

融合 M2Net 的子空间优化逆散射成像方法<sup>\*</sup>

朱艳萍 张慕林 陈金立 陈家楠 陈继鑫

(南京信息工程大学电子与信息工程学院 南京 210044)

**摘要:** 针对提升现有逆散射成像算法精度的需求和抗噪声性能具有局限性的问题,本文提出了一种基于随机方差缩减的子空间优化法与 M2Net 深度网络融合的逆散射成像方法。该方法在优化的 SOM 框架下引入随机方差缩减梯度法,通过使用两层循环结构,在每次迭代中随机抽取少量样本进行更新,以修正项来减少方差并提升计算效率。在此基础上,构建了包含多尺度层的 M 型残差块的 U 形嵌套模型 M2Net 网络结构,并将初始重构结果作为输入数据用于 M2Net 的训练,实现对散射体结构的进一步高精度重构。该方法与传统方法相比,在结构相似性方面提升 10%~30%,在均方根误差方面降低 5%~15%,表明所提出方法在抗噪声性能方面表现优异,并能够实现高精度的图像重建。

**关键词:** 电磁逆散射;子空间优化法;随机方差缩减梯度法;M2Net

**中图分类号:** O451;TN011 **文献标识码:** A **国家标准学科分类代码:** 510.1025

## Subspace-optimized inverse scattering imaging method integrated with M2Net

Zhu Yanping Zhang Mulin Chen Jinli Chen Jianan Chen Jixin

(School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

**Abstract:** In response to the demand for improving the accuracy of existing backscatter imaging algorithms and the limitations of noise resistance, this paper proposes an inverse scattering imaging method based on the integration of Subspace Optimization Method with Variance Reduction and the M2Net. Within the optimized SOM framework, the Stochastic Variance Reduced Gradient method is introduced, employing a two-layer loop structure that randomly samples a small subset of data in each iteration to update the model, thereby reducing variance through correction terms and improving computational efficiency. Building upon this, a U-shaped nested model called M2Net, incorporating M-shaped residual blocks with multi-scale layers, is constructed. The initial reconstruction results are used as input data for the deep network training of M2Net, enabling further high-precision reconstruction of the scatterer structure. Compared with traditional methods, this method improves structural similarity by 10%~30% and reduces root mean square error by 5%~15%, indicating excellent noise resistance performance and the ability to achieve high-precision image reconstruction.

**Keywords:** electromagnetic inverse scattering;subspace optimization method;SVRG;M2Net

## 0 引言

近年来,随着成像技术需求的增长,微波成像技术在医疗成像<sup>[1]</sup>、无损检测<sup>[2]</sup>、油气探测<sup>[3]</sup>和目标识别<sup>[4]</sup>等领域得到了广泛应用。该技术的核心在于解决电磁散射的逆散射问题(inverse scattering problem, ISP),即通过测量散射场数据与电磁场前向模型的结合,重建出目标区域的几何特性和介电常数。然而,逆散射问题存在高度的非线性和病态性<sup>[5]</sup>,对求解的稳定性和精度提出了极高的要求,使得求解过程面临诸多挑战。

传统解决逆散射问题的方法可以分为线性与非线性两种。线性方法通过近似将逆问题转化成线性问题,比如一阶波恩近似和利托夫近似<sup>[6]</sup>等,非线性则是通过迭代方法来优化求解,典型的包括变形波恩迭代(distorted-born iteration method, DBIM)<sup>[7]</sup>、对比源反演法(contrast source inversion, CSI)<sup>[8]</sup>和子空间优化(subspace optimization method, SOM)<sup>[9]</sup>。这些方法成像精度较低且难以对复杂散射体进行成像,同时无法处理高介电常数下的问题。

为了提高成像精度并解决病态问题,近年来基于传统算法提出了多种改进方法<sup>[10-12]</sup>。Ye 等<sup>[13]</sup>提出了一种

收稿日期:2025-03-28

<sup>\*</sup> 基金项目:国家自然科学基金(62071238)项目资助

基于子空间的变形波恩迭代法 (subspace-based distorted-born iteration method, S-DBIM), 它可以比 DBIM 更准确地估计电场, 并且具有更快的收敛速度。文献[14]在子空间划分模糊与确定部分的基础上, 进一步细分感兴趣域, 计算主子域的感应电流。然后, 以主子域的感应电流作为初始解, 重构整个散射体域, 这提高了重构精度并降低了计算解域的维数。此外, 一种基于快速傅里叶变换的双子空间优化方法 (two fold SOM, TSOM)<sup>[15]</sup>来解决电磁逆散射问题, 实现了在高度非线性条件下的逆散射成像。上述研究展现了通过优化传统算法来提升成像效果的潜力, 但也存在一些问题, 如在面对复杂散射体时仍然无法达到较好的成像精度, 且抗干扰能力还有待提升。在逆散射成像算法的综合性能力方面仍然需要深入研究。

由于基于传统算法的改进对提升成像精度的作用是有限的, 而卷积神经网络在图像分割领域表现极其突出<sup>[16-17]</sup>, 因此将卷积神经网络与逆散射问题相结合<sup>[18-20]</sup>的研究也逐渐成为该领域的热门方向。文献[21]借鉴了物理知情监督残差学习的方案来模拟传统波恩迭代法的计算过程, 提出神经波恩迭代方法, 进一步提升了重构散射体精度。Guo 等<sup>[22]</sup>将预测散射场的正向建模神经网络嵌入在反演神经网络中, 反演网络以迭代方式根据模拟数据和观测数据之间的残差预测模型更新。所提出的反演网络可以实现超分辨率重建, 但其网络设计较为复杂。文献[23]提出了一种迭代多尺度深度网络, 通过在不同尺度的感兴趣域内构建目标函数, 并将目标函数分解成若干个优化子问题, 以此求解重构最优解, 为目标实时重构提供了一个有效方案, 但对高度线性的复杂散射体重构仍存在局限性。文献[24]使用变形波恩迭代方法重建大脑二维图像, 并将这些图像作为 U-Net 网络中的输入, 提升了成像效果, 但该方法在前端计算上并没有进行相应的改进以更好地适配网络输入, 缺乏前端与网络输入之间的协同优化。上述方法在重构复杂散射体或高噪声环境下的表现仍然有限。尽管可以提升重构精度, 但在面对高度非线性或复杂结构的散射体时, 其性能可能下降, 容易出现重建不准确的情况。

针对以上问题, 本文提出了一种基于随机方差缩减的子空间优化方法与深度网络 M2Net 融合的逆散射成像新策略。该方法在优化框架中引入了随机方差缩减梯度法 (stochastic variance reduced gradient, SVRG), 以替代传统的共轭梯度法, 从而显著提高了迭代效率与算法的稳定性。初始重构结果通过 SOM-SVRG 方法获得, 并作为输入用于训练深度网络模型 M2Net。M2Net 凭借其卓越的图像分割能力进一步提升了散射体重构的精度。通过在 Austria 和手写体数字识别数据集 (modified national institute of standards and technology database, MNIST) 等数据集上的仿真实验, 验证了所提出方法在逆散射成像方面的优越性能与应用潜力。

## 1 逆散射成像理论与方法

### 1.1 逆散射成像模型和原理

如图 1 所示, 逆散射成像模型由均匀背景介质、散射体与发射、接收天线组成。假设目标区域 D 的均匀背景介质中存在一个非线性散射体, 背景介质的介电常数为  $\epsilon_b$ , 磁导率为  $\mu_b$ , 电导率为  $\sigma_b$ , 而该散射体的形状、位置、相对介电常数值  $\epsilon_r$  均未知。在二维横磁模式下, 区域 D 外均匀交替分布着同一频率的发射天线与接收天线, 其中发射天线的矢量位置是  $r_i^t$ , 阵元数为  $N_i$ , 接收天线的矢量位置和阵元数分别为  $r_p^t$ 、 $N_t$ 。




图 1 电磁逆散射模型图

Fig. 1 Model of electromagnetic inverse scattering problem

解决逆散射成像问题的核心在于: 利用发射、接收天线所获取的散射场数据  $E_p^{sca}(r_p^t)$  来计算未知散射体的介电常数值  $\epsilon_r$ 。根据无源麦克斯韦方程组及电流连续性方程, 可推出自由空间的波动方程:

$$\nabla \times \nabla \times \mathbf{E} = j\omega\mu_b\sigma_b\mathbf{E} + k_b^2\mathbf{E} \quad (1)$$

其中,  $\omega$  为角频率, 介质波数  $k_b = \omega\sqrt{\mu_b\sigma_b}$ ,  $\nabla$  代表哈密顿算子, 将式(1)与矢量格林函数结合, 可得散射场数据方程:

$$\mathbf{E}_p^{sca}(r) = k_b^2 \int_D \mathbf{G}(r, r') \chi(r') \mathbf{E}_p^{tot}(r') dr' \quad (2)$$

其中,  $\chi$  为对比度函数, 且矢量格林函数  $\mathbf{G}(r, r')$  为:

$$\mathbf{G}(r, r') = \left[ \mathbf{J} - \frac{\nabla \times \nabla}{k_0^2} \right] \frac{e^{jk_b|r-r'|}}{4\pi|r-r'|} \quad (3)$$

实际求解中将目标区域 D 划分为  $M$  个网格, 各位置为  $r_m, m = 1, 2, \dots, M$ 。定义  $\mathbf{E}^{tot}(r_m)$  为入射到第  $m$  个网格的总场,  $\mathbf{E}^{inc}(r_m)$  为入射场, 其满足离散偶极近似的自治方程为:

$$\mathbf{E}^{tot}(r_m) = \mathbf{E}^{inc}(r_m) + \sum_{n \neq m} jk_b\eta_0\mathbf{G}(r_m, r_n)\chi\mathbf{E}^{tot}(r_n), \quad m = 1, 2, \dots, M \quad (4)$$

其中, 对比度函数  $\chi = -i(k/\eta_0)A_n[\epsilon(r_n) - 1]$ ,  $A_n$  为  $r_n$  处的网格面积,  $\eta_0$  是自由空间阻抗, 同时  $\chi_n$  与感应电流  $\mathbf{J}_p^d(r_n)$  满足式(5)。

$$\mathbf{J}_p^d(r_n) = \chi_n \mathbf{E}_p^{tot}(r_n), \quad n = 1, 2, \dots, M \quad (5)$$

为简化运算,定义对比源矩阵为  $\mathbf{X}_n = \text{diag}(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M)$ , 映射矩阵为  $\bar{\mathbf{G}}_D(m, n) = jk_b \eta_0 \mathbf{G}(\mathbf{r}_m, \mathbf{r}_n)$ , 感应电流矩阵为  $\bar{\mathbf{J}}_p^d = [\mathbf{J}_p^d(\mathbf{r}_1), \mathbf{J}_p^d(\mathbf{r}_2), \dots, \mathbf{J}_p^d(\mathbf{r}_M)]$ , 入射场矩阵为  $\bar{\mathbf{E}}_p^{\text{inc}}(\mathbf{r}_m) = [\mathbf{E}_p^{\text{inc}}(\mathbf{r}_1), \mathbf{E}_p^{\text{inc}}(\mathbf{r}_2), \dots, \mathbf{E}_p^{\text{inc}}(\mathbf{r}_M)]$ 。那么式(5)结合式(4)可以简化为:

$$\bar{\mathbf{J}}_p^d = \bar{\mathbf{X}}_n \cdot (\bar{\mathbf{E}}_p^{\text{inc}}(\mathbf{r}_m) + \bar{\mathbf{G}}_D(m, n) \cdot \bar{\mathbf{J}}_p^d) \quad (6)$$

由式(2),离散后  $\mathbf{r}_p^t$  处的散射场  $\mathbf{E}_p^{\text{scat}}(\mathbf{r}_p^t)$  可表示为:

$$\mathbf{E}_p^{\text{scat}}(\mathbf{r}_p^t) = \sum_{m=1}^M jk_b \eta_0 \mathbf{G}(\mathbf{r}_p^t, \mathbf{r}_m) \mathbf{X}_m \mathbf{E}_p^{\text{tot}}(\mathbf{r}_m) \quad (7)$$

同理,定义映射矩阵为  $\bar{\mathbf{G}}_s(p, m) = jk_b \eta_0 \mathbf{G}(\mathbf{r}_p^t, \mathbf{r}_m)$ , 散射场矩阵为  $\bar{\mathbf{E}}_p^{\text{scat}} = [\mathbf{E}_p^{\text{scat}}(\mathbf{r}_1^t), \mathbf{E}_p^{\text{scat}}(\mathbf{r}_2^t), \dots, \mathbf{E}_p^{\text{scat}}(\mathbf{r}_{N_s}^t)]$ , 则式(7)可以简化为:

$$\bar{\mathbf{E}}_p^{\text{scat}} = \bar{\mathbf{G}}_s(p, m) \cdot \bar{\mathbf{J}}_p^d \quad (8)$$

即逆散射模型的状态方程式(6)与数据方程式(8)。

## 1.2 SOM-SVRG(SS)优化方法

子空间优化方法(SOM)采用奇异值分解  $\bar{\mathbf{G}}_s = \bar{\mathbf{U}} \cdot \bar{\Sigma} \cdot \bar{\mathbf{V}}^H$  来确定对比源的子空间,将对比源分解成确定部分和模糊部分,即  $\bar{\mathbf{V}}^H$  中前  $L$  个奇异值的分解向量组成信号子空间  $\bar{\mathbf{V}}^+$ , 后  $M-L$  个向量组成噪声子空间  $\bar{\mathbf{V}}^-$ 。那么感应电流  $\bar{\mathbf{J}}$  可以写作:

$$\bar{\mathbf{J}} = \bar{\mathbf{J}}^+ + \bar{\mathbf{V}}^- \cdot \bar{\alpha} \quad (9)$$

其中,  $\bar{\mathbf{J}}^+$  是确定电流部分,而模糊电流部分需要通过迭代优化参数  $\bar{\alpha}$  获得。SOM 方法构建的目标函数为:

$$\text{Min } f(\alpha_1, \alpha_2, \dots, \alpha_L, \bar{\chi}) =$$

$$\sum_{p=1}^{N_i} \left( \frac{\bar{\mathbf{E}}_p^{\text{scat}} - (\bar{\mathbf{G}}_s \bar{\mathbf{J}}_p^+ + \bar{\mathbf{G}}_s \bar{\mathbf{V}}^- \cdot \bar{\alpha}_p)^2}{\bar{\mathbf{E}}_p^{\text{scat}}^2} + \frac{\bar{\mathbf{A}} \cdot \bar{\alpha}_p - \bar{\mathbf{B}}^2}{\bar{\mathbf{J}}_p^+^2} \right) \quad (10)$$

其中,为简化运算定义  $\bar{\mathbf{A}} = \bar{\mathbf{V}}^- \bar{\chi} \cdot (\bar{\mathbf{G}}_D \cdot \bar{\mathbf{V}}^-)$ ,  $\bar{\mathbf{B}} = \bar{\chi} \cdot (\bar{\mathbf{E}}_p^{\text{inc}} + \bar{\mathbf{G}}_D \cdot \bar{\mathbf{J}}^+) - \bar{\mathbf{J}}^+$ ,  $\bar{\mathbf{G}}_D, \bar{\mathbf{G}}_s$  分别是 D 域与 S 域的二维矢量格林函数,下标  $p$  代表第  $p$  个发射天线对应相应参数。传统 SOM 方法通过对该目标函数进行交替优化和共轭梯度下降法,来更新  $\bar{\alpha}$  与对比度函数  $\bar{\chi}$  两个参数。但是,该方法在计算过程中可能会导致中心点的介电常数激增,同时共轭梯度法在每次迭代时都需要重新计算全局梯度,计算代价较高。

因此,本文通过利用随机方差缩减法来降低计算成本,并引入罚函数项来削弱计算后过高的介电常数值。SVRG 利用内外双循环结构<sup>[25]</sup>,通过每隔若干次更新设置一个参考点,然后在该处计算所有样本的平均梯度,得到平均梯度值。在随后的迭代过程中,每一步的梯度估计值是由当前点的梯度、参考点的梯度以及平均梯度共同计算得到。具体而言,首先定义场误差方程  $\delta^{\text{dat}}$  式(11)和电流误差方程  $\delta^{\text{sta}}$  式(12)。

$$\delta^{\text{dat}} = \bar{\mathbf{E}}_p^{\text{scat}} - (\bar{\mathbf{G}}_s \bar{\mathbf{J}}_p^+ + \bar{\mathbf{G}}_s \bar{\mathbf{V}}^- \cdot \bar{\alpha}_p) \quad (11)$$

$$\delta^{\text{sta}} = \bar{\mathbf{A}} \cdot \bar{\alpha}_p - \bar{\mathbf{B}} \quad (12)$$

初始化后,对于第  $i$  次外循环,计算目标函数对于  $\bar{\alpha}$  的梯度:

$$g_{p,n} = \nabla_{\bar{\alpha}_p} f = \sum_{p=1}^{N_i} \left( \frac{(\bar{\mathbf{G}}_s \cdot \bar{\mathbf{V}}^-)^H \cdot \delta_{p,i-1}^{\text{dat}}}{\bar{\mathbf{E}}_p^{\text{scat}}^2} + \frac{\bar{\mathbf{A}}_{i-1}^H \cdot \delta_{p,i-1}^{\text{sta}}}{\bar{\mathbf{J}}_p^+^2} \right) \quad (13)$$

计算当前累积全梯度的均值  $\bar{g}_i = \frac{1}{i} \sum_{v=1}^i g_{p,v}$ , 然后进入内循环,对于第  $t$  次内循环,随机抽取  $i_t \in (1, 2, \dots, N_i)$ , 通过式(14)来缩减迭代方差:

$$g_t = g_{p,i_t} - (\bar{g}_{p,i_t} - \bar{g}_i) \quad (14)$$

其中,  $g_t$  表示梯度修正后的无偏估计,  $\bar{g}_{p,i_t}$  表示该随机样本中参考点的梯度值,  $\bar{g}_{p,i_t} - \bar{g}_i$  是当前梯度偏差,  $g_{i_t}$  是当前抽样点梯度,利用更新步长  $\eta_{i_t}, g_t$  来更新参数  $\bar{\alpha}_p$ 。

$$\bar{\alpha}_t = \bar{\alpha}_{t-1} + \eta_{p,i_t} \rho_{p,i_t} \quad (15)$$

其中,设定  $\rho_{p,i_t} = g_t + (\text{Re}[(g_t - \bar{g}_{p,i_t})^* g_t]) / (\bar{g}_{p,i_t} \|^2) \rho_{p,i_{t-1}}$ , 且设定  $\eta_{p,i_t} = - \left( \frac{(\bar{\mathbf{G}}_s \cdot \bar{\mathbf{V}}^-)^H \cdot \delta_{p,i-1}^{\text{dat}}}{\bar{\mathbf{E}}_p^{\text{scat}}^2} + \frac{(\bar{\mathbf{A}}_{i-1} \cdot \rho_{p,i_t})^H \cdot \delta_{p,i-1}^{\text{sta}}}{\bar{\mathbf{J}}_p^+^2} \right) / \left( \frac{\bar{\mathbf{G}}_s \cdot \bar{\mathbf{V}}^- \rho_{p,i_t}^2}{\bar{\mathbf{E}}_p^{\text{scat}}^2} + \frac{\bar{\mathbf{A}}_{i-1} \rho_{p,i_t}^2}{\bar{\mathbf{J}}_p^+^2} \right)$ , 此时结束内循环,并选取参考点并计算参考点梯度  $\bar{g}_{p,i_t}$ , 同时更新总场和对比度。改进后迭代过程如算法 1 所示。

### 算法 1 SOM-SVRG 迭代算法伪码

输入:对比源初值  $\omega_0$

散射场数据  $\mathbf{E}_{\text{SCA}}$

测量数据的索引  $i \in (1, 2, \dots, N)$

随机抽取数据的索引  $i_k \in (1, 2, \dots, N)$

输出:对比度函数,  $X_n$

1) 计算格林函数  $\mathbf{G}_D, \mathbf{G}_S$

2) 设置对比度初值  $\bar{\chi}_0 = 0, \bar{\alpha} = 0$ , 迭代次数  $i$  至 0

3) while  $F(\bar{\alpha}, \bar{\chi}_n) < \Omega$  or  $i < N$

步骤(1)求解当前目标函数全梯度值  $\bar{g}_{ip}$

步骤(2)求解累积全梯度的均值

$$\bar{g}_i = \frac{1}{i} \sum_{v=1}^i g_{p,v}$$

步骤(3)

for  $t=0, 1, 2, \dots, N-1$  do

1. 随机抽取  $i_t \in (1, 2, \dots, N_i)$

2. 利用全梯度均值修正估计梯度

$$g_t = g_{p,i_t} - (\bar{g}_{p,i_t} - \bar{g}_i)$$

3. 更新当前步长  $\eta_{p,i_t}$

4. 更新系数值

$$\bar{\alpha}_t = \bar{\alpha}_{t-1} + \eta_{p,i} \mathbf{p}_{p,i}$$

end for

步骤(4)选取参考点

步骤(5)更新总场  $\bar{\mathbf{E}}_{p,i}^{\text{tot}} = \bar{\mathbf{E}}_{p,i}^{\text{inc}} + \bar{\mathbf{G}}_p \bar{\mathbf{J}}_{p,i}$

更新对比度

$$\mathbf{x}_i = \left[ \sum_{p=1}^{N_i} \frac{\bar{\mathbf{E}}_{p,i}^{\text{tot}}}{\|\bar{\mathbf{J}}_p^+\|} \cdot \frac{\bar{\mathbf{J}}_{p,i}}{\|\bar{\mathbf{J}}_p^+\|} \right] / \left[ \sum_{p=1}^{N_i} \frac{\bar{\mathbf{E}}_{p,i}^{\text{tot}}}{\|\bar{\mathbf{J}}_p^+\|} \cdot \frac{\bar{\mathbf{E}}_{p,i}^{\text{tot}}}{\|\bar{\mathbf{J}}_p^+\|} \right]$$

步骤(6)  $i = i + 1$

4) end

### 1.3 M2Net 网络模型

实现准确的逆散射成像,需要有效集成图片中的局部

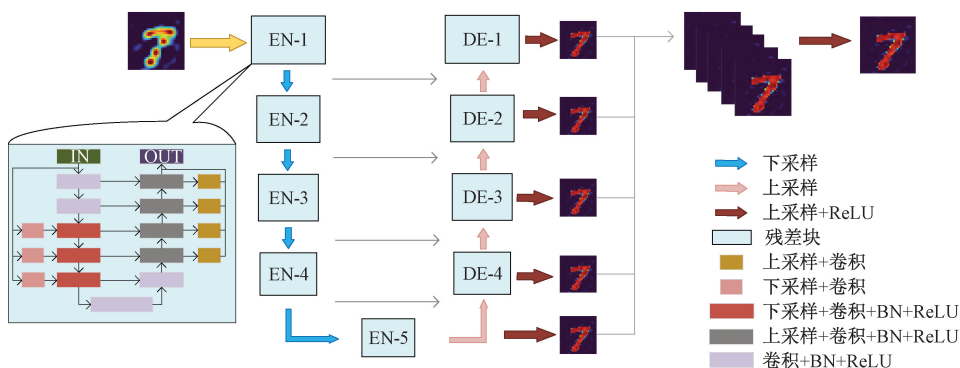


图 2 M2Net 网络结构框架图

Fig. 2 M2Net network architecture framework diagram

结构及残差连接,能在不降低分辨率的情况下提取多尺度上下文信息。对于逆散射问题,介电常数分布描述了散射体对周围背景的电磁特性差异,这要求网络模型具有精准的特征提取能力,以得到正确的反演图形。因此在编码阶段,En\_1 至 En\_5 通过逐层增加卷积层的深度来扩大感受野,捕捉全局和局部信息的多尺度特征,在解码阶段, M2Net 与编码阶段对称,采用了逐步上采样、特征融合和卷积的策略来逐渐还原特征图。而网络右侧的特征融合模块将 5 个预测图加权求和;在 En\_5 及 De\_1 至 De\_4 后接入  $3 \times 3$  卷积层与激活函数,生成 6 个侧向显著性预测图,并由特征融合模块通过将 6 个侧向输出统一上采样以输出高精度的成像结果。

在逆散射成像中,网络的编码器通过深层特征提取有效捕获微弱散射信号的空间特征,解码器则通过多级特征重建实现目标结构的精确恢复。该架构显著增强了系统在低信噪比条件下的鲁棒性,其分层特征解耦机制为复杂散射环境下的高精度定量成像提供了理论保障。

#### 1) 结构化剪枝

原始的 U2Net 通过使用扩张卷积以及过量的编解码层来提升感知域捕捉更广泛的特征信息,但这同时会导致特征信息的丢失并增加计算量,为了使网络更有效地处理

信息和全局信息。M-Net 作为 U-Net 的改进版本<sup>[26]</sup>,通过引入多尺度的输入和输出层,进一步增强了模型对不同尺度特征的敏感度。在损失函数的设计上, M-Net 采用加权均方差作为目标函数,从而更充分地利用多尺度特征,提升图像分割能力。受 U2Net 与 M-Net 启发,本文所使用的 M2Net 总体框架是一种以 M-Net 为基础的嵌套结构,如图 2 所示,通过嵌套 M-Net 的方式提高网络的深度与复杂性,从而提升模型对多尺度信息的捕捉和利用。而 M2Net 的每个小层级均沿用了类似 M-Net 中的编码器-解码器结构,以有效分离、处理和融合多层次的图像特征信息。

具体来说, M2Net 模型的最外层是由编码器和解码器块组成的 9 个独立的大 U 形结构,每个结构都填充有小的 M 块,包括重复应用的多尺度输入输出层、多尺度编解码

逆散射问题,本文对其进行结构化剪枝,将原始 U2Net 的扩张卷积以及 11 层的编解码层剪枝为 9 层编解码层,从而降低了网络的复杂度和训练时间。

#### 2) 改进的 M 型模块

与传统 U2Net 中的残差 U 型模块(residual U-blocks, RSU)相比,改进的 M 型模块通过增加多尺度输入层与多尺度输出层,由多尺度输入输出层、多尺度编解码结构及残差连接三部分组成:输入层提取局部特征;编解码结构中左侧通过多级下采样捕获多尺度特征,右侧通过上采样重建高分辨率特征;残差连接将输入特征与深层特征融合,增强特征表达能力。

### 1.4 SS-M2Net 算法实现

基于上述方法,本文提出了一种基于 SS-M2Net 的新型逆散射成像方法,图 3 是该算法的流程图,通过将改进的 SOM 算法和 M2Net 网络模型相结合,实现高效且高质量的成像效果。具体而言,首先在散射场信息采集阶段,采用交替方式环形排布发射和接收天线,利用足够长的散射柱体以近似二维截面,将测量的散射场数据输入算法进行处理。然后,在优化的 SOM 框架下,引入随机方差缩减梯度下降算法替代传统的共轭梯度法,从而显著提升迭代更新过程的效率和收敛性能。最后,将通过 SVRG 算法获



得的初始重构解作为深度网络模型 M2Net 的输入,通过对 M2Net 的训练和优化,进一步提升成像质量。该方法成功实现了高精度的逆散射成像目标。




图 3 SS-M2Net 流程图

Fig. 3 SS-M2Net flowchart

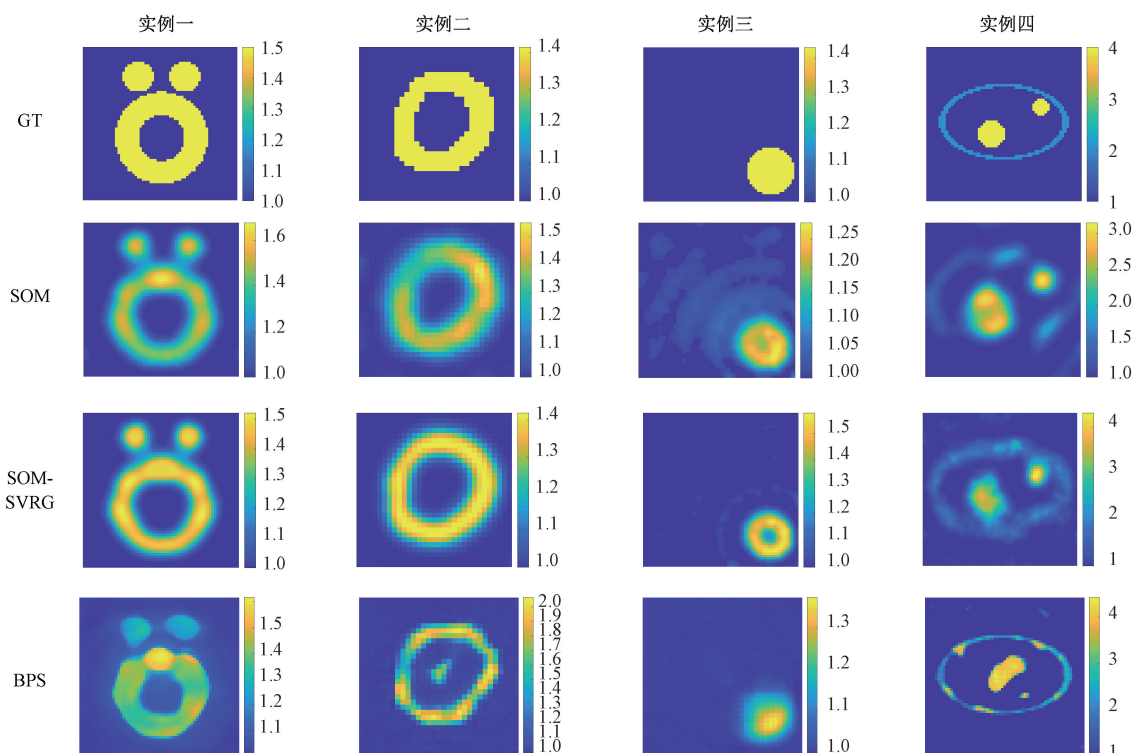
## 2 实验结果分析

### 2.1 SS-M2Net 的准确性

本节将展示一些成像结果以评估 SS-M2Net 方法的成像准确性。在实验中,设定共有 16 根发射天线和 32 根接收天线,其均匀交替的分布在区域 D 外的一个半径为 2 m 的中心圆上。工作频率设定为 400 MHz~3 GHz,以克服色散效应,满足不同散射体所需的最佳成像频率。实验将区

域 D 离散为  $32 \times 32$  或  $64 \times 64$  的网格,并以  $32 \times 16$  的多稳态响应矩阵的形式记录在前向模型中生成的散射场数据。本文选取运用 SOM、SOM-SVRG、BPS、SS-UNet、SS-M2Net 进行反演成像。同时为了使散射场数据更加贴近实际测量效果,向该矩阵加入相应水平的加性高斯白噪声,本小节所有成像结果均加入 5% 的高斯白噪声。

对于类圆柱截面型散射体,假设散射体在  $1 \text{ m} \times 1 \text{ m}$  的目标区域内,其具体位置与介电常数值均未知,设定背景介质为 1。网络部分则采用圆柱截面数据集,其散射体位置随机生成,介电常数值选取 1.2~1.8 的随机值,其中选取 700 张图像用于训练网络模型,200 张用于验证,100 张用于测试。仿真测试结果如图 4 所示,实例一的 Austria 散射体由两个圆柱体截面和一个圆环截面构成,用于检验各方法在较复杂散射体重建中的性能表现。结果表明,SS-M2Net 在复杂散射体的重建上保持了相对稳定的成像效果,其余方法并不能很好完成复杂散射体的重建。实例二则采用了不规则的手写圆环以测验网络对异常图片的成像性能,SS-M2Net 仍然有较好的成像结果。在实例三中,SOM、SOM-SVRG、BPS 对单一圆截面中心成像存在失真,而 SS-M2Net 则展现了更好的成像性能。实例四是模拟脑部血块的简易散射体,同时将介电常数值提升至 4,进一步提升散射体复杂程度,此时对照组方法的成像结果仅能勉强体现散射体位置,对散射体形状和介电常数值反演都难以完成,而 SS-M2Net 在该场景中表现出较高的重建精度,能够准确地恢复散射体的介电常数和形状。






图 4 圆柱截面、类脑数据集重构对比图

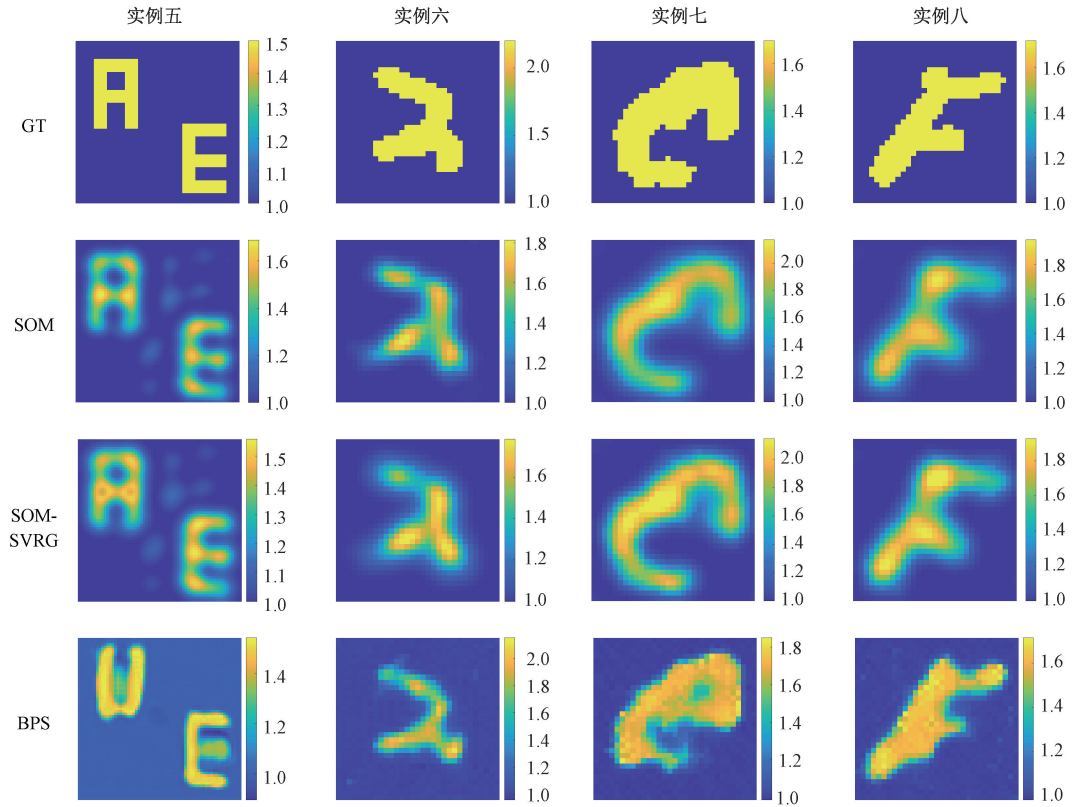
Fig. 4 Reconstruction result of cylindrical cross-section

为了进一步检验 SS-M2Net 对提升成像精度具有普遍性,本文继续采用印刷类散射体和 MNIST 手写数据集做验证。其中,印刷类字母数据集是在  $64 \times 64$  分辨率的矩阵方格内,随机生成 1 000 张有两个不同字母的图像,其位置随机且不重叠,介电常数值相同且选取 1.2~1.8 的随机值。如图 5 所示,实例五采取了印刷字母数据集,相较于实例一~四,该实例更着重于各方法对图形边界的成像能力,成像结果表明 SS-M2Net 对边界具有较好的分辨能力。实例六为 MNIST 数据集,本实例网络选取了 700 个样本用于训练,200 个样本验证,100 个样本测试。实例七、八为 EMNIST 数据集,在实例六的基础上进一步提升成像难

度,SS-M2Net 也取得了良好的成像结果。在定量分析方面,表 1 和表 2 列出了 5 种方法在成像中的结构相似性指数(structural similarity index, SSIM)和均方根误差(root mean squared error, RMSE)的对比结果。其中,结构相似性定义为:

$$\text{SSIM} = \frac{(2\mu_{\hat{y}}\mu_y + C_1)(2\sigma_{\hat{y}y} + C_2)}{(\mu_{\hat{y}}^2 + \mu_y^2 + C_1)(\sigma_{\hat{y}}^2 + \sigma_y^2 + C_2)} \times 100\% \quad (16)$$

其中,  $\hat{y}$ 、 $y$  分别表示原始图像和成像结果,  $\mu_{\hat{y}}$ 、 $\sigma_{\hat{y}}$ 、 $\sigma_{\hat{y}y}$  分别表示图像像素的均值、标准差和协方差。






图 5 印刷字母、MNIST 重构结果对比图

Fig. 5 Reconstruction result of letter and MNIST

表 1 圆柱截面、类脑数据集重构的 SSIM 和 RMSE

Table 1 SSIM and RMSE for reconstruction of cylindrical cross-section

%

成像方法	实例一		实例二		实例三		实例四	
	SSIM	RMSE	SSIM	RMSE	SSIM	RMSE	SSIM	RMSE
SOM	60	14	68	8.2	72	11.0	41	45
SOM-SVRG	70	15	77	5.5	81	8.1	50	39
BPS	74	16	70	9.0	78	9.0	53	61
SS-UNet	80	13	85	4.3	93	3.5	61	35
SS-M2Net	86	11	93	3.7	97	2.9	70	30

表 2 字母、MNIST 重构的 SSIM 和 RMSE

Table 2 SSIM and RMSE for reconstruction of letter and MNIST

%

成像方法	实例五		实例六		实例七		实例八	
	SSIM	RMSE	SSIM	RMSE	SSIM	RMSE	SSIM	RMSE
SOM	57	19	55	27	58	24.6	58	22
SOM-SVRG	69	16	63	24	62	22	63	24
BPS	74	12.4	73	16	69	27	74	20
SS-UNet	80	10	71	20	73	18	76	16
SS-M2Net	91.4	6.1	84.5	11	82	11.5	85	11.3

均方根误差则定义为:

$$\text{RMSE} = \frac{1}{N} \sqrt{\sum_{n=1}^N \frac{\|\epsilon_r(r_n) - \epsilon_b(r_n)\|^2}{\|\epsilon_b(r_n)\|^2}} \times 100\%$$

(17)

其中,  $\epsilon_b(r_n)$  表示散射体  $r_n$  处的真实介电常数值,  $\epsilon_r(r_n)$  表示  $r_n$  处重构的介电常数值。

可以观察到, SS-M2Net 在 SSIM 指标上相较于其余方法具有显著提升, 提升幅度在 10%~30%。此外, SS-M2Net 在 RMSE 指标上也表现出一定程度的降低。这些结果表明, SS-M2Net 在成像精度上具有一定的优越性。

2.2 SS-M2Net 的鲁棒性

在实际应用中, 测量获得的散射场数据往往会受到各种噪声干扰, 因此对算法的噪声鲁棒性提出了较高要求, 以适应不同程度的噪声影响。为评估 SS-M2Net 的抗噪性

能, 本节选用 Austria 散射体, 将不同水平的高斯白噪声添加至测得的散射体多稳态响应矩阵中, 并对其进行逆散射重构分析, 以验证算法在噪声环境下的鲁棒性。同时, 本节引入性能指标相对误差(relative error, RE)来进一步定量评判各噪声下的成像效果。

$$\text{RE} = \frac{1}{N} \sum_{n=1}^N \frac{\|\epsilon_r(r_n) - \epsilon_b(r_n)\|}{\|\epsilon_b(r_n)\|} \times 100\%$$

(18)

其中,  $\epsilon_b(r_n)$  表示散射体  $r_n$  处的真实介电常数值,  $\epsilon_r(r_n)$  表示  $r_n$  处重构的介电常数值。

如图 6 所示, 基于 5% 高斯噪声的圆柱截面数据集进行网络训练后, 利用 SS-M2Net 算法对具有不同水平加性高斯白噪声的 Austria 散射体数据进行反演重构。图 6(a)~(d) 分别对应 5%、10%、20%、30% 的高斯白噪声水平。结果显示, 当噪声水平低于 20% 时, SS-M2Net 方法能够保持良

好的成像质量,当噪声水平超过 30%后,重构图像才开始出现明显失真。图 7 展示了在不同噪声条件下重构结果的介电常数值分布直方图。在与原始介电常数值最为接近的频段 1.45~1.65 中,尽管噪声水平不断增加,该频段的占比并未显著降低。这表明尽管在高噪声条件下重构图像的形状略有失真,但其介电常数值依然保持了较高的精确度。

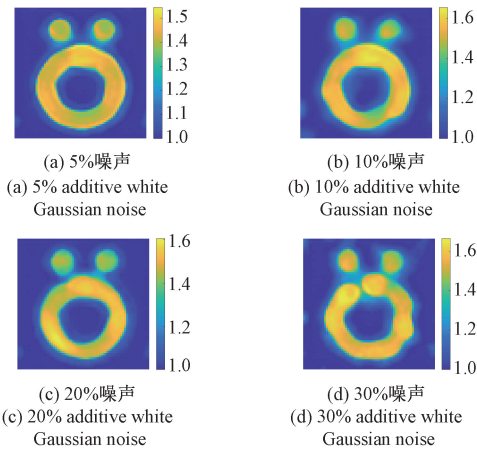


图 6 不同噪声下的 Austria 重构结果对比图  
Fig. 6 Reconstruction result of Austria under different noises




图 7 不同噪声下的 Austria 介电常数值分布  
Fig. 7 Distribution of dielectric Austria's constant values under different noises

表 3 定量展示了不同噪声水平下重构图像的相对误差值。结果表明,随着高斯白噪声百分比的逐步增大,相对误差值依然保持在较低范围内,表现出良好的稳定性。这一趋势进一步验证了 SS-M2Net 模型在处理高噪声环境时具有较好的鲁棒性。

表 3 不同噪声下重构“Austria”的相对误差  
Table 3 RE of "Austria" under different noises

噪声	5%	10%	20%	30%
RE	0.049 2	0.061 6	0.077	0.081 7

2.3 消融实验

为了进一步验证 M2Net 对逆散射重构精度提升的有效性,本节选用 Austria 散射体,通过对 U2Net 中依次加入

剪枝和改进 M 模块操作,来展开消融实验,重构结果与实验数据分别如图 8 与表 4 所示。图 8(b)~(d)分别对应 3 种不同模块的成像重构结果。

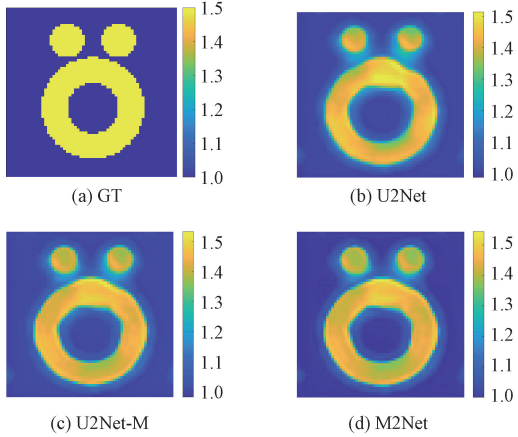


图 8 不同模块下的 Austria 重构结果对比图  
Fig. 8 Reconstruction result of Austria under different module

表 4 不同模块下重构“Austria”的 SSIM 和 RMSE  
Table 4 SSIM and RMSE of "Austria" under different module

U2Net	M 模块	剪枝	RE	SSIM/%	RMSE/%
✓			0.054	83.5	11.8
✓	✓		0.051	85.1	11.4
✓	✓	✓	0.049	86.0	11.0

如图 8 与表 4 所示,在替换改进的 M 模块以后,成像结果的 SSIM 提升 1.6%,RE 与 RMSE 分别降低 0.003 与 0.4%,这表明 M 模块挖掘了更多的散射体特征,同时剪枝操作使得网络减少冗余特征,提升了网络性能。

3 结 论

本文提出了一种 SOM-SVRG 与 M2Net 神经网络相融合的方法。首先在改进 SOM 框架下,利用 SVRG 代替共轭梯度法完成后续迭代更新,然后用所求得原始解训练 M2Net,进一步优化成像效果,达到目标的逆散射成像。实验结果表明,SS-M2Net 能够较为精确地描述逆散射成像过程,与传统方法相比,在多个关键指标上都有一定提升,具有更强的重构稳定性和成像精度,从而验证了该算法在成像过程中的有效性和优越性。未来工作将进一步研究高介电常数与复杂图像的成像算法,并与实际脑肿瘤检测和成像的应用相结合。

参考文献

[1] GUO L, NGUYEN-TRONG N, AI-SAFFAR A, et al. Calibrated frequency-division distorted born iterative tomography for real-life head imaging [J]. IEEE Transactions on Medical Imaging, 2021, 41(5):



- 1087-1103.
- [2] GAO Y, LIU H, WANG X, et al. On an artificial neural network for inverse scattering problems[J]. *Journal of Computational Physics*, 2022, 448: 110771.
  - [3] HE Y, ZHANG L, TONG M S. Microwave imaging of 3-D dielectric-magnetic penetrable objects based on integral equation method[J]. *IEEE Transactions on Antennas and Propagation*, 2023, 71(6): 5110-5120.
  - [4] BAO G, LI P, LIN J, et al. Inverse scattering problems with multi-frequencies [J]. *Inverse Problems*, 2015, 31(9): 093001.
  - [5] BEVACQUA M T, ISERNIA T. Quantitative non-linear inverse scattering: A wealth of possibilities through smart rewritings of the basic equations[J]. *IEEE Open Journal of Antennas and Propagation*, 2021, 2: 335-348.
  - [6] 于士奇,张清河,覃琴,等. 一阶 Born 近似下的不均匀目标贝叶斯压缩感知微波成像方法[J]. *微波学报*, 2020, 36(3): 49-54.
  - YU SH Q, ZHANG Q H, QIN Q, et al. Microwave imaging of non-uniform target within the first-order born approximation by bayesian compressive sensing [J]. *Journal of Microwaves*, 2020, 36(3): 49-54.
  - [7] 刘珩,王若璇. 基于改进对比源反演算法的脑卒中微波检测成像技术研究[J]. *北京理工大学学报*, 2022, 42(10): 1097-1104.
  - LIU H, WANG R X. Research on microwave imaging technology of stroke detection based on improved contrast source inversion algorithm[J]. *Journal of Beijing Institute of Technology*, 2022, 42 (10): 1097-1104.
  - [8] CHEN X. Subspace-based optimization method for solving inverse-scattering problems [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 48(1): 42-49.
  - [9] YE X, CHEN X. Subspace-based distorted-born iterative method for solving inverse scattering problems[J]. *IEEE Transactions on Antennas and Propagation*, 2017, 65(12): 7224-7232.
  - [10] KARADIMA O, LU P, SOTIRIOU I, et al. Experimental validation of the DBIM-TwIST algorithm for brain stroke detection and differentiation using a multi-layered anatomically complex head phantom[J]. *IEEE Open Journal of Antennas and Propagation*, 2022, 3: 274-286.
  - [11] THEU L T, QUANG-HUY T, DUC-NGHIA T, et al. High sound-contrast inverse scattering by MR-MF-DBIM Scheme[J]. *Electronics*, 2022, 11(19): 3203.
  - [12] QUANG-HUY T, NGUYEN T K, SOLANKI V K, et al. An enhanced multi-frequency distorted born iterative method for ultrasound tomography based on fundamental tone and overtones [J]. *International Journal of Information Retrieval Research (IJIRR)*, 2022, 12(1): 1-19.
  - [13] YE X, CHEN X. A distorted Born subspace based optimization method [C]. *2016 Progress in Electromagnetic Research Symposium (PIERS)*. IEEE, 2016: 939.
  - [14] ALI M R, KHATTAB M A, MABROUK S M. Optical soliton solutions for the integrable Lakshmanan-Porsezian-Daniel equation via the inverse scattering transformation method with applications [J]. *Optik*, 2023, 272: 170256.
  - [15] LU P, KOSMAS P. Three-dimensional microwave head imaging with GPU-based FDTD and the DBIM method[J]. *Sensors*, 2022, 22(7): 2691.
  - [16] 陈光耀,陈田,高学海,等. 跨层融合的轻量化太阳能电池片缺陷分割方法[J]. *电子测量技术*, 2024, 47(24): 118-127.
  - CHEN G Y, CHEN T, GAO X H, et al. C2LA-U2-Net: Light weight defect segmentation method for solar Cells with cross-layer fusion [J]. *Electronic Measurement Technology*, 2024, 47(24): 118-127.
  - [17] 王子鹏,孙鹏,程耀瑜,等. 基于深度学习增强的散射介质成像重建[J]. *国外电子测量技术*, 2024, 43(12): 1-7.
  - WANG Z P, SUN P, CHENG Y Y, et al. Deep learning-enhanced imaging reconstruction through scattering media[J]. *Foreign Electronic Measurement Technology*, 2024, 43(12): 1-7.
  - [18] GUO L, SONG G, WU H. Complex-valued Pix2pix—Deep neural network for nonlinear electromagnetic inverse scattering [J]. *Electronics*, 2021, 10(6): 752.
  - [19] LI L, WANG L G, TEIXEIRA F L, et al. DeepNIS: Deep neural network for nonlinear electromagnetic inverse scattering[J]. *IEEE Transactions on Antennas and Propagation*, 2018, 67(3): 1819-1825.
  - [20] CHEN X, WEI Z, MAOKUN L, et al. A review of deep learning approaches for inverse scattering problems (invited review) [J]. *Electromagnetic Waves*, 2020, 167: 67-81.
  - [21] SHAN T, LIN Z, SONG X, et al. Neural born iterative method for solving inverse scattering problems: 2D cases [J]. *IEEE Transactions on Antennas and Propagation*, 2022, 71(1): 818-829.
  - [22] GUO R, LIN Z, SHAN T, et al. Physics embedded

deep neural network for solving full-wave inverse scattering problems [J]. IEEE Transactions on Antennas and Propagation, 2021, 70(8): 6148-6159.

[23] 周辉林,黄鑫,王玉峰. 基于迭代多尺度深度网络的非线性逆散射成像方法[J]. 电波科学学报, 2022, 37(6):1019-1024,1094.

ZHOU H L, HUANG X, WANG Y H. Nonlinear inverse scattering imaging method based on iterative multi-scale network [J]. Chinese Journal of Radio Science,2022,37(6):1019-1024,1094.

[24] MOUSAVI S S S, MAJEDI M S. High quality brain image reconstruction based on DBIM and U-Net[C]. 2023 30th National and 8th International Iranian Conference on Biomedical Engineering (ICBME). IEEE, 2023: 171-175.

[25] 刘彦,郭田德,韩丛英. 一类随机方差缩减算法的分析与改进[J]. 中国科学:数学, 2021, 51(9):1433-1450.

LIU Y, GUO T D, HAN C Y. Analysis and improvement for a class of variance reduced methods[J]. Scientia Sinica Mathematica, 2021, 51(9):1433-1450.

[26] MEHTA R, SIVASWAMY J. M-net: A convolutional neural network for deep brain structure segmentation[C]. 2017 IEEE 14th International Symposium on Biomedical Imaging(ISBI 2017). IEEE, 2017: 437-440.

作者简介

**朱艳萍**(通信作者),博士,副教授,主要研究方向为雷达/通信信号处理、超宽带定位及微波近距离成像。

E-mail:001520@nuist.edu.cn

**张慕林**,硕士研究生,主要研究方向为基于深度学习的微波近距离成像。

E-mail:202312490184@nuist.edu.cn

**陈金立**,博士,教授,主要研究方向为基于深度学习的智能信号处理与数据分析、无线通信测向定位技术。

E-mail:chen820803@yeah.net