·智能医疗器械专栏·

基于 Swin Transformer 的稀疏阵列脑卒中微波成像方法

李凡[a] 张泽堃[b] 刘珩[b*]

（北京理工大学 a. 网络空间安全学院；b. 信息与电子学院，北京 100081）

【摘要】 针对便携式微波脑卒中检测设备因天线数量受限导致空间采样稀疏，进而使微波逆散射成像面临严重欠定性与病态性、非迭代算法成像质量差的技术难题，提出一种基于物理先验Swin Transformer的级联成像架构即深度学习增强型截断奇异值分解（deep learning-enhanced truncated singular value decomposition, DL-TSVD）算法。该架构利用深度学习网络的全局自注意力机制，将低维的8×8稀疏散射矩阵高保真映射为16×16稠密矩阵，随后代入截断奇异值分解算法（truncated singular value decomposition, TSVD），完成高分辨率的脑部介电常数分布反演。在S参数拟合精度方面，预测散射矩阵的复数域均方根误差较传统插值法显著降低了67.53%。同时，仿体实验证实了DL-TSVD算法在真实硬件噪声与天线互耦环境下的抗噪泛化能力，重构图像的结构相似性指数（structural similarity index measure, SSIM）达到0.541。实测结果表明该方法在不增加射频硬件的前提下有效缓解了稀疏阵列下电磁逆散射问题的病态性，为便携式微波脑卒中检测设备提供了一定的技术参考。

【关键词】 脑卒中；微波成像；稀疏阵列；深度学习；逆散射问题

【中图分类号】 TH77; TP18; R743.3 【文献标识码】 A 【DOI】 10.11876/mimt202603002

Sparse array microwave stroke imaging method based on Swin Transformer

Li Fan[a], *Zhang Zekun*[b], *Liu Heng*[b*]

(*a. School of Cyberspace Science and Technology*; *b. School of Information and Electronics*, *Beijing Institute of Technology*, *Beijing 100081*, *China*)

【Abstract】 Portable microwave stroke detection devices often suffer from sparse spatial sampling due to a limited number of antennas. This limitation leads to severe ill-posed and ill-conditioned problems in microwave inverse scattering imaging. To address these technical challenges, this paper proposes a cascaded imaging architecture based on a physics-constrained Swin Transformer, termed deep learning-enhanced truncated singular value decomposition (DL-TSVD) algorithm. By leveraging the global self-attention mechanism of the deep learning network, this architecture achieves high-fidelity mapping from a low-dimensional 8×8 sparse scattering matrix to a 16×16 dense matrix. Subsequently, the dense matrix is fed into the truncated singular value decomposition (TSVD) algorithm to accomplish the high-resolution inversion of the brain's permittivity distribution. In terms of S-parameter fitting accuracy, the complex-domain root mean square error of the predicted matrix is significantly reduced by 67.53% compared with traditional interpolation methods. Additionally, phantom experiments verify the noise-resistant generalization ability of the DL-TSVD architecture under real hardware noise and antenna mutual coupling environments. The structural similarity index measure (SSIM) of the reconstructed images reaches 0.541. The results demonstrate that the proposed method effectively mitigates the ill-conditioned nature of the electromagnetic inverse scattering problem under sparse arrays. It breaks through the resolution bottleneck of spatial sampling without increasing the number of antennas, providing a valuable technical reference for

收稿日期：2026-05-22

基金项目：嘉兴市科技计划项目“便携式微波成像颅脑伤快速检测技术及仪器研究”（2024BZ20001）

第一作者：李凡，女，在读硕士研究生，研究方向：微波成像

通信作者：刘珩，女，博士研究生，副教授，研究方向：微波成像

portable microwave stroke monitoring systems.

【Key words】 Brain stroke; Microwave imaging; Sparse array; Deep learning; Inverse scattering problem

脑卒中具有高发病率、高致残率和高死亡率的特征，院前急救与重症监护阶段的快速精准诊断对挽救患者生命至关重要[1-2]。计算机断层扫描（computed tomography, CT）、磁共振成像（magnetic resonance imaging, MRI）等传统医学影像设备虽然分辨率高，但在便携性与部署灵活性方面难以满足急救车震动环境或高频次连续床旁监测的需求，且CT固有的电离辐射限制了其在特殊人群中的应用[3-4]。微波成像（microwave imaging, MWI）技术凭借无电离辐射、非侵入性、低成本及设备紧凑等优势，成为脑卒中检测中极具潜力的医学成像手段[5]。

微波成像技术的核心原理是利用病变组织与正常脑组织之间显著的介电特性差异，测量电磁散射信号并反演颅内的介电常数分布[6]。然而，为满足便携式设备的工程要求，通常只能配置有限数量的天线，稀疏阵列采样导致微波逆散射成像面临严重的欠定性与病态性问题。现有研究[7-8]尝试通过虚拟阵元合成、频域零填充插值或引入结构化权重来改善稀疏阵列下的成像质量。然而，此类基于线性插值的方法存在固有缺陷：一是简单的线性插值无法有效恢复多层脑组织中因多重散射丢失的高频非线性特征；二是针对虚拟数据的抑制权重极难自适应确定，使得重建图像中极易产生高强度的栅瓣伪影，图像分辨率低，病灶边缘模糊。

近年来，深度学习在脑部成像与病变类型分类上展现出巨大潜力，但大多采用端到端的卷积神经网络[9]，受限于局部感受野，难以准确还原天线间的长距离电磁耦合响应。此外，纯数据驱动的学习网络在面临强环境噪声时极易陷入过拟合，产生缺乏物理可解释性的虚假病灶，难以满足医疗级高置信度的需求[10]。

在上述研究基础上，本研究提出了一种基于物理先验 Swin Transformer的级联成像架构即深度学习增强型截断奇异值分解（deep learning–enhanced truncated singular value decomposition, DL–TSVD）算法。DL–TSVD有效结合了深度学习网络与非迭代微波逆散射成像算法，在训练环节引入了融合电磁理论的混合损失函数，利用自注意力机制捕获全局电磁耦合特征，将散射参数矩阵从 8 × 8 向 16 × 16 进行高保真扩维。在不增加射频硬件的前提下，实现了脑卒中出血病灶的高分辨、高保真定量重建。

1 稀疏阵列下的微波脑部成像原理与方法

在已知收发天线位置，发射信号频率以及波形、散射体的几何结构与电磁特性的前提下，基于麦克斯韦方程组可以计算电磁场在空间中的分布。电磁散射逆问题则是在已知散射场分布的情况下，求解空间内的电磁特性分布。脑部病变组织的各项电磁特性参数与健康人脑组织相比均存在明显差异，微波成像技术正是通过在脑外捕获这些含有病变位置与体积信息的异常散射信号，从而实现对脑卒中的定位和成像，成像模型如图 1 所示。

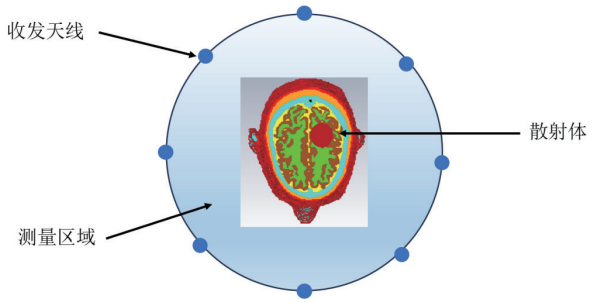


图 1 脑部微波成像模型示意

1.1 线性非迭代算法原理与稀疏阵列下的局限性

在散射体的作用下，空间中任意一点 $\boldsymbol{r}$ 的总电场 $E_{\mathrm{tot}}(\boldsymbol{r})$ 可以表示为入射场 $E_{\mathrm{inc}}(\boldsymbol{r})$ 与散射场 $E_{\mathrm{scat}}(\boldsymbol{r})$ 之和，利用格林定理可以得到 Lippmann–Schwinger 积分方程：

$$E_{\mathrm{tot}}(\boldsymbol{r}) = E_{\mathrm{inc}}(\boldsymbol{r}) + k_b^2 \int_{\Omega} G_b(\boldsymbol{r},\boldsymbol{r}')\chi(\boldsymbol{r}')E_{\mathrm{tot}}(\boldsymbol{r}')\mathrm{d}\boldsymbol{r}' \quad (1)$$

在非迭代成像算法中，通常采用一阶 Born 近似对积分方程进行线性化[11]。假设目标为弱散射体，由散射体引起的场扰动远小于入射场本身，则可用已知的入射场 $E_{\mathrm{inc}}(\boldsymbol{r}')$ 近似代替目标内部的总场 $E_{\mathrm{tot}}(\mathbf{r}')$，在测量面 Γ 上提取散射场，可得线性化的电场积分方程：

$$E_{\text{scat}}(\boldsymbol{r}_m) \approx k_b^2 \int_{\Omega} G_b(\boldsymbol{r}_m, \boldsymbol{r}') E_{\text{inc}}(\boldsymbol{r}') \chi(\boldsymbol{r}') \mathrm{d}\boldsymbol{r}', \quad \boldsymbol{r}_m \in \Gamma \tag{2}$$

在实际求解中，通常采用矩量法将连续的成像区域Ω离散化为M个等尺寸的均匀像素网格[12]，前向散射物理过程的代数映射可表示为：

$$\Delta \boldsymbol{s} \approx \boldsymbol{A} \Delta \boldsymbol{\chi} \tag{3}$$

其中，$\Delta \boldsymbol{s} \in \mathrm{C}^{\mathrm{Q}\times 1}$ 是由 $\mathrm{N}\times\mathrm{N}$ 散射矩阵向量化得到的列向量，有效通道数 $\mathrm{Q}=\mathrm{N}(\mathrm{N}-1)$，$\Delta \boldsymbol{\chi} \in \mathrm{C}^{\mathrm{M}\times 1}$ 是待重建的介电对比度函数向量，$\boldsymbol{A} \in \mathrm{C}^{\mathrm{Q}\times \mathrm{M}}$ 是描述入射场和格林函数的系统矩阵。在传统的TSVD求解架构中[13-14]，首先对系统矩阵 $\boldsymbol{A}$ 进行奇异值分解：

$$\boldsymbol{A} = \boldsymbol{U}\boldsymbol{\Sigma}\boldsymbol{V}^H = \sum_{i=1}^{\operatorname{rank}(\boldsymbol{A})} \sigma_i \boldsymbol{u}_i \boldsymbol{v}_i^H \tag{4}$$

为了获取稳定的逼近解，TSVD引入截断阶数 $K \leqslant \operatorname{rank}(\boldsymbol{A})$，强行舍弃那些极小奇异值对应的噪声子空间特征，构建正则化解：

$$\Delta \boldsymbol{\chi} = \sum_{n=1}^{K} \frac{\boldsymbol{u}_n^H \Delta \boldsymbol{s}}{\sigma_n} \boldsymbol{v}_n \tag{5}$$

然而，在便携式设备中，有效独立观测通道数Q远小于待求像素数M。有限的数据无法支撑高频奇异向量的重构，小奇异值对应的分量对噪声极度敏感，导致重建图像中极易出现严重的伪影和失真，极大限制了稀疏阵列下的成像质量。为了缓解逆问题求解的病态性，可以对散射矩阵进行离散傅里叶变换，结合零填充技术来进行插值，以提高空间采样密度。零填充TSVD（zero-padding TSVD, ZP-TSVD）算法就是将插值后获得的扩展矩阵直接代入TSVD求解器进行图像重构[15]。脑部复杂组织会导致多重散射效应[16]，使得散射S参数与空间位置之间呈现非线性关系，零填充插值无法恢复这些丢失的高频非线性特征。为了实现S参数矩阵的高保真映射，本研究进一步提出采用Swin Transformer作为网络骨干，利用其层级窗口注意力机制捕捉天线间的全连接耦合关系。

1.2 基于物理先验的S-SwinSR网络

由于S参数的物理数值通常在 10^{-3} 至 10^{-5} 量级，直接输入学习网络会导致激活值极小，因此，首先将复数稀疏矩阵拆分为实部与虚部构建双通道实数张量，在训练集上统计全局像素的均值 μ_{train} 与标准差 σ_{train}，对输入张量执行Z-Score标准化操作：

$$\boldsymbol{X}_{\text{in}} = \frac{\operatorname{Concat}\left[\operatorname{Re}\left(\boldsymbol{S}_{\text{orig}}\right), \operatorname{Im}\left(\boldsymbol{S}_{\text{orig}}\right)\right] - \mu_{\text{train}}}{\sigma_{\text{train}}} \tag{6}$$

标准化后的张量进入堆叠的Swin Transformer模块，网络交替利用窗口多头自注意力机制和移动窗口多头自注意力机制，在保持线性计算复杂度的同时，高效提取了整个天线阵列的非线性电磁耦合特征。最后引入亚像素卷积层执行空间重排，最终输出高分辨率的双通道稠密散射张量 $\boldsymbol{Y}_{\text{out}} \in \mathbf{R}^{2\times 16\times 16}$。

为了确保网络生成的S参数矩阵符合电磁波传播规律，本研究设计了融合电磁理论的混合损失函数：

$$\mathrm{L}_{\text{total}} = \lambda_{\text{con}} \mathrm{L}_{\text{con}} + \lambda_{\text{mag}} \mathrm{L}_{\text{mag}} \tag{7}$$

其中，λ_{con}、λ_{mag} 为平衡各损失项的超参数，L_{con}、L_{mag} 分别表示内容一致性损失和幅值损失。

内容一致性损失采用L1范数严格约束预测矩阵 $\boldsymbol{S}_{\text{pred}}$ 与高分辨真值 $\boldsymbol{S}_{\text{gt}}$ 之间的绝对数值偏差，相较于均方误差，L1范数能有效减少图像生成过程中的平滑模糊效应：

$$\mathrm{L}_{\text{con}} = \left\| \boldsymbol{S}_{\text{pred}} - \boldsymbol{S}_{\text{gt}} \right\|_1 \tag{8}$$

由于微波信号的幅值直接映射电磁能量在有耗生物介质中的衰减与耗散过程，单纯的实虚部约束可能导致能量畸变，因此引入幅值损失强制网络学习信号在介质中的电磁幅值一致性约束：

$$\mathrm{L}_{\text{mag}} = \left\| \boldsymbol{S}_{\text{pred}} - \boldsymbol{S}_{\text{gt}} \right\|_2^2 \tag{9}$$

1.3 DL-TSVD级联成像架构

基于S-SwinSR网络与TSVD非迭代算法，本研究构建了DL-TSVD级联成像架构，主要包含3个阶段。

（1）数据构建与预处理阶段：利用矩量法仿真8天线散射数据和16天线散射数据，构建成对的数据集。对数据进行标准化处理，以消除量级差异对网络训练的影响。

（2）深度学习增强阶段：输入归一化后的稀疏S参数，训练后的S-SwinSR网络能够提取全局电磁耦合特征，最终经反归一化输出虚拟扩展的稠密S参数。

（3）成像反演阶段：构建Born近似下的系统矩阵，并应用对角线掩膜剔除强自反射干扰，最后利用TSVD算法求解逆问题，获得高分辨率的目标

介电常数分布图像。

2 实验结果与分析

2.1 前向仿真设置与数据集构建

本研究基于矩量法构建了大规模的电磁前向仿真数据集，以实现中心频率为 1 GHz，工作域为 20 cm × 20 cm的脑部仿真环境，并用背景介质模拟平均脑组织（相对介电常数 ε_r=40、电导率 σ = 0.5 S/m）[17]，如图 2 所示。为了保障模型对不同脑部异常形态的泛化能力，设置在脑部区域内随机生成不同坐标、直径在 0.5 cm至 5 cm区间随机波动的出血性病灶（ε_r=55，σ =1.5 S/m），批量生成了 2 000组对齐样本。每对样本涵盖 1 组 8 天线稀疏散射矩阵（网络输入）及对应场景下的 16 天线稠密散射矩阵（真值标签）。为模拟复杂的真实电磁测量背景，提升网络在实测环境中的抗噪鲁棒性，本研究在训练数据中随机注入了 2% ~ 10%的高斯白噪声进行数据增强。在模型训练策略上，按 7:2:1 的比例将数据集划分为训练集、验证集和独立测试集。

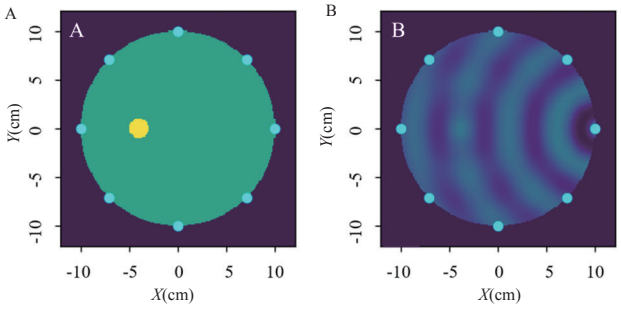


图 2 前向仿真模型设置 A 为二维模型的相对介电常数分布；B 为天线产生的示例总场分布

注：蓝点表示天线位置；黄点表示模拟出血病灶。

2.2 S 参数拟合精度分析

高精度的 S 参数矩阵是实现高质量图像重构的基础，本研究对比了传统零填充插值法与 1.2 所述 S–SwinSR 网络生成的 16 × 16 扩展矩阵。在二维仿真区域内设置一个半径为 1 cm的模拟出血病灶目标，分别采集 8 天线与 16 天线标准散射矩阵，计算得到零填充插值扩展矩阵以及 S–SwinSR 网络生成的扩展矩阵，如图 3 所示。

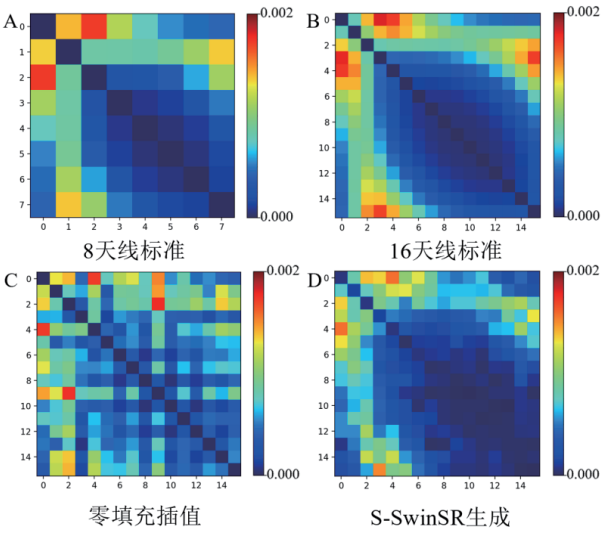


图 3 不同方法获得的 S 参数矩阵对比 A 为仿真生成的 8 天线标准散射矩阵；B 为 16 天线标准散射矩阵；C 为零填充插值扩展矩阵；D 为 S–SwinSR 网络生成的扩展矩阵

从可视化结果可以看出，8 天线下空间采样稀疏，难以表征复杂的散射信息。传统的零填充插值方法虽然在数学上使矩阵实现了稠密化，但整体丢失了由电磁散射引起的高频细节。相比之下，S–SwinSR 网络生成的矩阵与 16 天线标准 S 参数矩阵高度相似。

为客观、定量地评估 S–SwinSR 网络对电磁信号的拟合精度，本研究以 16 天线标准 S 参数矩阵为基准，分别计算了零填充插值与 S–SwinSR 网络生成的 S 参数矩阵归一化后的均方根误差（root mean squared error, RMSE）和平均绝对误差（mean absolute error, MAE）[18]，见表 1。计算结果表明，在复数域拟合中，S–SwinSR 网络的归一化均方根误差相较于零填充插值法显著降低了 67.53%，这证明经过物理先验训练的 S–SwinSR 网络有效捕获了高频非线性散射特征，完成了散射矩阵的高保真扩维预测。

表 1 零填充插值与 S–SwinSR 网络生成 S 参数矩阵的 NRMSE 和 NMAE

方法	复数域		幅值域	
	NRMSE	NMAE	NRMSE	NMAE
零填充插值	1.54	1.09	0.72	0.48
S-SwinSR 网络生成	0.50	0.37	0.41	0.28

注：NRMSE 为归一化后的均方根误差；NMAE 为归一化后的平均绝对误差。

2.3 成像性能评估

为了验证所构建方法在真实复杂电磁环境下的有效性与泛化能力，本研究搭建了微波成像软硬件平台并配制了高保真脑部等效仿体，开展单目标与多目标成像实验。实验平台核心由是德科技N9915A矢量网络分析仪、射频开关矩阵以及8阵元Vivaldi天线阵列组成。采用直径20 cm的3D打印圆柱形薄壁容器模拟颅腔，容器内填充由聚乙烯吡咯烷酮、氯化钠及去离子水配制的脑等效模拟液。其中，背景耦合介质模拟正常脑组织（ε_r=40，σ =0.5 S/m），异常病灶则通过液囊注入模拟血液（ε_r=55，σ =1.5 S/m）来实现，如图4所示。

实验设置了4种成像方案，分别基于不同方法对系统在1 GHz单频点下实测获取的8×8散射矩阵进行逆散射图像重建。①8天线标准TSVD：直接将测量的8×8矩阵代入TSVD求解；②ZP-TSVD：将8×8矩阵经频域零填充插值扩展至16×16稠密矩阵后代入TSVD求解；③加权插值TSVD（interpolation-weighted TSVD，IW-TSVD）：采用插值加权算法对虚拟通道施加显式权重抑制后进行TSVD求解；④DL-TSVD：将实测的8×8矩阵送入训练好的S-SwinSR网络，生成16×16稠密矩阵后代入TSVD求解。由于8天线稀疏阵列的有效独立观测通道数仅为56个，截断阶数K值过高会导致图像被极小奇异值对应的噪声完全淹没；而扩维后输出了240个有效通道，提升了系统矩阵的有效秩，允许采用更高的截断阶数以捕获网络恢复出的高频空间细节，因此成像过程中8天线标准TSVD使用截断阶数K=40，而DL-TSVD等扩维方法均使用K=80以保证成像对比公平性。

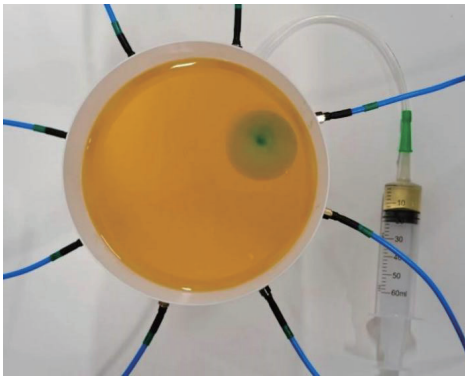


图4 实验装置实物

4种成像方案在单目标和双目标实验中的成像结果见图5。传统8天线标准TSVD受限于稀疏的空间采样，目标与背景伪影严重混叠，偏心病灶定位出现明显偏差。ZP-TSVD虽通过频域插值增加了数据量，但放大了虚假通道从而导致图像伪影泛滥。IW-TSVD通过显式权重抑制了虚拟通道的负面影响，病灶边缘有所收敛。相比之下，本研究提出的DL-TSVD算法表现最优，背景杂波被有效滤除，病灶定位精准。在双目标分辨实验中，传统算法与数学插值类算法均出现了严重的伪影粘连或目标丢失，而DL-TSVD能够清晰地分离两个独立目标，且目标轮廓清晰、背景干净。

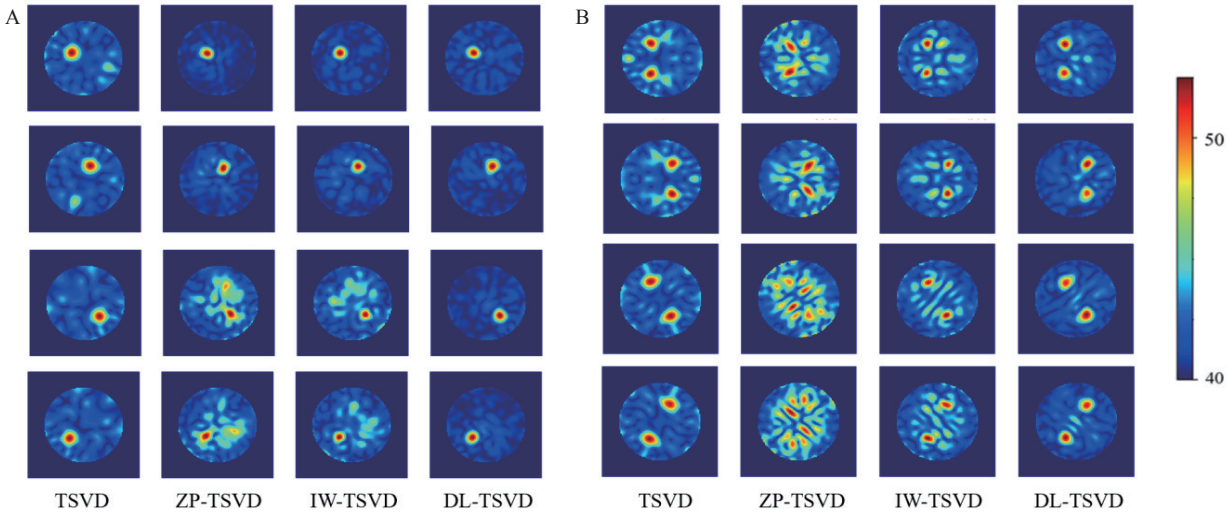


图5 单目标和双目标成像实验结果 A为单目标成像；B为双目标成像

注：TSVD为标准的截断奇异值分解算法；ZP-TSVD为零填充截断奇异值分解算法；IW-TSVD为加权插值截断奇异值分解算法；DL-TSVD为深度学习增强型截断奇异值分解算法。

为客观评估上述成像结果，本研究将物理液囊在天线阵列截面上的几何投影作为参考真值，采用结构相似性指数（structural similarity index measure, SSIM）和均方根误差（MSE）对成像质量进行定量计算，SSIM侧重于分析轮廓与定位保真度，MSE侧重于衡量像素级重建误差[15]。为保证统计结果的可靠性，定量计算样本涵盖了单目标与双目标场景，并且独立重复20次实验，结果如表2所示。

表2 不同方案重构图像的SSIM和MSE比较

成像方法	S参数矩阵规模	截断阶数	SSIM	MSE
8天线标准	8×8	40	0.197	0.265
ZP–TSVD	8×8→16×16	80	0.148	0.312
IW–TSVD	8×8→16×16	80	0.302	0.178
DL–TSVD	8×8→16×16	80	0.541	0.166

注：SSIM为结构相似性指数；MSE为均方根误差；ZP–TSVD为零填充截断奇异值分解算法；IW–TSVD为加权插值截断奇异值分解算法；DL–TSVD为深度学习增强型截断奇异值分解算法。

从定量评估数据可以看出，ZP–TSVD因噪声放大更显著使得SSIM（0.148）低于传统8天线TSVD（0.197）、MSE（0.312）高于传统8天线TSVD（0.265），综合成像性能更差；DL–TSVD重构图像的SSIM达到了0.541，显著高于传统8天线TSVD的0.197，提升了174.62%，更有利于临床上判断病灶位置和大小；同时，DL–TSVD的MSE低至0.166，相较于传统8天线TSVD的0.265大幅降低了37.36%。

3 结论

本文针对便携式微波脑卒中检测设备在稀疏天线阵列下面临的逆问题病态性难题，提出了一种基于物理先验Swin Transformer的级联成像架构DL–TSVD。S–SwinSR网络实现了从8×8稀疏S参数到16×16稠密S参数的非线性映射，在网络训练中融合了L1范数和幅值能量损失，避免了使用深度学习网络直接输出成像结果的不可解释性。误差量化分析表明，S–SwinSR网络生成的S参数矩阵在复数域RMSE上较传统零填充插值法降低了67.53%。这种包含真实高频散射特征的高维矩阵，有效地缓解了TSVD求解过程中采样不足导致的病态性。

在仿体成像实验中，无论是单目标还是复杂的双目标场景，DL–TSVD算法均能显著抑制稀疏阵列带来的栅瓣伪影。在8天线条件下，成功实现了对微小、多发病灶的准确定位与清晰分离，针对实测场景中存在的复杂天线互耦与硬件噪声问题，DL–TSVD展现出了优异的跨域泛化能力。实测定量评估表明，DL–TSVD重构图像的SSIM达到0.541，MSE低至0.166，相较于传统的8天线标准TSVD方法，分别提升了174.62%和降低了37.36%。

综上所述，本研究构建方法不仅在算法机理上实现了向高可信、物理可解释性模型的演进，更在不增加任何射频硬件资源与系统复杂度的前提下提升了成像质量。本研究成果为微波脑成像设备向低成本、小型化、高分辨率方向的临床应用发展提供了一定的理论路径与技术参考。本研究仍存在一定局限性，当前的物理仿体主要基于均匀背景介质，而真实人脑包含高阻抗颅骨、脑脊液等强异质多层结构，限制了系统对病变绝对介电常数值的精细重建，进而影响高精度的脑卒中鉴别诊断。后续研究将进一步引入真实人脑三维高逼真度模型，开展样本的泛化性验证。

利益冲突：作者声明没有利益冲突。

[参 考 文 献]

[1] 中华医学会神经病学分会, 中华医学会神经病学分会脑血管病学组. 中国重症卒中管理指南2024[J]. 中华神经科杂志, 2024, 57(7): 698–714.
[2] 国家卫生健康委加强脑卒中防治工作减少百万新发残疾工程专家委员会.《2024年中国脑卒中防治报告》概要[J]. 首都医科大学学报, 2025, 46(6): 947–960.
[3] 刘延华. 颅脑CT血管成像在急性缺血性脑卒中诊断及预后中的应用价值[J]. 中外医学研究, 2024, 22(6): 64–67.
[4] 廖萌, 谢明国. 缺血性脑卒中辨证分型与MRI病变部位相关性的Meta分析[J]. 中西医结合心脑血管病杂志, 2024, 22(8): 1389–1394.
[5] Fazli R, Momeni H. Microwave imaging of small scatterers by MUSIC algorithm using a novel source number detection method[J]. Progress in Electromagnetics Research C, 2022, 127: 145–156.
[6] Vanhari R A, Bakhtafrouz A, Noghanian S. Performance analysis of iterative methods in microwave imaging with various regularization techniques[J]. IEEE Open Journal of Antennas and Propagation, 2024, 5(6): 1523–1538.
[7] Zhang X, Du N, Wang J, et al. Improving the imaging performance of microwave imaging systems by exploiting virtual antennas[J]. IEEE Transactions on Microwave

（下转第67页）

长为6个月，设备寿命延长效果、长期不良事件发生率等远期指标尚无法评估，未来需开展更长周期的追踪研究以验证该模式的持续效益[15]。

综上所述，与传统管理模式相比，中医诊疗设备全生命周期质量管理模式通过覆盖采购验收、日常监控、预防维护及报废更新的全流程系统性管控，有效降低了设备故障率、闲置率及不良事件发生率，同时提高了设备完好率、预防性维护执行率及患者临床总有效率，设备运行效能得到改善。未来可进一步探索人工智能预测性维护技术与设备信息化管理平台的深度融合，推动中医诊疗设备管理向智能化、精准化方向持续发展。

利益冲突：作者声明没有利益冲突。

[参 考 文 献]

[1] 张广华. 医院医疗设备全生命周期信息化管理的常见问题与改进对策[J]. 中国新通信, 2024, 26(7): 37–39, 42.

[2] 周俏俏, 路婧. 基于UDI的物联网技术在医疗器械全生命周期信息化管理的应用现状[J]. 中国医疗设备, 2024, 39(6): 161–167.

[3] 程静. 基于全生命周期管理理念的医疗设备信息管理系统[J]. 中国医疗器械杂志, 2024, 48(3): 319–322, 338.

[4] 张洁, 郭冠南, 朱水成, 等. 基于DIKW模型的医院大型医疗设备全生命周期管理智慧决策路径研究[J]. 中国医学装备, 2025, 22(12): 103–108.

[5] 《中医病证诊断疗效标准》[J]. 湖北中医杂志, 2002(2): 57.

[6] 苏辉强, 庄云龙, 陈向君, 等. 医院医疗器械设备全生命周期管理的优化策略[J]. 中国医疗器械信息, 2025, 31(19): 152–155.

[7] 杨盛林, 夏德习, 崔涛, 等. 医疗器械设备的全生命周期管理体系构建[J]. 中国医疗器械信息, 2025, 31(15): 13–15, 25.

[8] 刘炜, 何铁. 医疗设备的全生命周期管理问题探讨与优化对策研究[J]. 中国设备工程, 2025(11): 100–102.

[9] 刘剑龙. 基于信息化管理系统的医疗设备全生命周期管理研究[J]. 中国医疗器械信息, 2025, 31(9): 153–155.

[10] 林董怡, 金宁茹. 关于公立医院医疗设备全生命周期管理的研究[J]. 中国设备工程, 2025(7): 140–142.

[11] 汤国平, 周庆利. 基于预算的医疗设备全生命周期质量管理[J]. 现代医院管理, 2023, 21(4): 100–103.

[12] 卢倩, 杨国平, 钟靓. 提高医疗设备使用效益和成本管控水平的探索：基于设备全生命周期管理理论[J]. 现代医院, 2023, 23(7): 1082–1085.

[13] 吴平凤, 姚辉, 林建勋, 等. 智慧医院医疗设备全生命周期管理系统构建与评价研究[J]. 中国医学装备, 2023, 20(6): 149–155.

[14] 王月波, 周鹰, 王卓, 等. 医院资源规划系统在医疗设备全生命周期信息化管理中的效果分析[J]. 中国医学装备, 2023, 20(5): 153–158.

[15] 伍兴思. PDCA循环在医疗设备全生命周期管理中的应用价值[J]. 中国设备工程, 2023(2): 38–40.

（上接第17页）

Theory and Techniques, 2024, 72(10): 5734–5744.

[8] Takemoto R, Cha J, Jeong I, et al. Effectiveness and characteristics of virtual antennas in the multiple signal classification algorithm[J]. Electronics, 2025, 14(1): 73.

[9] Yago Ruiz Á, Cavagnaro M, Crocco L. An effective framework for deep–learning–enhanced quantitative microwave imaging and its potential for medical applications[J]. Sensors, 2023, 23(2): 643.

[10] Hu X, Xu F, Guo Y, et al. MDLI–Net: model–driven learning imaging network for high–resolution microwave imaging with large rotating angle and sparse sampling[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5212617.

[11] Guo L, Khosravi–Farsani M, Stancombe A, et al. Adaptive clustering distorted born iterative method for microwave brain tomography with stroke detection and classification[J]. IEEE Transactions on Biomedical Engineering, 2022, 69(4): 1512–1523.

[12] Park W K. MUSIC algorithm for imaging small anomaly from scattering parameter: real–data experiments[C]//2018 Progress in Electromagnetics Research Symposium (PIERS–Toyama). Piscataway: IEEE, 2018: 2362–2364.

[13] Tobon Vasquez J A, Scapaticci R, Turvani G, et al. A prototype microwave system for 3D brain stroke imaging[J]. Sensors, 2020, 20(9): 2607.

[14] Rodriguez–Duarte D O, Tobon Vasquez J A, Scapaticci R, et al. Experimental validation of a microwave system for brain stroke 3–D imaging[J]. Diagnostics, 2021, 11(7): 1232.

[15] Zhang Z, Liu H, Li F, et al. Interpolation–weighted TSVD for sparse array microwave tomography[J]. Electronics, 2026, 15(6): 1212.

[16] Lu P, Kosmas P. Three–dimensional microwave head imaging with GPU–based FDTD and the DBIM method[J]. Sensors, 2022, 22(7): 2691.

[17] Ni S, Zhang Z, Li R, et al. Investigation of the dielectric properties for brain and blood phantoms[C]//2025 10th International Conference on Computer and Communication System (ICCCS). Piscataway: IEEE, 2025: 372–376.

[18] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600–612.