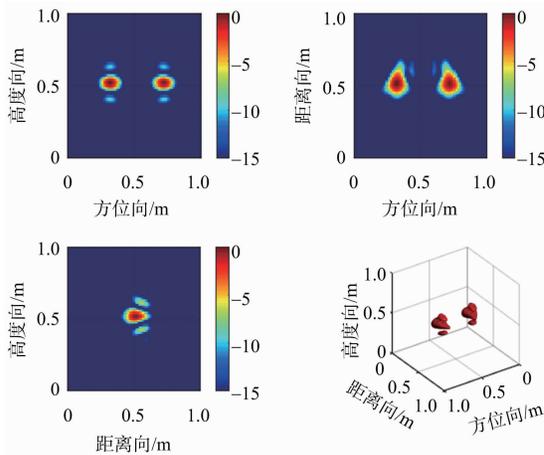
值算法(ISTA)算法成像结果,图 6(c)~图 6(e)给出了  $\alpha=1,5,10$  时 AMP 算法的成像结果。与图 5 的成像结果对比,衍射层析算法成像中旁瓣的存在导致成像结果杂波较多;ISTA 算法图像与图 5 像基本相同,但是 ISTA 算法阈值参数需要手动调整;AMP 算法在不同的  $\alpha$  下对旁瓣滤除效果明显



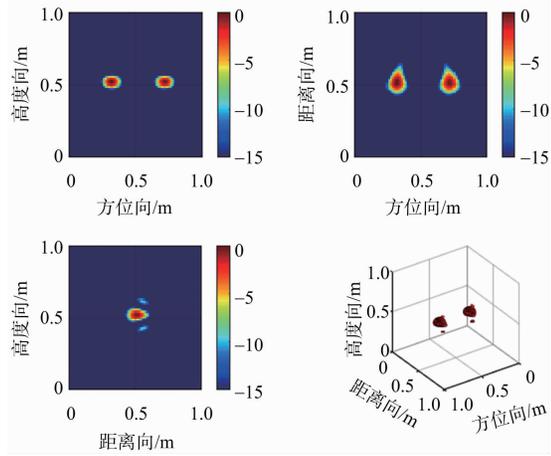
(a) DT 算法成像结果



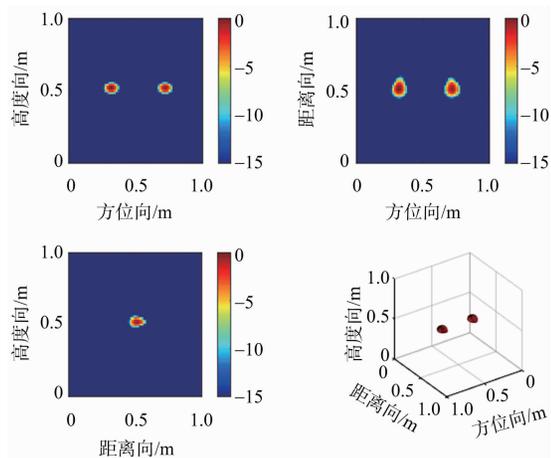
(b) ISTA 算法成像结果



(c)  $\alpha=1$  时 AMP 算法成像结果



(d)  $\alpha=5$  时 AMP 算法成像结果



(e)  $\alpha=10$  时 AMP 算法成像结果

图 6 LAMP 网络与其他成像算法的比较

不同,表明人工设定阈值参数将很大程度上决定最终的成像结果。

为了更直观地对算法性能进行对比,表 2 给出其在 TCR、ENT、MFOD、PRT 方面的对比,分别反映了目标杂波比、图像熵、目标的边缘轮廓特性和算法运行时间。从表中可以看出,DT 算法成像的 PRT 值最小,程序运行时间较短,但其 TCR、ENT 和 MFOD 较大,图像聚焦度不够高,杂波较多,轮廓特性不明显;ISTA 算法 TCR、ENT 和 MFOD 较小,成像质量较高,但其 PRT 值为 691 s,反映出程序迭代次数过多,运行时间较长;AMP 算法在不同  $\alpha$  值下 TCR、ENT 和 MFOD 不同,表明了阈值参数对重建图像质量的影响;LAMP 网络 TCR 值比手动调参下小 3 dB,ENT 与 MFOD 也小于其他算法,所成图像最清晰,此外,AMP 单次迭代时间约为 40 s,而 LAMP 单层网络使用 GPU 运行时间约为 4 s,PRT 值小于 ISTA 和

AMP算法,表明了本文方法运行时间小于其他方法。

表2 TCR、ENT、MFOD、PRT的比较

算法	TCR/dB	ENT	MFOD	PRT/s
DT	32.386 6	0.476 2	0.004 6	195.557 6
ISTA	61.450 9	0.375 4	2.882 2e-04	691.602 9
AMP, $\alpha=1$	42.493 6	0.446 7	0.002 1	631.301 7
AMP, $\alpha=5$	53.335 3	0.398 6	7.009 6e-04	—
AMP, $\alpha=10$	61.476 9	0.372 5	3.314 6e-04	—
LAMP	64.450 3	0.366 0	2.593 6e-04	211.392 0

## 4.2 实测数据结果分析

采用维拉诺瓦(Villanova)大学高级通信中心(CAC)与空军研究实验室(AFRL)合作收集得到的穿墙雷达成像实验数据,探测场景如图7所示<sup>[14]</sup>。选取 $65 \times 57$ 平面阵列所得到的数据进行三维穿墙成像,发射信号是载波频率为2 GHz,带宽为1 GHz的步进频率波形,步进间隔为5 MHz。对数据进行预处理,使用背景相消除墙体杂波和噪声。使用Populated Scene场景回波数据生成训练样本,加入信噪比为 $-5 \sim 5$  dB范围内噪



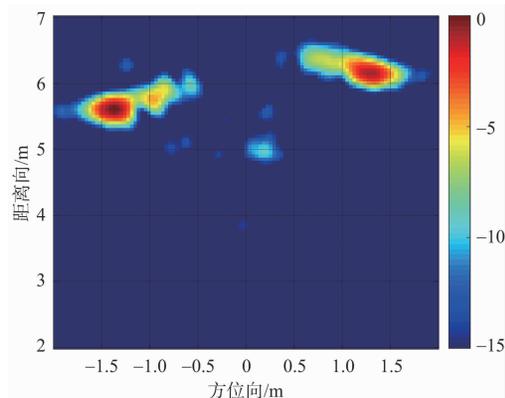
(a) 探测场景图



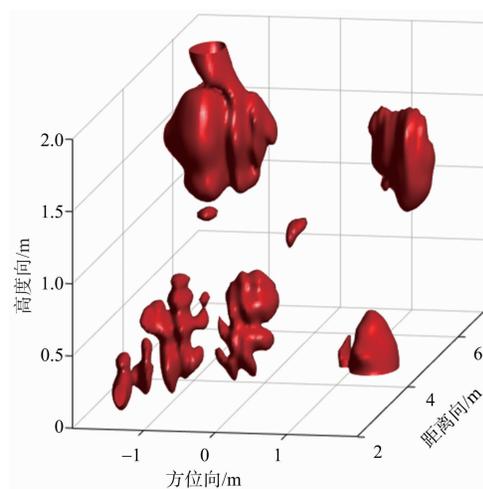
(b) 雷达穿墙场景图

图7 实验场景

声,一共生成50组样本。使用Calibrated Scene场景进行实验验证,DT算法成像结果如图8所示,LAMP网络下回波数据50%降采样成像结果如图9所示。在图8、图9中,图(a)为高度为1.2 m处切片图,图(b)为三维成像立体图。通过对比可知,DT算法存在目标周围旁瓣较多、受噪声干扰严重、数据量大等缺点;LAMP网络的成像目标周

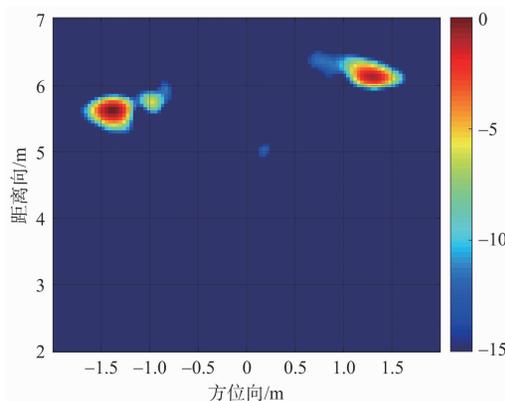


(a) 方位-距离向切片图

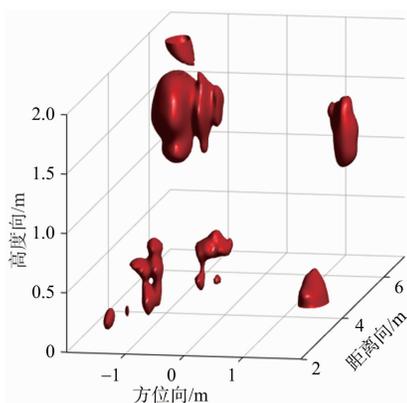


(b) 三维成像立体图

图8 DT算法成像结果



(a) 方位-距离向切片图



(b) 三维成像立体图

图 9 LAMP 网络成像结果

围基本不存在旁瓣干扰,随机噪声也得到了很好的抑制,同时没有损坏目标的边缘特性。表 3 给出了 DT 算法和 LAMP 网络所成像的 TCR、ENT、MFOD 和 PRT 值。

表 3 TCR、ENT、MFOD、PRT 的比较

算法	TCR/dB	ENT	MFOD	PRT/s
DT	33.023 0	0.967 6	0.003 4	398.530 0
LAMP	50.169 6	0.728 3	0.001 3	416.327 0

## 5 结束语

本文提出了一种衍射层析稀疏模型下的学习成像方法,通过构建衍射层析稀疏模型降低了存储空间,并通过设计 LAMP 网络自动学习可调参数,提高了成像质量,适用于三维穿墙雷达成像。还需注意的是:在衍射层析稀疏模型中没有使用深度学习卷积层替换其他参数,也没有考虑墙体杂波与目标回波的分离,下一步拟对网络结构和训练样本作一定的更改,实现它们的分离。

### 参考文献:

[1] AHMAD F, ZHANG Y, AMIN M G. Three-Dimensional Wideband Beamforming for Imaging Through a Single Wall[J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(2): 176-179.

[2] ZHANG W, HOORFAR A. Three-Dimensional Real-Time Through-the-Wall Radar Imaging with Diffraction Tomographic Algorithm [J]. IEEE Trans on Geoscience and Remote Sensing, 2013, 51(7): 4155-4163.

[3] REN K, CHEN J, BURKHOLDER R J. A 3-D Uniform Diffraction Tomographic Algorithm for Near-

Field Microwave Imaging through Stratified Media[J]. IEEE Trans on Antennas and Propagation, 2018, 66(6): 3034-3045.

- [4] YOON Y S, AMIN M G. Through-the-Wall Radar Imaging Using Compressive Sensing Along Temporal Frequency Domain[C]//IEEE International Conference on Acoustics Speech & Signal Processing, Dallas, TX, USA; IEEE, 2010: 2806-2809.
- [5] GAO Y, PENG W, QU Y, et al. Through-the-Wall Imaging Based on Modified Compressive Sampling Matching Pursuit[C]// 2017 Sixth Asia-Pacific Conference on Antennas and Propagation, Xi'an, China; IEEE, 2017: 1-3.
- [6] 张燕, 晋良念. 结合 TV 约束的穿墙雷达扩展目标成像方法[J]. 雷达科学与技术, 2017, 15(3): 229-235.
- ZHANG Yan, JIN Liangnian. Through-the-Wall Radar Extended Target Imaging with TV Constraints [J]. Radar Science and Technology, 2017, 15(3): 229-235. (in Chinese)
- [7] TANG V H, BOUZERDOUM A, PHUNG S L. Compressive Radar Imaging of Stationary Indoor Targets with Low-Rank Plus Jointly Sparse and Total Variation Regularizations [J]. IEEE Trans on Image Processing, 2020, 29: 4598-4613.
- [8] ITO D, TAKABE S, WADAYAMA T. Trainable ISTA for Sparse Signal Recovery[J]. IEEE Trans on Signal Processing, 2019, 67(12): 3113-3125.
- [9] 罗迎, 倪嘉成, 张群. 基于“数据驱动+智能学习”的合成孔径雷达学习成像[J]. 雷达学报, 2020, 9(1): 107-122.
- [10] LI Shiyong, ZHAO Guoqiang, SUN Houjun, et al. Compressive Sensing Imaging of 3-D Object by a Holographic Algorithm[J]. IEEE Trans on Antennas and Propagation, 2018, 66(12): 7295-7304.
- [11] BORGERDING M, SCHNITER P, RANGAN S. AMP-Inspired Deep Networks for Sparse Linear Inverse Problems [J]. IEEE Trans on Signal Processing, 2017, 65(16): 4293-4308.
- [12] 侯彦, 上官伟, 孙进平. 基于复近似消息传递的前视雷达成像分辨率增强算法[J]. 航空工程进展, 2020, 43(1): 60-65.
- [13] KINGMA D, BA J. Adam: A Method for Stochastic Optimization[C]//the 3rd International Conference for Learning Representations, San Diego; [s. n.], 2014: 1-15.