

## 基于深度卷积自编码器的微波成像方法及其医学应用潜力

邓煌森, 刘捷, 闫炼, 朱光正, 宁旭, 秦明新, 陈明生  
陆军军医大学生物医学工程与影像医学系, 重庆 400038

**【摘要】**开发一个基于深度学习的微波成像模型,将散射电场直接映射为目标物体介电特性分布图像,并探索其在医学应用的潜在价值。采用二维时域有限差分法进行数值模拟来获取散射电场数据集;构建基于深度卷积自编码器成像模型,对两类目标物体进行成像研究;使用相对误差进行成像结果的定量评估,并分析成像模型对不同卒中类型的区分能力。结果表明基于深度卷积自编码器的成像网络在处理两种数值模型时均展现出出色的成像性能。对于简单物体,该模型能准确定位并初步重建物体形状,平均相对误差为0.3012;对于卒中模型,能较好地重建卒中区域的位置和形状,初步重建其他脑组织,平均相对误差为0.0778。基于深度卷积自编码器的微波成像网络对快速准确重建图像很有前景,脑卒中检测的数值示例表明该方法在生物医学成像领域具有显著的应用潜力。

**【关键词】**脑卒中;微波成像;深度学习;卷积自编码器

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2025)02-0184-06

### Microwave imaging method based on deep convolutional autoencoder and its potential for medical application

DENG Huangsen, LIU Jie, YAN Lian, ZHU Guangzheng, NING Xu, QIN Mingxin, CHEN Mingsheng

School of Biomedical Engineering and Medical Imaging, Army Medical University, Chongqing 400038, China

**Abstract:** A deep learning based microwave imaging model which can directly map the scattered electric field to the dielectric property distribution image of the target object is developed, and its potential for medical applications is explored. The two-dimensional time-domain finite difference method is used for numerical simulation to obtain a dataset of scattered electric fields; a deep convolutional autoencoder based imaging model is constructed to perform imaging studies on two types of target objects; the imaging results are quantitatively evaluated using relative error, and the model's ability to distinguish different types of strokes is also analyzed. The results show that the imaging network based on deep convolutional autoencoder exhibits excellent imaging performance when processing both numerical models. For simple objects, the model can accurately locate and preliminarily reconstruct the shape of the object, with an average relative error of 0.3012, while for the stroke models, it can effectively reconstruct the location and shape of the stroke area, and preliminarily reconstruct other brain tissues, with an average relative error of 0.0778. The microwave imaging network based on deep convolutional autoencoder has great promise for fast and accurate image reconstruction, and the numerical example of stroke detection demonstrates its significant application potential in biomedical imaging.

**Keywords:** stroke; microwave imaging; deep learning; convolutional autoencoder

### 前言

微波成像是一种新兴的成像技术,用于重建目标区域内物体的介电特性(介电常数和电导率)分布。通常在成像区域周围放置天线阵列,向目标物

体发送电磁波,同时测量电磁波穿透或反射后发生变化的散射数据,通过有效的算法分析测量散射数据,从而估计物体的介电参数分布图像<sup>[1]</sup>。在微波频率下,人体不同组织展现出不同的介电特性,并且病变组织与正常组织之间存在较大介电特性差异,这使得微波成像用于人体检测变得可行<sup>[2]</sup>。微波成像技术具有无创、非电离辐射和快速便携的优点,在医疗诊断应用中有重要潜力。当前微波成像在乳腺癌筛查<sup>[3]</sup>、脑血管疾病诊断<sup>[4]</sup>和治疗监测<sup>[5]</sup>等领域得到广泛关注。从数学角度看,微波成像的反演过程可以视作求解逆散射问题,这被认为是一个高度非线性

**【收稿日期】**2024-07-22

**【基金项目】**国家自然科学基金(62171444)

**【作者简介】**邓煌森,硕士,研究方向:脑卒中微波成像和电磁检测, E-mail: Chris\_324@163.com

**【通信作者】**陈明生,博士,副教授,研究方向:智能脑损伤电磁检测, E-mail: chenms83@163.com

性且具有病态性的逆问题<sup>[6]</sup>。目前,解决微波成像反演问题的方法主要包括雷达成像<sup>[7-8]</sup>和微波层析成像<sup>[9-10]</sup>,但它们各自存在局限性。例如,雷达成像虽然成像速度快,但成像精度低;微波层析成像需要大量迭代计算,十分耗时,不适用于实时重建。

随着计算能力的持续增强和大数据处理能力的不断提升,深度学习技术在计算机科学和工程应用等多领域迅速发展。利用特定数据集训练神经网络模型,深度学习可被广泛应用于执行特定的功能或任务,尤其在计算机视觉领域,深度学习在图像分类<sup>[11]</sup>和图像分割<sup>[12]</sup>方面取得显著的成就。卷积神经网络(Conventional Neural Network, CNN)是深度学习中一种主流的算法架构,其卷积操作具有卓越的特征提取能力,有效减少模型需要学习的参数量<sup>[13]</sup>。CNN的引入使得深度学习能构建更深、更广的网络结构,从而有效处理大规模数据集并解决复杂的问题。有研究利用深度学习处理非线性病态性逆问题,在信号去噪<sup>[14]</sup>、信号恢复<sup>[15]</sup>和反卷积<sup>[16]</sup>等精确模型的逆问题领域取得了令人印象深刻的成果。面对

微波成像的逆散射问题,深度学习展现出作为一种强大的非线性求解工具的潜力,提供一种计算高效且可靠的解决方案。

本研究提出一种基于深度学习的微波成像模型来解决非线性逆散射问题,对所开发的模型进行测试,在两种合成数据集(圆柱体和大脑模型)中展现出有前景的结果,并探究其在脑卒中检测方面应用的潜力。

1 资料与方法

1.1 研究流程

首先,通过模拟仿真来获取目标物体的散射电场数据,设定两种类型的数值模型:简单圆柱体和具有不同位置与大小的卒中模型,并对仿真数据进行预处理,制备后续训练的数据集。接着,搭建一个深度自编码网络模型(Deep Conventional Autoencoder Network, DCAN),对其进行训练和测试。最后,采用相对误差(Relative Error, RE)来评价成像模型的重建质量(图1)。

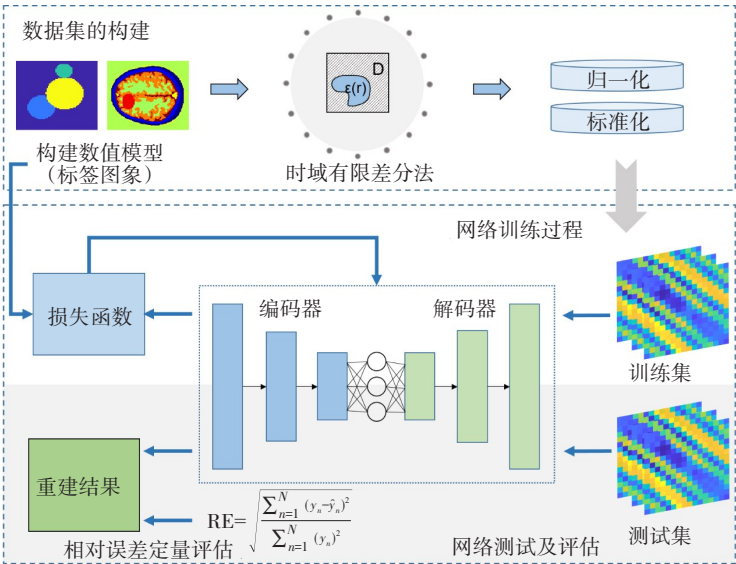


图1 基于深度卷积自编码器微波成像网络构建流程图

Figure 1 Flowchart of microwave imaging network construction based on deep convolutional autoencoder

1.2 数据的获取

**1.2.1 简单圆柱体的数值模拟** 随机生成 500 个半径、数量和位置各异的圆柱体图像。介电常数设置为 1~7,数量限定在 1~3,随机生成的圆柱体半径为 0.15~0.4 cm,允许圆柱体之间的重叠。在模拟仿真中,圆柱体被放置在成像区域的中心,周围以 100 mm 为半径的圆中均匀放置 16 个天线,天线同时作为发

射器和接收器。使用时域有限差分法在 800 MHz 下进行数值模拟(仅考虑二维的情况),共得到 16×16×500 个数据集。仿真在包含 48 个核的 2 个 Intel(R) Xeon(R) Gold 高性能 CPU 和 NVIDIA Quadro RTX 5000 GPU 的工作站上于 20 min 内完成。

**1.2.2 卒中模型的数值模拟** 引入具有解剖学结构的数值脑模型<sup>[17]</sup>,并选择切片 36,大小为 128×128。所

选切片包含6种组织:皮肤、脂肪、颅骨、脑脊液、灰质和白质,对不同组织赋予相应的介电常数<sup>[18]</sup>。生成随机位置和大小椭圆作为中风嵌入切片36来构建脑卒中模型,共生成2 000张脑卒中图像。其中出血性卒中的介电常数与血液(血液介电常数61.7)相同,缺血性卒中的介电常数(缺血组织介电31.400 8)低于正常组织的10%<sup>[19]</sup>。前向过程采用时域有限差分求解器实现。使用高性能工作站实现卒中模型模拟仿真(仿真过程耗时约12 h)。数据获取的过程均在MATLAB 2023a中实现。

### 1.3 网络结构和训练

#### 1.3.1 网络结构

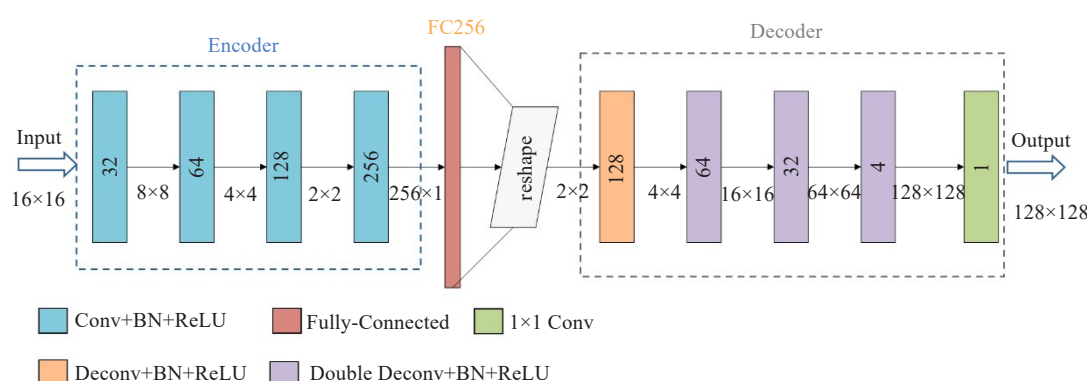


图2 深度卷积自编码器网络结构图

Figure 2 Structure of deep convolutional autoencoder network

1.3.2 网络训练过程 对散射数据和介电常数图像进行归一化处理,让网络训练更容易收敛。两个数据集都按照9:1的比例拆分成训练集和测试集。在网络训练过程中,数据批量大小为16,初始学习率设为0.002,采用Adam优化器优化网络参数,动量参数设置为 $\beta_1=0.9$ 和 $\beta_2=0.999$ 。使用早停机制,在5次epoch后损失没有明显改变时停止训练。选用均方差损失(Mean Square Error, MSE)函数训练网络,公式如下:

$$MSE = \frac{\sum_{m=1}^M \sum_{n=1}^N (y - \hat{y})^2}{M \times N} \quad (1)$$

其中, $M$ 为单次批量大小, $N$ 为总像素点个数, $y$ 为标签图像, $\hat{y}$ 为网络重建结构。另外,如果网络参数和损失函数没有较大改动,最多50个epoch训练网络。代码均基于PyTorch深度学习框架编写,并在工作站中开展网络训练。

#### 1.4 评价指标

为检验网络重建介电常数分布的精确性,使用RE来定量分析。RE是衡量实际测量值和预测值之间差异的度量,其定义如下:

Net<sup>[20]</sup>结构进行修改,得到本研究的成像网络。DCAN结构可以分为编码器、全连接层和解码器(图2)。编码器能对输入的散射场进行编码压缩、细化特征信息,其结构是由4组卷积、批量归一化和校正线性单元的模块组成,其中每个模块的卷积层均是2D卷积运算,步长为2,卷积核大小为 $2 \times 2$ 。在编码器和解码器中用全连接层作为中间连接层,包含256个神经元。解码部分是上采样的过程,逐层重组编码器细化的特征信息,最终重构脑卒中对比度图像。解码器包含7组上卷积、批量归一化和校正线性单元的模块,并在末端使用 $1 \times 1$ 的卷积层。7组模块中上卷积均使用2D反卷积,卷积核大小为 $2 \times 2$ ,步长为2。

$$RE = \sqrt{\frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{\sum_{n=1}^N (y_n)^2}} \quad (2)$$

其中, $N$ 是重建图像的像素总数, $\hat{y}_n$ 为网络重建的电气特性分布图像, $y_n$ 为标签图像的电气特性分布图像。

## 2 结果

### 2.1 简单物体的成像示例

如图3所示,DCAN对随机生成的圆柱体的成像结果的6个示例,每个示例均能在1 s内重建完成。实验1和实验3分别为含有不同介电常数的单一圆柱体,其位置和尺寸各不相同;实验2、实验5和实验6则为不同数量、随机大小和位置的圆柱体相互重叠的情况;实验4则包含多个未重叠的圆柱体。从图中可以看出,模型在目标物体的定位方面表现出较好的能力。通过使用RE对6个示例及整个测试集进行定量分析,图3中的示例的RE值范围为0.282 1~0.406 9,总测试集的平均RE值为0.301 2。具体来看,实验1



和实验3的RE分别为0.275 2和0.282 1,结合图3的可视化结果可发现,模型对介电常数较大的圆柱体具有更好的成像效果。对于实验2、实验5和实验6,其RE值分别为0.371 7、0.398 1和0.406 9;由图3及

RE分析可以得出,圆柱体重叠边界越复杂,模型的成像效果越差。值得注意的是,实验4的RE值为0.393 5,高于实验2;结合图3可知,对于低介电常数且尺寸较小的物体,模型的成像难度较大。

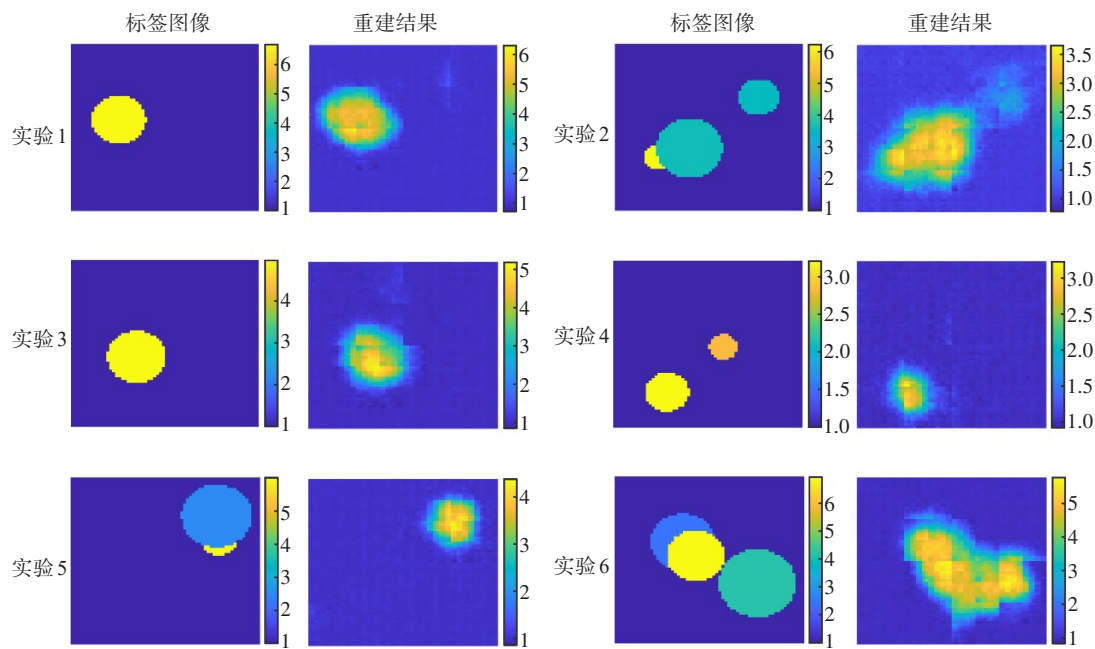


图3 成像模型对简单物体的重建结果

Figure 3 Reconstruction results of simple objects using the imaging model

2.2 脑卒中成像的实例

采用200个未参与训练的散射电场信号数据集用于验证训练后网络的性能。在图4中,展示了4个代表性测试的重建结果,每个测试均在1 s内完成。图4第1列显示了不同程度和位置的卒中图像。为探究网络实现“异构”重建的中间过程,更直观地理解网络如何捕捉特征去重构卒中图像,给出神经网络训练1个epoch(图4第2列)和10个epoch(图4第3列)时的测试重构结果,可以看出网络在训练1个epoch时已能较好地重构大脑轮廓,但其组织边界不清晰且未能重建出血的位置和大小;训练10个epoch后,DCAN能开始重建卒中区域,但重构出血区域仍较模糊。图4第4列为网络最终训练后(训练50个epoch)的测试结果。实验7~实验10重建结果的RE为0.072 8~0.079 6,总体测试集的RE为0.077 8。上述结果表明所设计的DCAN能较好重建卒中图像。

出血性和缺血性卒中在发病机制上差异很大,不同类型的卒中需要提供对应的治疗方案。因此在卒中检测的应用中,区分出血性和缺血性卒中是至关重要的。本研究使用所提模型对区分卒中类型进行训练和测试,其测试结果如图5所示。DCAN能较

好重构出血性卒中,不仅能准确定位出血性卒中,也能较好重建出血区域的大小;但对缺血性卒中的重构质量还有待提高,虽然能较准确地定位缺血位置,但是对于缺血区域的大小和形状无法重构完全。

3 讨论

由于微波成像问题具有高度的非线性和病态性,传统上常用非迭代和迭代的优化算法来解决这类逆问题。其中,非迭代算法在处理高介电常数的物体时往往不能提供满意的成像结果;而迭代算法虽然能提供较高的成像精度,但涉及复杂的数学计算且耗时长。鉴于此,深度学习技术以其出色的非线性求解能力被引入微波成像领域,作为一种新的解决微波成像逆散射问题的工具,以提高成像精度<sup>[21-24]</sup>。本研究采用基于深度卷积自编码器的成像方法进行微波成像研究,这种方法实现了从测量的散射电场到直接重建介电常数图像的端到端学习。与传统需计算非齐次格林函数的方法不同,基于深度学习的方法无需考虑目标域与测量域之间的复杂关系,从而简化了计算过程。深度网络的学习参数被用于模拟解决非线性逆问题,将优化算法的迭代

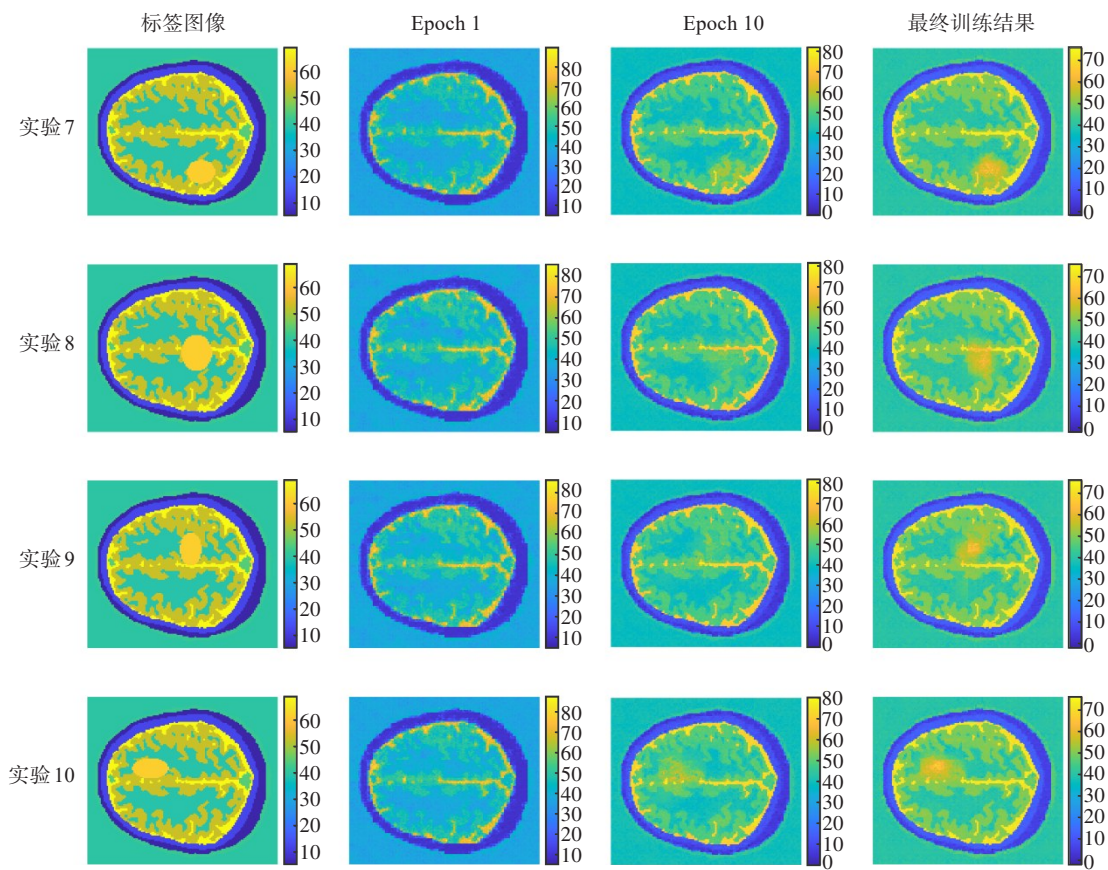


图 4 不同训练时期和最终训练后网络对卒中模型的成像结果

Figure 4 Imaging results of the stroke model at different training stages and after final training

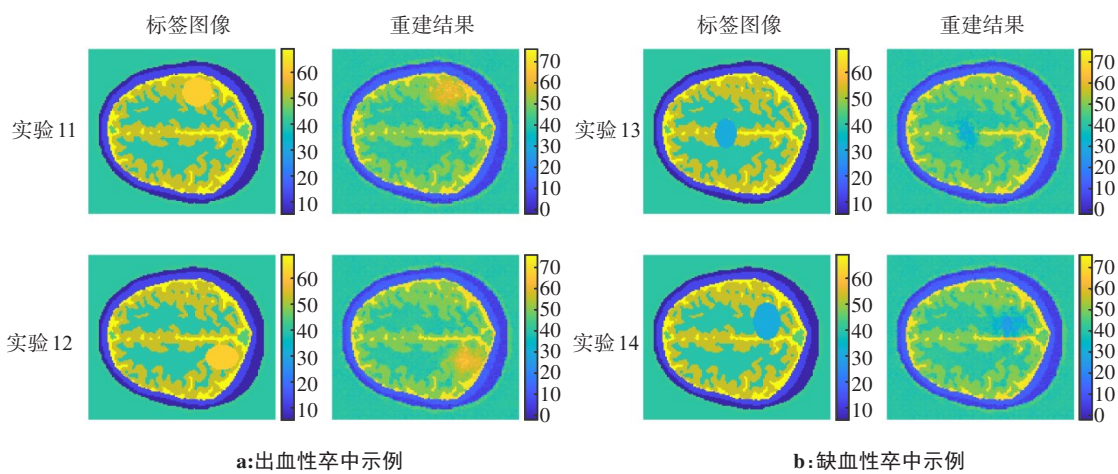


图 5 出血性和缺血性卒中中的成像结果

Figure 5 Imaging results for hemorrhagic and ischemic strokes

过程转化为网络训练过程,避免复杂的数学运算。基于深度学习的成像方法展示了在实时高精度微波成像问题上的巨大潜力。

目前,检测卒中的主要成像技术包括 CT 和 MRI<sup>[25]</sup>。这两种技术虽能提供高精度的成像结果,但它们各有局限:CT 存在电离辐射风险,不适合用于持续监测;MRI 设备成本高昂且体积庞大,难以实现便

携。与之相比,微波成像技术由于其非电离性、低成本和便携性的特点,在卒中的及时检测和实时监测中展现出独特的优势。微波成像技术已被广泛应用于研究脑卒中的成像和检测,主要采用基于畸变波恩迭代算法和对比源反演算法框架的迭代方法<sup>[26-28]</sup>。这些传统迭代方法在成像效果有待进一步提高,且耗时较长,在缺血性卒中的成像重建上效果不佳。



鉴于此,本研究探索了基于深度学习的微波成像方法,此方法不仅能准确定位卒中区域,还能提供比传统方法更准确的卒中尺寸重建结果。实验证明基于深度学习的方法在成像质量上获得了更好的成像质量,且能在1 s内完成重建。此外,相较于传统方法,基于深度学习的方法在重建缺血性卒中方面表现更佳,这对区分不同类型的卒中并精准重建缺血区域具有重要价值。

本研究虽在基于深度学习的微波成像方法中取得一定进展,但仍存在局限性:(1)目前使用的简单物体和卒中模型数据集规模较小,样本的多样性不足,这对于依赖大量数据进行训练的深度学习方法而言,样本量不足以支撑训练出较好的结果,为此,未来研究将增加不同人体头部模型切片,以丰富数据集的多样性。(2)尽管所提出的深度学习方法在卒中重建方面相较于传统方法有所改善,但成像精度仍有待进一步提高。(3)本研究主要关注脑实质卒中的成像,未涉及其他常见类型的卒中,今后的工作将结合临床,对其他常发性卒中进行定量成像研究。(4)目前的研究结果主要基于数值模拟的研究,尚未进行进一步的实验验证。

综上所述,基于深度卷积自编码器的微波成像方法展现了其在医学应用中的潜力,能更快速地对卒中进行成像检测,为未来基于深度学习的脑卒中微波成像方法的研究和应用提供实验基础。

## 【参考文献】

- [1] Afsari A, Abbosh AM, Rahmat-Samii Y. Modified born iterative method in medical electromagnetic tomography using magnetic field fluctuation contrast source operator[J]. IEEE Trans Microw Theory Tech, 2019, 67(1): 454-463.
- [2] Akazzim Y, Jofre M, El Mrabet O, et al. UWB-modulated microwave imaging for human brain functional monitoring[J]. Sensors (Basel), 2023, 23(9): 4374.
- [3] 郭东昊. 基于MICF-DMAS算法的乳腺癌微波共焦成像技术研究[D]. 济南: 山东师范大学, 2024.  
Guo DH. Research on microwave confocal imaging of breast cancer based on MICF-DMAS algorithm[D]. Ji'nan: Shandong Normal University, 2024.
- [4] Huang YJ, Feng QK, Huang L. Thermoacoustic imaging: from single-element scanning to portable and array-based imaging[J]. J Electron Sci Technol, 2023, 21(3): 100209.
- [5] Smith K, Bourqui J, Wang ZF, et al. Microwave imaging for monitoring breast cancer treatment: a pilot study[J]. Med Phys, 2023, 50(11): 7118-7129.
- [6] Costa Batista A, Batista LS, Adriano R. A quadratic programming approach for microwave imaging[J]. IEEE Trans Antennas Propag, 2021, 69(8): 4923-4934.
- [7] Naghibi A, Attari AR. Near-field radar-based microwave imaging for breast cancer detection: a study on resolution and image quality[J]. IEEE Trans Antennas Propag, 2021, 69(3): 1670-1680.
- [8] Gupta A, Kumar Yadav S, Durai C, et al. Enhanced breast tumor localization with DRA antenna backscattering and GPR algorithm in microwave imaging[J]. Results Eng, 2024, 24: 103044.
- [9] 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 RX. Research on microwave imaging technology of stroke detection based on improved contrast source inversion algorithm[J]. Transactions of Beijing Institute of Technology, 2022, 42(10): 1097-1104.
- [10] 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 Trans Biomed Eng, 2022, 69(4): 1512-1523.
- [11] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks[J]. Commun ACM, 2017, 60(6): 84-90.
- [12] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2014: 580-587.
- [13] Xu YS, Zhang HZ. Convergence of deep convolutional neural networks[J]. Neural Netw, 2022, 153: 553-563.
- [14] Wang HH, Wang YH, Wang X, et al. A novel deep-learning model for RDTs signal denoising based on down-sampling and convolutional neural network[J]. J Lightwave Technol, 2022, 40(12): 3647-3653.
- [15] Huijben IA, Veeling BS, Janse K, et al. Learning sub-sampling and signal recovery with applications in ultrasound imaging[J]. IEEE Trans Med Imaging, 2020, 39(12): 3955-3966.
- [16] Liu CW, Sun MY, Dai NX, et al. Deep learning-based point-spread function deconvolution for migration image deblurring[J]. Geophysics, 2022, 87(4): S249-S265.
- [17] Qureshi AM, Mustansar Z. Levels of detail analysis of microwave scattering from human head models for brain stroke detection[J]. PeerJ, 2017, 5: e4061.
- [18] Gabriel S, Lau RW, Gabriel C. The dielectric properties of biological tissues: II. Measurements in the frequency range 10 Hz to 20 GHz[J]. Phys Med Biol, 1996, 41(11): 2251-2269.
- [19] Semenov S, Huynh T, Williams T, et al. Dielectric properties of brain tissue at 1 GHz in acute ischemic stroke: experimental study on swine[J]. Bioelectromagnetics, 2017, 38(2): 158-163.
- [20] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(12): 2481-2495.
- [21] Zhang HH, Yao HM, Jiang LJ, et al. Solving electromagnetic inverse scattering problems in inhomogeneous media by deep convolutional encoder-decoder structure[J]. IEEE Trans Antennas Propag, 2023, 71(3): 2867-2872.
- [22] Zhang HH, Yao HM, Jiang LJ, et al. Enhanced two-step deep-learning approach for electromagnetic-inverse-scattering problems: frequency extrapolation and scatterer reconstruction[J]. IEEE Trans Antennas Propag, 2023, 71(2): 1662-1672.
- [23] 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 (Basel), 2023, 23(2): 643.
- [24] Liu JZ, Chen LM, Xiong H. An encoder-decoder and modified U-Net network for microwave imaging of stroke[J]. Int J Imaging Syst Technol, 2024, 34(2): e22995.
- [25] Löfblad KO, Altrichter S, Mendes Pereira V, et al. Imaging of acute stroke: CT and/or MRI[J]. J Neuroradiol, 2015, 42(1): 55-64.
- [26] Sun SL, Kooij BJ, Jin T, et al. Cross-correlated contrast source inversion[J]. IEEE Trans Antennas Propag, 2017, 65(5): 2592-2603.
- [27] Sun SL, Dai DH, Wang XS. A fast algorithm of cross-correlated contrast source inversion in homogeneous background media[J]. IEEE Trans Antennas Propag, 2023, 71(5): 4380-4393.
- [28] Mousavi SS, Majedi MS. A modified microwave imaging method for brain stroke detection[J]. IEEE Trans Antennas Propag, 2024, 72(1): 890-900.

(编辑:谭斯允)