



## 基于条件去噪扩散模型的电阻抗/ 微波双模态成像算法研究\*

刘近贞<sup>1,2)\*\*</sup> 孟祥骞<sup>1,2)</sup> 熊 慧<sup>1,2)</sup> 周李敏<sup>1,2)</sup> 李春婵<sup>3)</sup>

<sup>(1)</sup> 天津工业大学控制科学与工程学院, 天津 300387; <sup>(2)</sup> 天津工业大学天津市电气装备智能控制重点实验室, 天津 300387;

<sup>(3)</sup> 天津工业大学工程实训中心, 天津 300387)

**摘要** 目的 脑卒中具有高发病率与高致残率, 病灶的精准检测是临床救治的关键。电阻抗成像 (electrical impedance tomography, EIT) 与微波成像 (microwave tomography, MWT) 作为非侵入、无电离辐射的生物医学成像技术, 在床旁实时监测与快速筛查中具备显著优势。然而, 单一模态面临成像精度低、信息单一的问题, 难以满足临床精准检测的需求。因此, 开展电阻抗与微波双模态成像研究具有重要意义。**方法** 为实现电阻抗和微波信息有效融合, 提出双模态融合条件去噪扩散模型 (dual-modality fusion conditional denoising diffusion probabilistic model, DM-DDPM), 通过构建双编码器网络, 分别提取EIT边界电压的信息与MWT散射场的深层介电特性信息, 借助注意力特征融合实现异构特征的有效融合, 生成互补融合先验。引入交叉注意力机制将融合先验数据作为条件, 引导基于Transformer的扩散模型进行反向去噪, 以实现电导率分布的高精度重构。**结果** 所提算法在不同噪声水平下均保持优异性能, 在信噪比为 30 dB 的噪声环境下, 该算法的平均相对误差降低至 0.20 以下, 结构相似度和相关系数分别保持在 0.90 和 0.89 以上。相较单模态算法及多模态算法, 伪影显著减少、病灶边缘更清晰、定位更准确。实物实验中, 算法可有效抑制环境噪声与系统干扰, 实现模拟病灶精准重建, 验证了实际应用可行性。**结论** 该算法将双模态信息与条件去噪扩散模型结合, 既解决单模态成像精度低、抗噪性差的问题, 又避免多模态数据直接融合的噪声放大缺陷, 实现了对不同数量脑卒中病灶的精准定位, 为脑卒中检测提供了可靠的技术支撑。

**关键词** 脑卒中, 电阻抗成像, 微波成像, 多模态融合, 条件去噪扩散模型, 图像重建

中图分类号 R318.0, Q64

DOI: 10.3724/j.pibb.2026.0031

CSTR: 32369.14.pibb.20260031

脑卒中作为一种高发病率和高死亡率的疾病, 准确检测病灶大小和位置对临床治疗至关重要<sup>[1]</sup>。电阻抗成像 (electrical impedance tomography, EIT) 与微波成像 (microwave tomography, MWT) 作为非侵入式医学成像技术, 凭借其非电离辐射、便携及实时成像等优势, 在临床诊断领域极具潜力<sup>[2-3]</sup>。EIT利用电导率差异, 通过电极阵列的激励与测量反演组织的电导率分布, 已应用于脑卒中检测<sup>[4]</sup>、肺部成像<sup>[5]</sup>等生物医学领域。MWT基于组织电特性差异引发的微波吸收与反射变化, 反演目标区域的复介电常数分布<sup>[6]</sup>, 为病灶检测提供了另一种重要的技术路径。单一模态的成像存在明显局限。EIT的“软场”特性使其对深层组织敏感性不足, MWT的逆散射问题的非线性

则易产生伪影<sup>[7]</sup>, 影响成像精度。针对单一物理场成像存在的问题, 研究者开始探索将不同物理机制的成像技术进行融合。

多模态成像技术通过有机整合同源或异源成像技术所获取的多维度信息, 旨在克服单一模态在空间分辨率或物理敏感度上的固有不足。多模态成像技术主要有两种类型, 第一种是先验信息法, 利用一个模态的成像结果作为先验信息来指导另一个模态的图像重建过程, 以此来提高成像质量。Li等<sup>[8]</sup>利用计算机断层扫描 (computer tomography, CT) 图像作为空间先验和正则化项来指导 EIT 重

\* 国家自然科学基金 (62401390) 资助项目。

\*\* 通讯联系人。

Tel: 022-83955415, E-mail: liujinzen@163.com

收稿日期: 2026-01-21, 接受日期: 2026-04-24

建。Fogel 等<sup>[9]</sup> 利用超声获取低分辨率的重建图像, 将其转换为复介电常数, 并将其作为先验信息应用于 MWT。Liang 等<sup>[10]</sup> 将超声成像得到的位置信息作为先验信息指导 EIT 重建, 并通过约束最小二乘法对不同模态信息进行融合。第二种方法是独立重建融合法, 即先独立重建各模态图像, 再通过信息融合技术将其结合, 生成最终图像。Khoshdel 等<sup>[11]</sup> 提出基于 U-Net 架构的卷积神经网络重建介电常数的实部和虚部的乳房图像, 并提出与微波和超声双模态结合的成像方法。Lin 等<sup>[12]</sup> 提出解纠缠变分自编码器 (disentangled variational autoencoder, DVAE) 解耦电阻抗、微波和超声层析成像的结构与数值特征, 结合不同模态的图像信息, 提高了肿瘤检测的准确性。尽管能充分利用多模态互补特征, 但若原始数据中存在较多噪声干扰, 会导致噪声在融合过程中被放大, 最终影响成像精度。

去噪扩散概率模型 (denoising diffusion probabilistic models, DDPM) 凭借其强大的概率建模能力及优异的抗噪性能, 在医学图像重建领域得到广泛关注<sup>[13]</sup>。与传统深度学习方法相比, DDPM 通过迭代去噪过程逐步细化图像细节。DDPM 已被用于 EIT 的图像重建问题<sup>[14]</sup>, 不同于

传统 EIT 重建方法依赖正问题建模与正则化约束以缓解不适定性, 可借助 DDPM 对电导率分布进行建模, 结合电压数据作为先验条件, 通过去噪过程逐步还原高精度的图像。

基于此, 本文提出一种用于脑卒中检测的电阻抗/微波双模态融合的条件去噪扩散模型 (dual-modality fusion conditional denoising diffusion probabilistic model, DM-DDPM)。该模型通过双编码器网络提取特征并生成融合先验信息。通过交叉注意力机制将融合先验嵌入基于 Transformer 的条件去噪扩散模型完成去噪过程。既避免了原始数据噪声在网络前端的放大, 又通过融合先验信息让 DDPM 的去噪过程始终受双模态物理信息的引导, 最终实现脑卒中中的高精度、高鲁棒性的图像重建。

## 1 实验方法

### 1.1 EIT 与 MWT 的数学模型

采用相邻电极激励模式进行 EIT 测量, 在被测物体边界均匀布置 16 个电极, 通过对电极阵列依次注入低频电流激励信号, 利用相邻电极采集边界电压数据, 可获取 208 个边界电压数据, 图 1 为 EIT 系统的简化模型。




Fig. 1 Simplified model of the EIT system

由于激励电流频率较低, 介电常数的影响可忽略不计, 电流场可视为稳态场。将人体颅脑形状简化为包含目标区域的均匀背景介质, 建立二维求解域  $\Omega$ 。基于麦克斯韦方程组, 电势  $\varphi$  与电导率  $\sigma$  的分布满足:

$$\nabla \cdot (\sigma(r) \nabla \varphi(r)) = 0, r \in \Omega \quad (1)$$

在此模型中, 电势分布和电导率分布的边界条件表示为:

$$\varphi(r) = \varphi_i(r), r \in \Omega' \quad (2)$$

$$\sigma(r) \frac{\partial \varphi(r)}{\partial n} = j_n(r), r \in \Omega' \quad (3)$$

$\varphi_i$  为被测边界电位分布,  $n$  为边界外法向量,  $j_n$  为电极注入的电流密度,  $\Omega'$  为被测场域的边界。采用有限元法对方程进行数值求解, 能够在电极布局 and 测量条件已知的情况下, 准确地模拟电流激励下的电位分布。

对于微波成像, 其数学模型也是基于麦克斯韦方程组, 核心是建立介质的电磁参数与散射电磁场

之间的关系。图2为16个天线均匀分布，依次照射被测场域 $\Omega$ ，照射后的散射场通过物体周围的16个接收天线来依次测量，获得256个电场强度。




Fig. 2 Configuration of the 16 antennas in the MWT system

对横磁波 (transverse magnetic wave, TM wave) 的二维电磁散射问题研究<sup>[15]</sup>。电磁源向 $\Omega$ 发送TM波，并在切面 $S$ 上构建标量积分方程，内部的散射场满足：

$$E^s(r) = k_b^2 \int_S G(r, r') \chi(r') E^s(r') (dr'), r \in S \quad (4)$$

其中， $E^s$ 是接收天线测得的散射电场， $E^s$ 是域 $S$ 中的总电场， $k_b$ 是背景波数， $S$ 是散射体的横截面。 $r' = (x', y')$ 是待测场域中的源点， $r = (x, y)$ 是天线的位位置向量。对比度函数 $\chi(r)$ 表示为：

$$\chi(r) = \frac{\varepsilon_r(r)}{\varepsilon_b} - 1 - j \frac{\sigma_r(r) - \sigma_b}{\omega \varepsilon_b} \quad (5)$$

其中， $\varepsilon_r$ 和 $\sigma_r$ 分别是病灶的相对介电常数和电导率， $\varepsilon_b$ 和 $\sigma_b$ 是背景介质的介电常数和电导率， $\omega$ 是入射电场的角频率。背景波数 $k_b$ 为：

$$k_b = \omega \sqrt{\varepsilon_0 \mu_0} \quad (6)$$

对于TM波，Dyadic Green函数可以用第二类汉克尔函数表示为：

$$G(r, r') = -\frac{jk_b^2}{4} H_0^{(2)}(k_b |r - r'|) \quad (7)$$

其中， $H_0^{(2)}$ 是第二类汉克尔函数，表示散射源与接收点之间的电磁场传播特性。基于上述数学模型，用时域有限差分法进行数值求解，获取待测场域的电磁场值，从而解决电磁正散射问题。

## 1.2 电阻抗/微波双模态成像方法基础

EIT和MWT分别在低频和高频范围内工作，探测不同的物理特性。EIT的逆问题是在已知边界

电压变化，求解被测场域的电导率分布，表示为公式(8)。MWT的逆散射问题是指通过已知散射电场的变化，来重构被测场域的复介电常数分布，表示为公式(9)。

$$\Delta V = J_1 \sigma \quad (8)$$

$$\Delta E = J_2 \chi \quad (9)$$

式中， $\Delta V$ 是EIT的边界测量电压， $\sigma$ 是待重建的介质电导率分布， $J_1$ 是电学灵敏度矩阵。 $\Delta E$ 是MWT测量的电场强度， $\chi$ 是待重建的介质对比度分布， $J_2$ 是电磁灵敏度矩阵。

测量相同被测场域的逆问题的数学模型为：

$$\begin{cases} \Delta V = J_1 \sigma \\ \Delta E = J_2 \chi \end{cases} \quad (10)$$

若 $x_1$ 为通过EIT模态测量得到的被测物体的位置， $x_2$ 为通过MWT模态测量得到的被测物体的位置，当双模态测量的目标位置相同时， $x_1 = x_2 = x$ 。假设 $\sigma$ 和 $\chi$ 到 $x$ 的映射满足：

$$\begin{cases} \sigma = f_1(x) \\ \chi = f_2(x) \end{cases} \quad (11)$$

将式(11)带入式(10)为：

$$\begin{cases} \Delta V = J_1 f_1(x) \\ \Delta E = J_2 f_2(x) \end{cases} \quad (12)$$

求解(12)，将单模态方程转化为双模态的统一模型：

$$y = g(x) \quad (13)$$

其中， $y$ 为双模态测量值， $g(\cdot)$ 为双模态测量值与重建目标位置的映射函数。

将两种模态结合可以利用低频与高频信息，捕获不同频段的电磁特性，实现了电导率与复介电常数的同步重构，可以解决单模态成像中因组织异质性导致的逆问题病态性。EIT和MWT均以组织的电特性为重建目标，可采用统一的算法实现数据融合。不需要直接求解耦合方程，通过损失函数迭代优化，最小化预测数据和正问题求解出的计算数据之间的误差。

$$Loss = \frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2 \quad (14)$$

式中， $y'_i$ 是预测数据， $y_i$ 是真实数据， $N$ 是被测场域的剖分单元数。

## 1.3 扩散模型

扩散模型是一种概率生成模型，是模拟分子扩散的规律，通过双向马尔可夫链结构，模拟“数据添加噪声-噪声还原数据”的过程。前向扩散过程

通过  $T$  个步长向原始数据逐步添加高斯噪声。利用重参数化, 任意时刻  $t$  的数据  $x_t$  可由原始数据  $x_0$  结合预定义的噪声调度参数  $\beta_t \in (0, 1)$  直接得到<sup>[13]</sup>,

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon \quad (15)$$

其中,  $\alpha_t = 1 - \beta_t$ ,  $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$ ,  $t = 1, 2, \dots, T$ ,  $\alpha_t = 1 - \beta_t$ ,  $\epsilon$  为高斯噪声, 随着  $t$  增加,  $x_t$  逐步趋于随机噪声。

反向过程从随机噪声  $x_t$  开始, 通过  $T$  步去噪重建原始数据。由于该过程的分布不可直接计算, 通常利用神经网络  $\epsilon_\theta$  来拟合噪声预测模型, 进而近似逼近反向分布的均值  $\mu_\theta$ , 即:

$$\mu_\theta = \frac{1}{\sqrt{\alpha_t}} \left( x_t - \frac{1 - \alpha_t}{\sqrt{1 - \alpha_t}} \epsilon_\theta(x_t, t) \right) \quad (16)$$

去噪过程是基于马尔可夫链实现, 即当前时间步的分布仅与前一时间步的分布有关, 无需依赖更早的数据。在模型完成第  $t$  步噪声预测后, 可通过逆转正向加噪过程, 反推出前一时间步  $t - 1$  的  $x_{t-1}$

分布, 即,

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} x_t - \frac{\sqrt{1 - \alpha_t}}{\sqrt{\alpha_t}} \epsilon_\theta(x_t, t) \quad (17)$$

通过逐步去噪, 模型能够从高斯噪声中恢复出高精度的电导率分布图像。

## 2 电阻抗/微波双模态融合的条件去噪扩散模型

DM-DDPM 网络可分为两大核心模块: 双模态特征融合预处理模块、基于条件去噪扩散模型的图像重建模块, 整体网络如图 3 所示。采用双编码器网络, 分别提取 EIT 的边界电压信息与 MWT 的散射场信息, 生成具有电导率分布特征与介电常数分布特征的融合先验信息。将这一先验信息作为条件, 引导基于 Transformer 的条件去噪扩散模型生成高精度电导率图像, 整个架构通过递进式设计, 充分发挥双模态信息的互补性与扩散模型的生成能力, 最终实现高精度的图像处理。




Fig. 3 Structure of DM-DDPM network

## 2.1 双编码器网络

双编码器网络是实现双模态信息特征提取与融合的核心，两分支结构对称但参数独立，确保能针对性地适配不同模态信号的特性。EIT分支输入电极测量的边界电压数据，通过一维卷积映射至高维特征空间，MWT分支输入为天线阵列接收的散射场数据，通过卷积块提取特征。编码层结构由3个卷积块与3个最大池化层组成，每个卷积块均采用“卷积层+BatchNorm+ReLU激活函数”的堆叠结构，增强特征表达能力并加速训练收敛。最大池化层用于下采样，实现特征图尺寸的减半与感受野的扩大。两个分支在瓶颈层进行深度融合，采用注意力特征融合（attentional feature fusion, AFF）<sup>[16]</sup>，将不同模态的信息自适应融合，生成融合特征，最大化地利用两种模态内部信息之间的关系。解码器经上采样及跳跃连接保留细节，最终输出同时编码了电导率与介电常数分布信息的初步融合结果。该阶段的作用并非直接得到最终电导率重建结果，而是作为条件引导信息，为后续扩散模型提供先验。

## 2.2 条件去噪扩散模型框架

DDPM是从随机高斯噪声开始反向去噪，既缺乏物理信息约束易生成虚假结构，又存在采样效率低的问题。为此，DM-DDPM模型引入条件约束机制，将预处理得到的初步成像结果嵌入扩散过程，实现双模态信息的深度融合与高精度成像。与无条件扩散模型仅依赖当前时刻进行去噪预测不同，条件去噪扩散模型在每一步反向去噪时，加入条件约束使去噪过程不仅依赖于当前噪声图像 $x_t$ 和时间步 $t$ ，更重要的是充分融合了双模态先验信息。

交叉注意力机制被用于实现电压数据与散射场数据的双模态融合，通过将双模态特征作为条件信息引入网络，对噪声预测过程进行约束。该机制在特征交互过程中能够有效挖掘不同模态之间的结构先验与物理关联。进行多次交叉注意力运算，强化输入数据与网络内在表征的深度融合，使网络在去噪的各个阶段均能感知双模态信息，从而提升对输入数据的判别能力。在此基础上，扩散模型不仅能够遵循其固有的概率生成过程，还能够生成与多模态数据一致的重建结果。如图4所示，交叉注意力机制计算融合得到的融合信息和电导率分布之间的关系，通过动态计算不同模态数据间的权重，实现信息的选择性融合。这种设计使得扩散模型在生成电导率分布时，不仅依赖统计先验，还能够显式地受双模态成像结果引导，避免无物理意义的解。




Fig. 4 Cross attention mechanism

## 2.3 位置嵌入

扩散模型的网络本身不具备时序感知能力，无法区分不同时间步 $t$ ，因此需对网络各层输出的特征张量引入时间步嵌入操作，将离散的时间步转化为高维连续向量，把扩散过程的时间步信息传入网络，使其精准感知当前所处的去噪阶段，进而指导噪声预测任务。采用Embedding层实现时间步 $t$ 的可学习向量表示，该策略能够自适应图像的去噪特征分布。具体为：首先构建形状为 $(100, D)$ 的嵌入字典（ $D$ 为嵌入维度），字典中每个时间步 $t(t \in [1, 100])$ 对应一个随机初始化的 $D$ 维向量，训练过程中，模型根据当前时间步 $t$ 调取对应的 $D$ 维嵌入向量，与卷积输出的特征张量在通道维度逐通道相加，完成时间步信息的嵌入。

## 2.4 基于Transformer的去噪网络

针对DDPM模型采用U-Net结构存在的局部依赖，而Transformer的自注意力机制可有效建模全局特征关联，提升成像精度<sup>[17]</sup>。因此，设计基于Transformer的U-Net网络作为电导率的特征提取和噪声去除，该网络保留U-Net的编码-解码与跳跃连接结构，将原有的卷积块替换为Transformer块，实现局部特征与全局特征的协同提取，噪声预测网络如图5所示。

Transformer块主要包括注意力计算块、残差结构、层归一化块和多层感知块（multilayer perceptron, MLP），具体结构如图6所示。将噪声电导率信息与条件融合结果进行特征嵌入，并通过位置编码引入空间结构信息，利用自注意力机制对全局特征进行建模，使网络能够在去噪过程中同时关注整体电导率分布与局部异常区域。




Fig. 5 Structure of the noise prediction network




Fig. 6 Transformer block

仿真数据集。采用COMSOL Multiphysics对颅脑模型进行建模, 并对其计算区域进行三角形网格剖分, 制作成含有345个节点和636个单元的有限元数据(图7)。随机选择14 000个电学样本和14 000个微波样本用于训练网络模型, 在输入网络前进行归一化处理, 按照8:1:1将数据集划分为互不重叠的训练集、验证集和测试集。为了简化实验, 将病灶区域的介电常数设定为37.87, 电导率设定为0.75 S/m, 脑组织的介电常数设定为55.60, 电导率为1.89 S/m。




Fig. 7 Finite element mesh of the head model

### 3 数据集构建与评价指标

#### 3.1 构建数据集

在多模态图像融合研究中, 由于EIT与MWT相关公开数据集匮乏, 因此, 本研究需要自行构建

#### 3.2 评价指标

训练网络的损失函数是每个像素的真实标签和预测标签之间的均方误差。训练过程采用固定学习率0.001, 并使用Adam优化器进行网络参数的更

新。网络模型的搭建使用Pytorch2.4框架，并使用NVIDIA GeForce RTX 4060 GPU (CUDA 11.8) 进行训练，训练周期为1 000 epoch，批量尺寸为64。

为评估所提出网络的图像重建性能，采用相对误差 (relative error, RE)、相关系数 (correlation coefficient, CC)、结构相似性指数 (structure similarity index measure, SSIM) 作为定量评价指标。

相对误差衡量重建图像与实际图像的差异，重建图像是否光滑，评估成像质量：

$$RE = \sqrt{\frac{\sum_i^N (x_i - y_i)^2}{\sum_i^N (y_i)^2}} \quad (18)$$

相关系数反映重建图像和实际图像之间的相关性：

$$CC = \frac{\sum_i^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i^N (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (19)$$

SSIM是用于衡量重建图像与实际图像之间相似度的指标，考虑了亮度、对比度和结构三个方面的相似性：

$$SSIM = \frac{(2\bar{x}\bar{y} + C_1)(2\sigma_{xy} + C_2)}{(\bar{x}^2 + \bar{y}^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (20)$$

其中， $x$ 和 $y$ 分别是重建图像和真实图像。 $\bar{x}$ 和 $\bar{y}$ 是两个图像的均值。 $\sigma_x^2$ 和 $\sigma_y^2$ 是两个图像的方差。 $\sigma_{xy}$ 是两个图像的协方差。 $C_1$ 和 $C_2$ 代表两个常数。

## 4 实验结果与分析

为了验证算法的图像生成能力和抗噪声能力，设计了仿真数据的对比实验和实测数据的对比实验来验证算法的可行性。

### 4.1 生成能力分析

通过增加时间步可提升网络的噪声预测精度。图8显示了重建图像的质量随着时间步的增加而提高，DM-DDPM网络在100个时间步具有非常好的效果，该模型基本能够在前50步中初步构建出目标的几何形状与轮廓。在60~100个时间步中，一般目标位置和尺寸趋于稳定，目标位置处的伪影逐渐减小，背景逐渐清晰。后期迭代主要是进一步优化电导率的预测值，提高图像重建精度。在80到100个时间步的过程中，增加时间步有助于消除伪影并增强网络泛化能力与稳定性。图9中，测试集中的样本在迭代70次后的SSIM和CC指标能达到0.99，RE也低于0.01。




Fig. 8 Reconstructed images at 100 steps




Fig. 9 Variation of metrics with iteration

### 4.2 抗噪性能验证

为了验证所提出DM-DDPM成像算法的性能，将所提出的方法与U-Net网络<sup>[18]</sup>、DiffusionEIT<sup>[14]</sup>、DiffusionMWT以及MDRANet<sup>[19]</sup>进行了对比。U-Net网络采用经典的编码器-解码器对称架构，通过层级卷积提取局部特征，并利用跳跃连接融合高低层特征，实现端到端映射。DiffusionEIT是基于单模态电阻抗成像的扩散模型，利用DDPM对电导率分布建模，将电压数据作为条件先验，通过逐步去噪过程还原图像。DiffusionMWT是基于单模态微波成像的扩散模型。MDRANet是一种多模态融合网络，采用双分支结构提取不同模态特征，经多尺度密集模块对提取的特征进行层间拼接，最后对深度特征解码生成融合图像。

此外，为了评估所提出算法的抗噪性能，添加信噪比 (signal-to-noise ratio, SNR) 为50、40和30 dB的高斯白噪声进行比较。所有方法使用相同的数据集进行训练，并对测试集添加噪声进行性能验证。

图 10~12 显示了图像重建结果, 针对不同病灶数量, DM-DDPM 在成像精度与鲁棒性上均优于对比网络, 能够更好地重建病灶的位置、大小和形状。U-Net 能够在一定程度上识别目标的位置和大小。随着噪声的增加, 会出现大范围的伪影。DiffusionEIT 在低噪声的情况下, 相较于其他网络的成像效果较好, 但加入噪声导致病灶的部分缺失, 抗噪性能较差。DiffusionMWT 在 30 dB 的噪

声下, 仍存在较多噪声, 去噪效果不佳。DM-DDPM 整合 EIT 与 MWT 的互补信息, 克服单模态数据局限性, 比单模态图像重建方法可利用的信息更加丰富与全面, 从而提升图像的质量。在双模态信息融合的过程中, 会引入冗余和冲突信息, 导致重建效果下降。相比 MDRANet, DM-DDPM 能够有效利用互补信息的同时避免冲突信息的干扰, 得到高质量的图像。




Fig. 10 Comparison of reconstructed images of single-target under different noise conditions




Fig. 11 Comparison of reconstructed images of double-target under different noise conditions




Fig. 12 Comparison of reconstructed images of triple-target under different noise conditions

表 1~3 显示了算法对脑卒中重建的平均  $RE$ 、平均  $CC$  和平均  $SSIM$  的计算结果, 可以看出 DM-DDPM 对 3 个测试样本的重建质量相较于其他网络模型有显著提升。40 dB 和 30 dB 噪声干扰下的重建图像  $SSIM$  均高于 0.90,  $CC$  均高于 0.89,  $RE$  均低于 0.20, 明显优于对比方法, 证明了网络的优越性。在 30 dB 的噪声下, 相较于单一 EIT 模态

DiffusionEIT,  $SSIM$  平均提高了 23.66%, 与单一 MWT 模态 DiffusionMWT 相比,  $RE$  平均提高 19.99%。表明双模态融合的重建结果的鲁棒性和重建精度远高于单一模态。DM-DDPM 在  $RE$ 、 $CC$ 、 $SSIM$  上的优异表现, 对应图 10~12 中伪影更少、边缘更清晰、目标结构更准确。

**Table 1 Metrics of single-target under different noise conditions**

| Algorithm    | SNR=50 dB |         |         | SNR=40 dB |         |         | SNR=30 dB |         |         |
|--------------|-----------|---------|---------|-----------|---------|---------|-----------|---------|---------|
|              | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  |
| U-Net        | 0.080 5   | 0.955 2 | 0.700 1 | 0.120 5   | 0.943 6 | 0.627 7 | 0.607 2   | 0.467 0 | 0.631 3 |
| DiffusionEIT | 0.007 8   | 0.988 9 | 0.943 5 | 0.066 7   | 0.948 8 | 0.953 5 | 0.243 8   | 0.855 1 | 0.891 0 |
| DiffusionMWT | 0.103 6   | 0.973 6 | 0.759 7 | 0.203 5   | 0.897 5 | 0.608 1 | 0.439 1   | 0.422 6 | 0.481 7 |
| MDRANET      | 0.049 5   | 0.978 0 | 0.717 1 | 0.105 1   | 0.966 1 | 0.694 8 | 0.320 3   | 0.418 4 | 0.693 7 |
| DM-DDPM      | 0.006 2   | 0.993 1 | 0.956 9 | 0.046 1   | 0.983 2 | 0.947 8 | 0.185 1   | 0.897 8 | 0.911 4 |

**Table 2 Metrics of double-target under different noise conditions**

| Algorithm    | SNR=50 dB |         |         | SNR=40 dB |         |         | SNR=30 dB |         |         |
|--------------|-----------|---------|---------|-----------|---------|---------|-----------|---------|---------|
|              | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  |
| U-Net        | 0.103 1   | 0.972 0 | 0.719 7 | 0.189 2   | 0.927 1 | 0.699 6 | 0.485 2   | 0.798 8 | 0.631 0 |
| DiffusionEIT | 0.140 1   | 0.981 0 | 0.966 5 | 0.093 3   | 0.981 2 | 0.958 8 | 0.540 0   | 0.821 4 | 0.543 2 |
| DiffusionMWT | 0.364 0   | 0.854 7 | 0.975 0 | 0.087 4   | 0.984 3 | 0.940 4 | 0.574 1   | 0.807 1 | 0.633 4 |
| MDRANET      | 0.066 5   | 0.988 5 | 0.850 5 | 0.065 8   | 0.986 8 | 0.848 9 | 0.721 3   | 0.565 6 | 0.550 4 |
| DM-DDPM      | 0.000 5   | 0.999 7 | 0.987 3 | 0.004 2   | 0.997 2 | 0.960 2 | 0.127 3   | 0.942 2 | 0.905 6 |

**Table 3 Metrics of triple-target under different noise conditions**

| Algorithm    | SNR=50 dB |         |         | SNR=40 dB |         |         | SNR=30 dB |         |         |
|--------------|-----------|---------|---------|-----------|---------|---------|-----------|---------|---------|
|              | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  | $RE$      | $CC$    | $SSIM$  |
| U-Net        | 0.092 0   | 0.997 9 | 0.873 4 | 0.178 7   | 0.983 1 | 0.890 4 | 0.337 4   | 0.924 5 | 0.652 1 |
| DiffusionEIT | 0.000 5   | 0.999 4 | 0.995 5 | 0.150 6   | 0.992 1 | 0.698 1 | 0.206 1   | 0.894 7 | 0.684 4 |
| DiffusionMWT | 0.000 6   | 0.999 6 | 0.994 3 | 0.139 0   | 0.994 2 | 0.723 6 | 0.224 1   | 0.853 6 | 0.667 5 |
| MDRANET      | 0.044 1   | 0.998 9 | 0.928 8 | 0.160 9   | 0.994 4 | 0.703 5 | 0.378 1   | 0.965 4 | 0.463 5 |
| DM-DDPM      | 0.000 8   | 0.999 5 | 0.998 5 | 0.059 7   | 0.993 4 | 0.946 4 | 0.106 2   | 0.969 4 | 0.902 8 |

针对不同目标物数量的重建结果表明, DM-DDPM 在各类场景下表现出优越的重建性能。与单模态网络相比, DM-DDPM 能够整合更丰富的电磁特性信息, 从而提升了图像重建质量。多模态融合可能引入冗余信息, 导致重建效果下降, DM-DDPM 将双模态融合结果作为条件先验而非直接融合原始数据, 既避免了原始数据噪声在融合前端的放大, 又提升了特征融合的针对性, 重建图像的伪影更少、边缘更清晰。

### 4.3 实物实验

为了验证 DM-DDPM 算法在真实环境下的可行性, 构建实物实验系统测量数据。如图 13a 所

示, EIT 数据采集系统由数据采集卡 (NI USB-6281)、4 个 16 通道多路复用器 (ADG1606) 组成的开关阵列、电流源、导线、16 个电极以及电脑组成。MWT 数据采集系统由矢量网络分析仪 VNA (Aglient E5071C)、两个频段为 0.8~2.5 GHz 的超宽带天线、同轴电缆、定位底座及电脑组成 (图 13b)。发射天线固定不动, 接收天线旋转一周, VNA 记录接收天线的 S 参数。

传感器数量的选取直接影响成像分辨率与计算效率, 参考现有研究<sup>[20-21]</sup>, 本研究在双模态成像系统中均配置 16 个传感器。由于电极夹会对 MWT 系统的微波信号采集产生电磁干扰, 导致接收的散

射场数据无法准确表征待测区域的介电特性, 因此实物实验采用异步采集完成双模态数据获取, 两次采集过程中保持水槽、目标物的位置完全固定, 确保双模态数据为同一场景的配对数据。




**Fig. 13 Comparison of physical experimental results**  
(a) EIT data acquisition system. (b) MWT data acquisition system.

测量区域为参照成年人标准颅脑轮廓设计的水槽模型, 外部尺寸为长约 22 cm、宽约 20 cm。盐水作为背景导电介质模拟正常脑组织, 其对应的电导率约为 1.6 S/m, 相对介电常数约为 75。选用绝缘亚克力块模拟脑卒中病灶区域, 利用二者在电导率、相对介电常数上的显著差异形成高对比度, 用于突出成像系统对异常区域的响应能力。在水槽中随机放置 1~3 个亚克力圆柱, 模拟不同病灶的分布情况。

实物实验受测量系统、环境等因素影响, 存在

较强的噪声干扰, 图 14 所示为算法的图像重建结果。U-Net 重建的病灶不清晰且存在较大伪影, DiffusionEIT 和 MDRANet 的重建图像有所改善, 但前者受单模态信息局限, 后者因双模态融合机制未能有效抑制冗余干扰, 导致病灶附近仍存在伪影, DM-DDPM 可实现病灶的精准定位, 且重建图像的伪影显著减少, 通过迭代去噪自适应地过滤掉测量中的随机噪声, 有效提升了成像的抗干扰能力, 充分验证了 DM-DDPM 算法在实际应用中的可行性与优越性。




**Fig. 14 Comparison of physical experimental results**

5 结 论

针对脑卒中检测中 EIT 与 MWT 单模态存在的成像精度低、伪影明显等问题, 提出一种电阻抗/

微波 DM-DDPM。该模型采用双编码器提取双模态特征并生成融合先验, 将融合先验通过交叉注意力机制嵌入扩散模型的去噪过程, 并使用 Transformer 块增强全局特征关联。通过仿真数据

与实物实验的对比, DM-DDPM在不同场景中均表现优异, 50 dB 信噪比下的  $RE$  均低于 0.006 2,  $SSIM$  均高于 0.956 9, 在 30 dB 低信噪比下  $RE$  仍控制在 0.185 1 以下,  $SSIM$  保持在 0.905 6 以上。与对比方法相比实现了更平滑的图像重建以及准确的目标物位置表达。该算法能够准确重建病灶的数量与位置, 并具备良好的抗噪性能。

虽然 DM-DDPM 方法能够完成高水平的图像重建, 但仍有改进空间。模型的背景与目标电导率相对单一, 在接下来的研究中可以尝试增加颅脑模型的复杂度, 构建更贴近临床真实场景的头模型, 进一步提升实际应用价值。

### 参 考 文 献

- [1] Sperber C, Gallucci L, Mirman D, *et al.* Stroke lesion size - Still a useful biomarker for stroke severity and outcome in times of high-dimensional models. *Neuroimage Clin*, 2023, **40**: 103511
- [2] 白世展, 李文胜, 林海军, 等. 基于径向基函数神经网络的肺部加权频差电阻抗成像方法. *生物化学与生物物理进展*, 2023, **50**(7): 1755-1766  
Bai S Z, Li W S, Lin H J, *et al.* *Prog Biochem Biophys*, 2023, **50**(7): 1755-1766
- [3] 邓煌森, 刘捷, 闫炼, 等. 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. *中国医学物理学杂志*, 2025, **42**(2): 184-189  
Deng H S, Liu J, Yan L, *et al.* *Chin J Med Phys*, 2025, **42**(2): 184-189
- [4] Toivanen J, Kolehmainen V, Paldanius A, *et al.* Graph convolutional networks enable fast hemorrhagic stroke monitoring with electrical impedance tomography. *IEEE Trans Biomed Eng*, 2026, **73**(2): 851-861
- [5] Kircher M, Elke G, Stender B, *et al.* Regional lung perfusion analysis in experimental ARDS by electrical impedance and computed tomography. *IEEE Trans Med Imaging*, 2021, **40**(1): 251-261
- [6] Fear E C. Microwave imaging of the breast. *Technol Cancer Res Treat*, 2005, **4**(1): 69-82
- [7] Bertero M, Boccacci P, De MoI C. Introduction to Inverse Problems in Imaging. 2nd Ed. Boca Raton: CRC Press, 2021
- [8] Li Z, Zhang J, Liu D, *et al.* CT image-guided electrical impedance tomography for medical imaging. *IEEE Trans Med Imaging*, 2020, **39**(6): 1822-1832
- [9] Fogel H, Hughson M, Asefi M, *et al.* Generation of prior information in a dual-mode microwave-ultrasound breast imaging system. *Sensors (Basel)*, 2022, **22**(18): 7087
- [10] Liang G, Ren S, Dong F. Ultrasound guided electrical impedance tomography for 2D free-interface reconstruction. *Meas Sci Technol*, 2017, **28**(7): 074003
- [11] Khoshdel V, Ashraf A, LoVetri J. Enhancement of multimodal microwave-ultrasound breast imaging using a deep-learning technique. *Sensors (Basel)*, 2019, **19**(18): 4050
- [12] Lin Z, Guo R, Zhang K, *et al.* Tri-modal joint inversion based on disentangled variational autoencoder for human thorax imaging. *IEEE Trans Instrum Meas*, 2023, **72**: 4506912
- [13] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 2020, **33**: 6840-6851
- [14] Liu J, Shi F, Xiong H, *et al.* DiffusionEIT: diffusion model for electrical impedance tomography. *IEEE Trans Instrum Meas*, 2024, **73**: 4509209
- [15] Costa Batista A, Batista L S, Adriano R. A quadratic programming approach for microwave imaging. *IEEE Trans Antennas Propag*, 2021, **69**(8): 4923-4934
- [16] Dai Y, Gieseke F, Oehmcke S, *et al.* Attentional feature fusion// Medioni G. 2021 IEEE Winter Conference on Applications of Computer Vision (WACV), Waikoloa, HI, USA: IEEE, 2021: 3559-3568
- [17] Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need// Luxburg U V, Guyon I, Bengio S, *et al.* *Advances in Neural Information Processing Systems*: 30. Red Hook: Curran Associates, 2017: 5998-6008
- [18] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation//Navab N, Hornegger J, Wells W M. *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. Cham: Springer, 2015: 234-241
- [19] Fu J, Li W, Peng X, *et al.* MDRANet: a multiscale dense residual attention network for magnetic resonance and nuclear medicine image fusion. *Biomed Signal Process Control*, 2023, **80**: 104382
- [20] 宋振忠, 张素勤, 杨懿铄, 等. 利用 Gauss-Newton 算法探究电极数对 EIT 重建图像质量的影响. *国外电子测量技术*, 2024, **43**(11): 44-49  
Song Z Z, Zhang S Q, Yang Y S, *et al.* *Foreign Electron Meas Technol*, 2024, **43**(11): 44-49
- [21] Abbosh Y M, Sultan K, Guo L, *et al.* Non-uniform antenna array for enhanced medical microwave imaging. *Sensors (Basel)*, 2025, **25**(10): 3174

## Research on Electrical Impedance and Microwave Dual-modality Tomography Algorithm Based on Conditional Diffusion Models\*


LIU Jin-Zhen<sup>1,2)\*\*</sup>, MENG Xiang-Qian<sup>1,2)</sup>, XIONG Hui<sup>1,2)</sup>, ZHOU Li-Min<sup>1,2)</sup>, LI Chun-Chan<sup>3)</sup>

<sup>(1)</sup>The School of Control Science and Engineering, Tiangong University, Tianjin 300387, China;

<sup>2)</sup>Key Laboratory of Intelligent Control of Electrical Equipment, Tiangong University, Tianjin 300387, China;

<sup>3)</sup>Engineering Training Center, Tiangong University, Tianjin 300387, China)

### Graphical abstract



**Abstract Objective** Stroke poses a heavy burden due to its high mortality and morbidity rates. Accurate and real-time detection of lesions is pivotal for prompt clinical intervention and favorable prognosis. Electrical impedance tomography (EIT) and microwave tomography (MWT) have emerged as compelling alternatives for stroke screening, owing to their non-ionizing, non-invasive and portable nature. EIT provides information on tissue conductivity, and MWT offers high sensitivity to changes in dielectric properties. However, single-modality

\* This work was supported by a grant from The National Natural Science Foundation of China (62401390).

\*\* Corresponding author.

Tel: 86-22-83955415, E-mail: liujinzen@163.com

Accepted: January 21, 2026 Accepted: April 24, 2026

imaging is inherently limited, EIT suffers from low sensitivity to deep-seated tissues and severe ill-posedness of inverse problems, whereas MWT is challenged by strong nonlinearity in inverse scattering and susceptibility to modeling errors. Consequently, the clinical utility of standalone EIT or MWT for stroke diagnosis remains constrained by poor spatial resolution and imaging artifacts. To improve the accuracy and robustness of stroke imaging, a dual-modality fusion conditional denoising diffusion probabilistic model (DM-DDPM) was proposed for high-precision dual-modality image reconstruction. **Methods** A dual-encoder network with a symmetric architecture and independently trained parameters was constructed to extract heterogeneous features separately from EIT boundary voltage measurements and MWT scattered field signals. Attentional feature fusion (AFF) is employed to integrate complementary information from the two modalities adaptively, generating robust fused priors that suppress redundant noise while preserving key physical characteristics. Subsequently, the fused priors are embedded into a Transformer-based diffusion model *via* a cross attention mechanism to guide the reverse denoising process. This approach effectively reduces artifacts and enhances the stability of conductivity distribution reconstruction. Time step embedding is introduced to enable the network to perceive the diffusion stage and further improve the accuracy of noise prediction. **Results** Simulated experiments demonstrated that DM-DDPM significantly outperforms single-modality and multi-modality networks under various noise levels. A head model simulation dataset was constructed based on COMSOL Multiphysics, and tests were carried out under 50 dB, 40 dB and 30 dB signal-to-noise ratio levels. At 30 dB, the average relative error (*RE*) was below 0.20, while the structural similarity index measure (*SSIM*) and correlation coefficient (*CC*) remained above 0.90 and 0.89, respectively. Compared with single-modality and multi-modality networks, artifacts were significantly reduced, lesion edges were clearer, and localization was more accurate. The model maintains high reconstruction quality and strong robustness for single, double, and triple lesions simultaneously. Furthermore, physical experiments were conducted using a 16-electrode EIT system and a 16-antenna MWT system with asynchronous data acquisition. These experiments confirmed the feasibility of the method in real-world scenarios and demonstrated that it can robustly reconstruct simulated lesions despite environmental interference and measurement noise, validating its reliability for practical clinical applications. **Conclusion** The proposed method effectively combines complementary dual-modality information with a conditional diffusion model. Low accuracy and poor noise resistance in single-modality imaging were effectively addressed, while the noise amplification issue caused by direct multimodal data fusion was avoided. The proposed algorithm exhibits strong anti-noise interference ability and high imaging stability in both simulation and physical experiments. Precise localization of stroke lesions with different quantities was achieved, providing a high-precision, and practical technical support for clinical stroke detection.

**Key words** stroke, electrical impedance tomography (EIT), microwave tomography (MWT), multimodal fusion, conditional diffusion model, image reconstruction

DOI: 10.3724/j.pibb.2026.0031

CSTR: 32369.14.pibb.20260031