

DOI: 10.3969/j.issn.1671-024x.2026.02.010

基于改进 CycleGAN 网络的电磁层析成像算法

李秀艳^{1,2}, 虞坤^{1,2}, 王琦^{2,3}, 张荣华⁴

(1. 天津工业大学 电子与信息工程学院, 天津 300387; 2. 天津工业大学 天津市光电检测技术与系统重点实验室, 天津 300387; 3. 天津工业大学 生命科学学院, 天津 300387; 4. 天津工业大学 人工智能学院, 天津 300387)

摘要: 为解决电磁层析成像(electromagnetic tomography, EMT)图像重建中由于逆问题的高度非线性、不适定导致重建图像容易产生伪影的问题, 提出了一种用于 EMT 图像重建的深度学习网络——带注意机制的循环生成对抗网络(CycleGAN-AM)。该网络由 2 个 GAN 网络构成, 通过双生成器、双鉴别器可以捕捉更多的非线性特征; 在生成器中使用全局注意力(GAM)来学习信道依赖关系, 提高了 CycleGAN-AM 的准确性和可解释性。通过仿真和金属检测实验评估了本文所提出算法的性能。成像结果表明: CycleGAN-AM 能够准确地恢复被测对象的边界, 并且可对新的电导率分布(尺寸/数量变化的被测对象)和噪声干扰下的被测对象进行有效的重建; 与传统的智能学习方法相比, CycleGAN-AM 可使成像精度提升 10% 以上。

关键词: 电磁层析成像; 图像重建算法; 深度学习; CycleGAN 网络

中图分类号: TP391.4

文献标志码: A

文章编号: 1671-024X(2026)02-0077-09

Electromagnetic tomography algorithm based on improved CycleGAN network

Li Xiuyan^{1,2}, Yu Kun^{1,2}, Wang Qi^{2,3}, Zhang Ronghua⁴

(1. School of Electronic and Information Engineering, Tiangong University, Tianjin 300387, China; 2. Tianjin Key Laboratory of Optoelectronic Detection Technology and Systems, Tiangong University, Tianjin 300387, China; 3. School of Life Sciences, Tiangong University, Tianjin 300387, China; 4. School of Artificial Intelligence, Tiangong University, Tianjin 300387, China)

Abstract: In order to solve the problem that reconstructed images in electromagnetic tomography (EMT) are prone to artefacts due to the highly nonlinear and ill-posed of the inverse problem, a deep learning structure namely cycle generative adversarial network with attention mechanism (CycleGAN-AM) is proposed for EMT image reconstruction. The network consists of two GAN networks, which can capture more nonlinear features through dual generators and dual discriminators. The use of global attention mechanism (GAM) in the generator to learn channel dependencies improves the accuracy and interpretability of CycleGAN-AM. The performance of the algorithm proposed in this paper is evaluated by simulation and metal detection experiments. The imaging results show that CycleGAN-AM is able to accurately recover the boundaries of the objects under test and can effectively reconstruct the objects under new conductivity distributions (objects of varying sizes/numbers) and noise interference. Compared with traditional intelligent learning methods, CycleGAN-AM can improve the imaging accuracy by more than 10%.

Key words: electromagnetic tomography; image reconstruction algorithm; deep learning; CycleGAN network

电磁层析成像(electromagnetic tomography, EMT)作为一种新的过程断层成像技术, 与耗时且具有放射性的计算机断层扫描(computed tomography, CT)和磁

共振成像(magnetic resonance imaging, MRI)不同, 因其成本低、反应快、实时无创监测、安装方便、使用安全等优点, 在工业、化学、生物医药、金属缺陷检测等领

收稿日期: 2024-03-14

基金项目: 国家自然科学基金项目(62071328)

通信作者: 李秀艳(1981—), 女, 博士, 副教授, 主要研究方向为图像处理和模式识别、电学成像技术。E-mail: lixiuyan@tiangong.edu.cn

域得到了广泛应用^[1-3]。电磁层析成像(EMT)技术作为一种可视化检测手段,其核心难点与研究热点均集中于图像重建算法。图像重建本质上是求解 EMT 中的非线性逆问题,即利用数据采集系统获取的测量电压信号,并结合已知的先验信息,通过特定的数学算法反演被测区域的电导率/磁导率分布。然而,“软场”性质的存在使 EMT 图像重建存在高度非线性的问题。此外,由于独立测量数据的数量远远少于待重建的未知电导率参数的数量,导致欠确定问题,使得重建图像经常受到低空间分辨率和伪影、畸变的影响。目前已有许多用于逆问题的求解算法,如线性反投影算法(linear back-projection, LBP)^[4]、Tikhonov 正则化算法^[5]、共轭梯度算法(conjugate gradient, CG)^[6]。上述算法原理是基于最优化方法,根据仿真得到的灵敏度矩阵,求其逆问题方程组的最优解。然而,大多数传统算法并没有很好地考虑到 EMT 的非线性特性,面临着重建精度的困境。

与传统方法相比,深度学习模型具有更深的模型结构,可以捕获更复杂的图像特征,获得更好的重建性能^[7-8]。因此,许多基于深度学习的方法已被应用于电学成像。经典的深度学习算法如卷积神经网络(CNN)^[9-10]、基于 CNN 构建的图像分割网络 U-Net^[11]在电阻断层成像(electrical impedance tomography, EIT)、电阻层析成像(electrical resistance tomography, ERT)中都取得了很好的效果,也有许多深度学习算法在 EMT 中效果良好^[7,12-14],然而其非线性拟合的精度并不理想,导致重建图像缺乏细节信息。生成式对抗网络(GAN)是一种经典的深度学习网络结构,由生成器和鉴别器组成^[15],通过生成器和鉴别器之间的对抗学习,有效地提高了重建图像的细节质量^[16-20]。但由于电磁层析成像往往伴随着成像场景复杂而且依赖训练样本,因此 GAN 存在生成图像鲁棒性不足的问题^[21]。与 GAN 相比,CycleGAN^[22-23]具有循环一致对抗性,包括从重建图像到初始图像的逆变换,通过循环来二次约束映射,降低了噪声的干扰,有望提高图像重建的鲁棒性。

基于此,本文提出了一种用于 EMT 图像重建的深度学习结构——带注意机制的循环生成对抗网络(CycleGAN-AM),该结构由预成像模块和后处理模块组成。将 CycleGAN 方法用于 EMT 成像,通过双生成器、双鉴别器捕捉更多的非线性特征,以提高电磁层析成像的抗噪能力;在生成器中引入 GAM 注意力机制,学习信道依赖关系,以期提高网络的重构精度和可解释性。

1 EMT 原理

EMT 的工作模式如图 1 所示。实测场分为被测物体和背景域 2 部分,实测场电导率为 σ_1 ,背景域电导率为 σ_0 。实测场周围均匀放置 8 个线圈,把传感器装置内的线圈依次当作是激励线圈,针对其施以激励电流,其余线圈则按顺序作为测量线圈获得测量电压,最后将得到 7×8 共 56 组电压信号。利用图像重建算法进行图像重建,获得的原始重建图像分辨率为 32×32 ,通过插值将图像分辨率提高到 256×256 。




图 1 8 电极 EMT 测量系统

Fig.1 8-electrode EMT measurement system

EMT 图像重建是将采集到的边界电压测量值 V 重构成电导率向量,这是一个非线性问题。

$$V = F(\sigma) \quad (1)$$

式中: V 为边界电压的测量相位矢量; F 为内部电导率分布的正演模型图。为了简化 EMT 模型,在假设感应场函数与物体空间内部电导率分布无关的情况下,采用线性逼近方法描述感应电压与电导率分布之间的非线性关系^[24]。感应电压与电导率分布的线性方程为:

$$S\sigma = V \quad (2)$$

式中: S 为归一化灵敏度矩阵,它是边界电压和电导率分布之间的映射。EMT 图像重建目的是通过求解式(2)中的模型来获得电导率分布。

基于深度学习方法求解 EMT 反问题的数学模型可以表示为:

$$R_{\text{resm}} = \operatorname{argmin} \sum_1^N L\{\sigma_0 R_\theta(V)\} + g(\theta) \quad (3)$$

式中: σ 和 V 为用来训练该模型的数据集; R 为深度学习网络结构,用来学习输入和输出之间的关系; L 和 g 分别表示损失函数和正则化函数; θ 为深度学习网络参数; $g(\theta)$ 为具有先验信息的正则化项; N 表示训练样本的数量。

2 基于 CycleGAN-AM 网络的 EMT 成像模型

2.1 CycleGAN-AM 网络的整体架构

CycleGAN-AM 网络由预处理模块和后处理模块

组成,能够充分发挥 CycleGAN 与传统算法的协同作用,如图 2 所示。

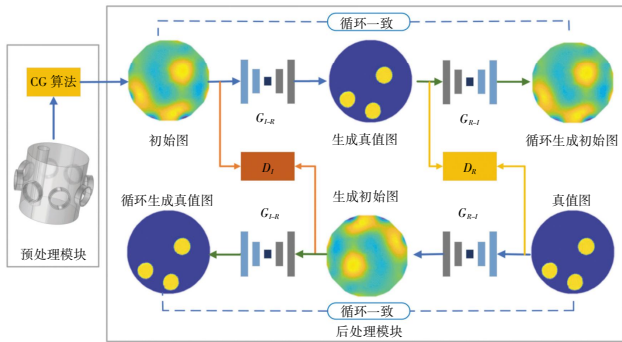


图 2 CycleGAN-AM 的总体架构

Fig.2 Overall architecture of CycleGAN-AM

CycleGAN-AM 的预成像模块利用共轭梯度迭代算法(CG)对电压矢量与像素分布的非线性关系进行初步映射,获得的原始重建图像分辨率为 32×32 ,通过插值将图像分辨率提高到 256×256 ,得到初始图。CycleGAN-AM 的后处理模块包含 2 个生成式对抗网

络(GANs),每个 GAN 由 1 个生成器 G 和 1 个鉴别器 D 组成。生成器 $G_{I \rightarrow R}$ 是将图像从初始域映射到真值域(生成/循环真值图);生成器 $G_{R \rightarrow I}$ 是将图像从真值域映射到初始域(生成/循环初始图)。鉴别器 D_r 用来区分生成真值图和真值图;鉴别器 D_i 被用来区分生成初始图和初始图。通过生成器 G 和鉴别器 D 网络的相互竞争,提高重建图像质量。此外,CycleGAN-AM 通过实施逆变换,即将生成初始图转换为循环初始图图像,并将生成真值图转换为循环真值图,从而使典型 GAN 的处理过程翻倍。这对模型形成了双重约束,提高了输出图像的精度。

2.2 生成器

生成器 G 的网络结构如图 3 所示。生成器包括编码器、转换器、解码器 3 部分,其输入和输出均为彩色电导率分布重建图像。在这个架构中,编码器将高维数据下采样从而提取初始图像的特征,转换器将初始域中的特征映射到真值域,而解码器将映射后的特征进行图形重建。




图 3 生成器结构

Fig.3 Structure of generator

2.2.1 编码器

为了获取多尺度特征,在编码器中采用 1 个卷积核为 9×9 和 2 个卷积核为 3×3 的卷积块对输入图像进行下采样处理,从而提取输入图像特征。此外,为避免因网络深度的加深导致梯度消失、无法继续训练模型的问题,每个卷积块中都包含批量归一化,通过将该层特征值分布重新拉回标准正态分布,使其位于激活函数对输入较为敏感的范围,来缓解梯度消失。

2.2.2 转换器

转换器采用 9 个残差块(residule_block)组成,处理来自编码器的特征,能够达到在转换的同时保留原

始图像特征的目标。此外,为了利用全局特征信息,在残差块的每个跳跃连接上引入了全局注意力机制(global attention mechanism, GAM)^[24],使网络能够更加聚焦于关键信息,减少冗余信息的干扰,增强网络对 EMT 初始图像的特征学习能力,使生成器能够提取更多尺度信息,从而提高预测的准确性。此外,全局注意力机制可以有效地解决网络的信息过载问题,提高网络的效率。

GAM 由通道注意力子模块与空间注意力子模块组成。其中,通道注意力子模块如图 4 所示,采用三维排列以保留 3 个维度上的信息,并利用 1 个双层多层

感知器(multilayer perceptron, MLP)来增强跨维度的通道与空间依赖性^[25]。空间注意力子模块如图 5 所示。在空间注意力子模块中,为提取空间信息,利用 2 个卷积核为 7×7 的卷积层实现空间信息融合,最后经过 Sigmoid 处理,得到输出结果。引入全局注意力机制的方法如下:

$$X_2 = M_C(X_1) \otimes X_1 \quad (4)$$

$$X_3 = M_S(X_2) \otimes X_2 \quad (5)$$

式中: X_1 为输入特征; X_2 为中间特征; X_3 为输出特征; M_C 为通道注意力机制; M_S 为空间注意力机制; \otimes 为元素的乘法。




图 4 通道注意力机制

Fig.4 Channel attention submodule




图 5 空间注意力机制

Fig.5 Spatial attention submodule

2.2.3 解码器

解码器的主要职责是依据转换器部分生成的特征向量,通过图像缩放卷积的上采样方法重构出接近真实的图像及其细微特征。本文解码器模块采用了含有 ReLU 激活函数的反卷积层(DeConv Layer),进行上采样图像,有助于增加空间尺寸并减小通道数,从而确保解码过程的高效性和准确性。最后一层是卷积层,用于从提取的特征信息中重建 EMT 图像。通过这种精细化的解码机制,能够生成更为真实、细节丰富的图像。

2.3 鉴别器

本文选取 patchGAN 作为鉴别器 D ,如图 6 所示。Patch 是指输入图像通过卷积映射成 $N \times N$ 的矩阵,此矩阵中每个点均代表原始图像中的一块小区域评价价值。相较于传统生成对抗网络以单个数值对整幅图像进行度量的方式,通过 $N \times N$ 的矩阵进行图像判断具备更大的“感受野”,因此表现出更强的分类和判别能力。鉴别器由 4 个下行块组成,每个下行块包含 1 个步长为 2×2 的卷积层、1 个批处理归一化层和 1 个 LReLU 激活函数。下行块之后是 1 个步幅为 1×1 的卷积层。整个鉴别器的卷积核设置为 4×4 。这样的补丁级鉴别器设计比全图像鉴别器具有更少的参数,有利于重建图像的细节保持。




图 6 鉴别器结构

Fig.6 Structure of discriminator

2.4 损失函数

本文的目标损失函数包括 2 种类型,即生成图像与真值图像之间的对抗性损失以及周期一致性损失。对抗性损失通过鼓励生成图像足够接近真值图像来提高生成模型的性能;而周期一致性损失则通过强制重建初始图像来实现周期一致性的约束,从而提高模型的稳定性和鲁棒性。完整的目标损失函数为:

$$L_{full} = L_{adv}(G_{1 \rightarrow R}, D_R) + L_{adv}(G_{R \rightarrow 1}, D_1) + L_{adv}(G_{1 \rightarrow R}, G_{R \rightarrow 1}) \quad (6)$$

把这 2 种损失函数结合在一起,可以获得 1 个更加全面和准确的目标损失函数,从而提升模型的性能和效果。接下来将详细介绍这 2 种损失函数。

对抗性损失由 2 部分组成,并应用于 2 个映射函数。第 1 部分是映射函数 $G_{I \rightarrow R}$ 的目标损失函数:

$$L_{adv}(G_{I \rightarrow R}, D_R) = E_{R_i \in N} [\log D_R(R_i)] + E_{I_i \in N} [\log(1 - D_R(G(I_i)))] \quad (7)$$

判别器 D_R 试图通过最大化这个损失来找到重建图像和真值图像之间的最佳决策边界; $G_{I \rightarrow R}$ 试图通过最小化该损失来生成 1 个可以欺骗 D_R 的重建图像。

第 2 部分是映射函数 $G_{R \rightarrow I}$ 的目标损失函数:

$$L_{adv}(G_{R \rightarrow I}, D_I) = E_{I_i \in N} [\log D_I(I_i)] + E_{R_i \in N} [\log(1 - D_I(G(R_i)))] \quad (8)$$

在网络训练过程中,不能保证学习到的函数仅仅通过对抗损失就能将初始图像 I_i 映射到真值图 R_i ,因此,使用 L1 范数引入循环一致性损失,避免 2 个映射 $G_{I \rightarrow R}$ 和 $G_{R \rightarrow I}$ 相互矛盾。循环一致性损失为:

$$L_{cyc}(G_{I \rightarrow R}, G_{R \rightarrow I}) = E_{R_i \in N} [\|G_{I \rightarrow R}(G_{R \rightarrow I}(R_i)) - R_i\|_1] + E_{I_i \in N} [\|G_{R \rightarrow I}(G_{I \rightarrow R}(I_i)) - I_i\|_1] \quad (9)$$

3 EMT 仿真结果与数据分析

3.1 数据集

基于深度学习的 EMT 图像重建需要大量的样本来训练网络模型。数据集的质量对模型的泛化能力有重要影响。由于噪声和干扰的存在,在实际的 EMT 系统中,难以得到准确的电导率分布。为了解决这一问

题,本文利用 COMSOL 和 MATLAB 联合仿真构建数据集,建立了一个 8 通道的 EMT 测量模型。圆柱体模型高度为 15 cm,半径为 5 cm,在圆形成像范围内放置一个或多个被测物体,周围均匀放置 8 个线圈。按照第 1 章中的激励测量方式进行有限元仿真,每个仿真模型均可获得含 812 个元素电导率分布向量和含有 56 个元素的测量数据向量。测量电压 V 和电导率 σ ,以矩阵形式存储。总体结构如图 7 所示。




图 7 8 通道 EMT 信号采集系统模型

Fig.7 Model of 8-channel EMT signal acquisition system

本文主要设计了 2 种类型的样本数据集,包括圆形样本和正方形样本,而且所有被测物体都在测量域范围内随机分布。其中,圆形被测物体包含 2 种半径,分别为 0.6 cm 和 1.0 cm;正方形被测物体的直角边为 1.8 cm。圆形样本和正方形样本一共分为 6 种情况,样本类型如图 8 所示,为了满足包含分布的随机性,本文制作了每种类型的样本 4 000 个。此外,采用随机抽样的方法将所有样本分为不相交的训练集(20 000)和测试集(4 000)。

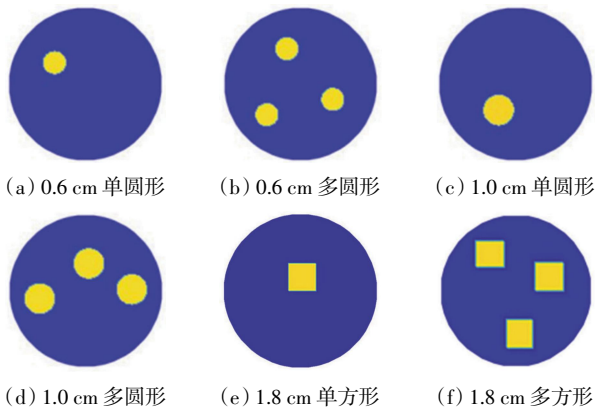


图 8 仿真数据集类型

Fig.8 Examples of EMT datasets

3.2 评价指标

为了定量评价 CycleGAN-AM 和参考方法的重建图像质量,使用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似度指数(structural similarity indices, SSIM)2 个指标来衡量重建图像和真值图像的相似度和误差,可表示为

$$SSIM(s, s') = \frac{(2m_s m_{s'} + C_1)(2\nu_{ss'} + C_2)}{(m_s^2 + m_{s'}^2 + C_1)(\gamma_s^2 + \gamma_{s'}^2 + C_2)} \quad (10)$$

$$PSNR(s, s') = 10 \lg \frac{(2^n - 1)^2}{MSE(s, s')} \quad (11)$$

式中: s 和 s' 分别表示真值图像和重建图像; m 和 γ 分别为均值和方差; ν 为协方差; C_1 和 C_2 为常数; n 为图像的二进制数;MSE 为均方误差。

此外,使用位置误差(position error, PE)和形状误差(shape deformation, SD)2 个指标来衡量重建图像的位置和形状的准确性,其可表示为

$$PE = r_s - r_{s'} \quad (12)$$

$$SD = \frac{A_s - A_{s'}}{A_s} \quad (13)$$

式中: r_s 和 $r_{s'}$ 分别为真值图像与重建图像中被测对象的中心与成像区域中心的距离; A_s 和 $A_{s'}$ 分别为真值图像与重建图像中被测对象的面积。

3.3 重建图像

为了验证本文方法的有效性,将 CycleGAN-AM 与 CycleGAN、CNN、Attention UNet、R-UNet 算法比较,并从测试集中随机挑选了 6 个不同样本作为评价对象。不同算法下的重建图像效果如图 9 所示。

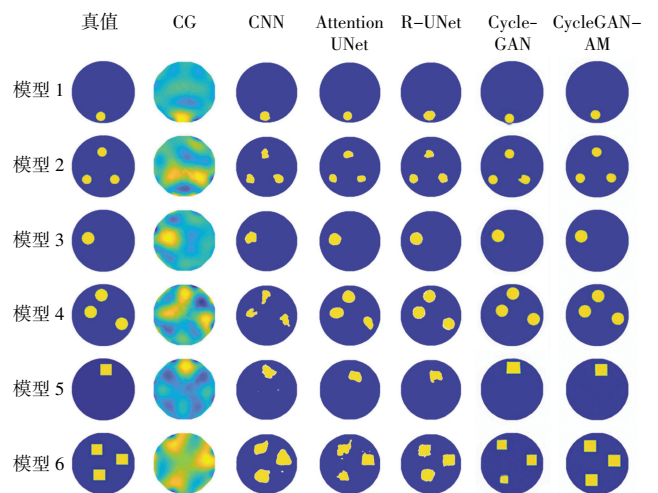


图 9 重建图像

Fig.9 Reconstruction images

由图 9 可以看出,与 CNN、Attention UNet、R-UNet 和 CycleGAN 网络相比,本文提出的 CycleGAN-AM 可以更有效地重建被测对象的细节特征。在传统图像重建算法中,虽然能看出被测物体的大概分布位置,但

被测对象的形状和位置无法得到准确的重建,并且在重建图像中出现严重的伪影。在 CNN、Attention UNet、R-UNet 网络中,减轻了重建图像伪影,但被测对象的位置、形状和大小都不准确;在 CycleGAN 网络中可以重建被测对象的形状和位置,而且对于单个被测物体来说成像边缘清晰,但在方形样本的重建图像中存在轻微的形状变形,且对于多个被测物体来说成像形状和位置的准确度不高。CycleGAN-AM 不仅能够重建被测物体的大小以及位置,而且能够较为准确地恢复被测对象的形状,具有更清晰的边缘和更好的形状。

为了评估不同深度学习方法在 EMT 图像重建任务中的效果,分别用 SSIM、PSNR、PE 和 SD 这 4 个指标对 5 种重建算法生成的图像进行了定量比较。结果如图 10 与图 11 所示。由图 10 和图 11 可以看出,CycleGAN-AM 方法表现出了明显优势,其平均 PSNR、SSIM 值都有明显的提升,体现了 CycleGAN-AM 优越的重建性能;其平均 PE 和 SD 值都有明显的下降,这表明采用 CycleGAN-AM 方法得到的 EMT 重建图像,在目标位置和形状表征上具有更高的精度,误差更小。

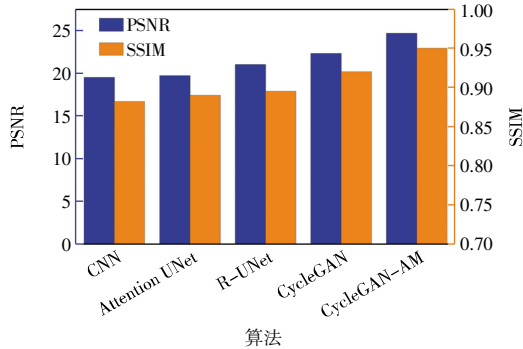


图 10 5 种方法重建图像的平均 PSNR 和平均 SSIM

Fig.10 Average PSNR and average SSIM of reconstructed images by five methods

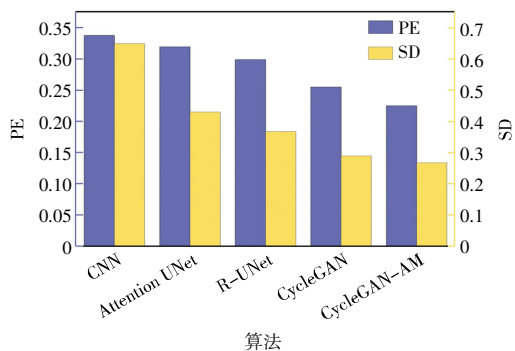


图 11 5 种方法重建图像的平均 PE 值和平均 SD 值

Fig.11 Average PE and average SD of reconstructed images by five methods

3.4 抗噪实验

为了验证 CycleGAN-AM 的抗噪声能力,在样本

中加入不同噪声水平(20 ~ 60 dB)的高斯白噪声。具有典型噪声水平的重构图像如图 12 所示。

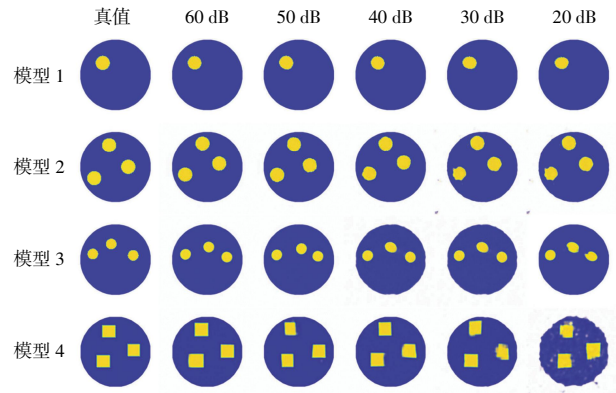


图 12 不同噪音水平下的重建图像

Fig.12 Reconstructed images under different noise levels

由图 12 可以看出,与无噪声情况下的仿真结果相比,有噪声的重建图像质量有所降低。随着噪声信噪比的下降,重建图像中被测对象的边界逐渐变形,物体实际分布有所偏移,尤其是对于方形样本,不能准确重建形状,但 CycleGAN-AM 重建图像的伪影依然较小,且仍然可以有效地重建出被测对象的位置和分布区域大小。这一特性说明,CycleGAN-AM 算法在复杂环境下依然能够保持较高的准确性和稳定性。

不同噪音水平下的重建图像的平均峰值信噪比(PSNR)和结构相似性指标(SSIM)如图 13 所示。由图 13 可以看出,虽然随着噪声信噪比(SNR)的降低,平均 PSNR 和 SSIM 逐渐下降,但信噪比大于 30 dB 时,重建图像的 PSNR 值保持在 20 以上,同时 SSIM 值也在 0.88 以上。由此表明,CycleGAN-AM 具有良好的抗噪能力,可以应对噪声干扰。




图 13 不同噪声下重建图像的平均 PSNR 和平均 SSIM

Fig.13 Average PSNR and average SSIM of reconstructed images under different noise levels

3.5 泛化实验

为了验证 CycleGAN-AM 的泛化能力,本文制作了与训练集不同尺寸和个数的样品来测试 CycleGAN-AM 的重建性能,主要包括以下 2 种类型:个数变化的

样本,包括与数据集个数不同的圆形样本与方形样本;尺寸变化的样本,包括大小不同的圆形样本、大小不同的方形样本,如图 14 所示。

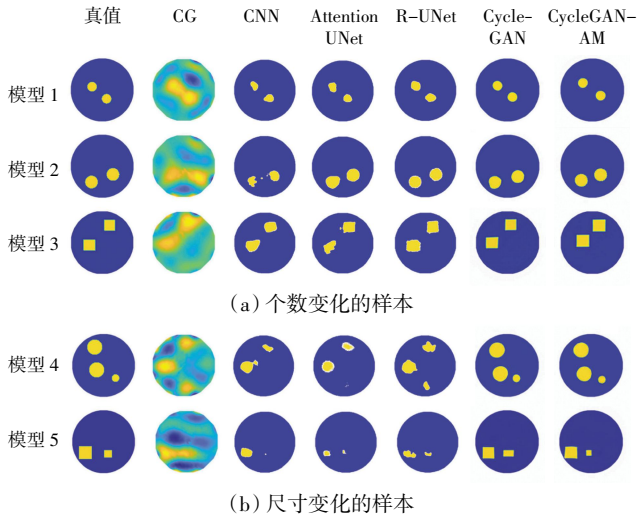


图 14 新样本重建图像

Fig.14 Reconstructed images of new samples

由图 14 可以看出:当样本个数与数据集中样本个数不同时,CNN、AttentionUNet、R-UNet 重建图像中的被测对象包含边界模糊,且不能准确重建出被测物体形状;与 CNN 和 CycleGAN 相比,CycleGAN-AM 可以更准确地重建被测对象的形状和边界。当测量域中出现尺寸变化的被测对象时,CNN、R-UNet、AttentionUNet 不能有效地重建被测对象的大小变化。CycleGAN 虽然对圆形被测对象的恢复效果较好,但对于方形被测对象不能很好的恢复本来尺寸,而 CycleGAN-AM 重建图像中被测对象的大小接近真实被测对象的大小。

此外,本文通过 PSNR 和 SSIM 对新样本的重建图像进行定量比较,结果如图 15 所示。

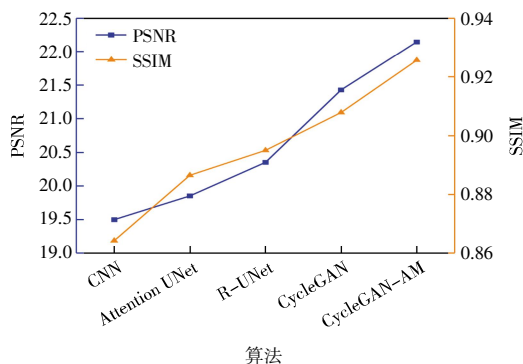


图 15 新样本重建图像的平均 PSNR 和平均 SSIM


Fig.15 Average PSNR and average SSIM of reconstructed images of new samples

由图 15 可以看出,相对于 CNN、AttentionUNet、


R-UNet 和 CycleGAN 来说,CycleGAN-AM 算法具有优秀的成像质量与相似度,表明 CycleGAN-AM 在泛化能力方面更加出色。

4 实验验证

8 电极 EMT 实验系统如图 16 所示,由传感器阵列、电磁层析检测设备和上位机 3 部分构成。传感器阵列负责接收和传递电磁信号。实验系统所用传感器阵列与仿真实验参数相同,每个线圈都采用铜线均匀绕制而成,内径均为 15 mm、匝数为 200,且在圆形测量域周边均匀分布。电磁层析检测设备由控制模块、多路选通模块、信号激励模块和数据采集模块组成,负责接收传感器测得的电磁数据,并将其由模拟信号形式转化为数字信号形式。此外,为了提高数据的质量,该模块还对数字信号进行预处理,包括信号的放大、滤波等操作。上位机负责接收、存储测量电压数据,并利用图像重建算法,对采集到的电压数据进行图像重建。实验测量域为圆柱体,内径为 5 cm。传感器阵列与仿真相同,8 个传感器线圈半径为 1.5 cm,均匀分布在圆形物场周围,线圈匝数则为用铜线均匀绕制的 200 匝。在实际实验过程中,以空气为背景域,在测量域随机放置铜棒,获得不同的实验数据,用于测试 CycleGAN-AM 的性能。



(a) 8 电极实验系统



(b) 系统结构



(c) 测量域

图 16 实验装置

Fig.16 Experimental setup

本文将基于 CycleGAN-AM 的 EMT 成像算法与 CNN、Attention UNet、R-UNet 和 CycleGAN 进行对比,重建结果如图 17 所示。由图 17 可以看出,相对于 CNN、R-UNet 和 AttentionUNet 等算法,本文提出的

CycleGAN-AM 算法的实验结果重建图像边缘比较圆滑,说明 CycleGAN-AM 算法可以更好地描述被测对象的形状和位置,而且 CycleGAN-AM 算法可以重建包含边界的更多细节特征,证明 CycleGAN-AM 算法具有更好的边界保持能力。

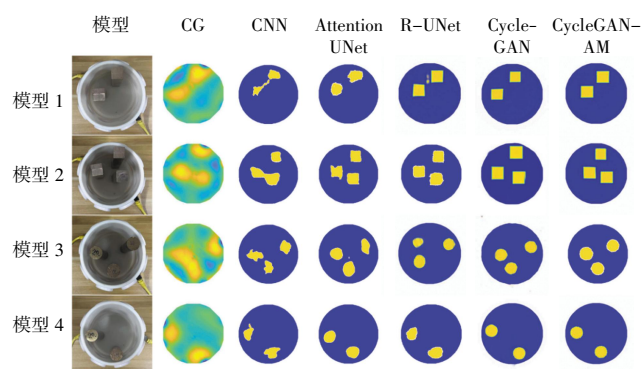


图 17 实验样本重建图像

Fig.17 Reconstruction images of experiment samples

通过图像评价指标 PSNR 和 SSIM 来判断实验样本的重建图像质量,200 组实验样本重建图像的 PSNR 和 SSIM 分布如图 18 中的箱形图所示。由图 18 可以看出,与 CNN、R-UNet 和 Attention UNet 相比,CycleGAN 和 CycleGAN-AM 的 SSIM 和 PSNR 分布更加密集,而且 CycleGAN-AM 的 PSNR 和 SSIM 值都有所提高,与传统方法相比分别提高了 15%和 11%。由此说明,该算法有效提高了网络的鲁棒性和重建质量。

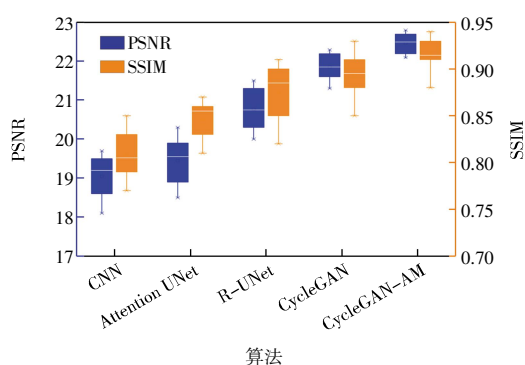


图 18 实验样本重建图像的 PSNR 和 SSIM

Fig.18 PSNR and SSIM of reconstructed images of experiment samples

5 结 论

本文提出了用于 EMT 图像重建的深度学习结构 CycleGAN-AM 以解决成像中的逆问题,该结构由预成像模块与后处理模块组成。在预成像模块中,将边界电压测量值重构为初始电导率图像;通过后处理模块中的双生成器和双鉴别器之间的对抗学习,可以从

初始电导率图像中获得具有更好细节特征的重建图像。通过仿真和实验验证了 CycleGAN-AM 网络用于 EMT 图像重建的可行性。结果表明:

(1) CycleGAN-AM 可以准确重建被测物体的大小、位置以及形状。

(2) 对于有噪声干扰的样本和新样本(个数、尺寸变化)也可以实现有效的图像重建。

(3) 与传统方法相比,CycleGAN-AM 成像精度提高了 15%,结构相似度提高了 11%,展现了良好的抗噪性和泛化能力,具有提高定量 EMT 成像质量的前景。

参考文献:

- [1] 付妍,董峰,谭超.电磁层析成像系统敏感场激励特性仿真研究[J].中国电机工程学报,2011,31(8):73-79.
Fu Yan, Dong Feng, Tan Chao. Simulation of excitation characteristics in sensing field of electromagnetic tomography system[J]. Proceedings of the CSEE, 2011, 31(8): 73-79(in Chinese).
- [2] 饶臻浩,张翱龙,金泽溟,等.金属结构损伤电磁检测软件设计与开发[J].测控技术,2022,41(7):105-110.
Rao Zhenhao, Zhang Aolong, Jin Zehao, et al. Design and development of electromagnetic testing software for metal structure damage[J]. Measurement & Control Technology, 2022, 41(7): 105-110(in Chinese).
- [3] 武建利.电磁层析成像在高速列车刹车盘缺陷检测中的应用研究[D].北京:北京交通大学,2019.
Wu Jianli. Application of brake disc defects inspection of high-speed train by using electromagnetic tomography [D]. Beijing: Beijing Jiaotong University, 2019(in Chinese).
- [4] Yang W Q, Peng L H. Image reconstruction algorithms for electrical capacitance tomography[J]. Measurement Science and Technology, 2003, 14(1): R1-R13.
- [5] 王莉莉,陈宇,陈德运,等.基于改进信赖域的电容层析成像图像重建算法[J].仪器仪表学报,2010,31(5):1076-1081.
Wang Lili, Chen Yu, Chen Deyun, et al. Improved trust region based image reconstruction algorithm for electrical capacitance tomography system[J]. Chinese Journal of Scientific Instrument, 2010, 31(5): 1076-1081(in Chinese).
- [6] 刘向龙.电磁层析成像关键问题及其在高铁车轮探伤中的应用研究[D].北京:北京交通大学,2019.
Liu Xianglong. Research on key issues of electromagnetic tomography and its application in high-speed rail wheel defect detection[D]. Beijing: Beijing Jiaotong University, 2019(in Chinese).
- [7] Xiao J, Liu Z, Zhao P F, et al. Deep learning image reconstruction simulation for electromagnetic tomography[J]. IEEE

- Sensors Journal, 2018, 18(8): 3290–3298.
- [8] Wang H, Yang Y Y, Pan Y, et al. Detecting thoracic diseases via representation learning with adaptive sampling[J]. Neurocomputing, 2020, 406: 354–360.
- [9] Hamilton S J, Hauptmann A. Deep D-bar: Real-time electrical impedance tomography imaging with deep neural networks[J]. IEEE Transactions on Medical Imaging, 2018, 37(10): 2367–2377.
- [10] Aleardi M, Vinciguerra A, Hojat A. A convolutional neural network approach to electrical resistivity tomography[J]. Journal of Applied Geophysics, 2021, 193: 104434.
- [11] Garehdaghi F, Meshgini S, Afrouzian R. Positron emission tomography image enhancement using magnetic resonance images and U-Net structure[J]. Computers & Electrical Engineering, 2021, 90: 106973.
- [12] Zhang P, Hu Y Y, Jin Y C, et al. A Maxwell's equations based deep learning method for time domain electromagnetic simulations[J]. IEEE Journal on Multiscale and Multiphysics Computational Techniques, 2021, 6: 35–40.
- [13] Noakoosteen O, Wang S, Peng Z, et al. Physics-informed deep neural networks for transient electromagnetic analysis[J]. IEEE Open Journal of Antennas and Propagation, 2020, 1: 404–412.
- [14] 李秀艳, 李明廷, 李晓捷, 等. 一种基于改进 U-Net 模型的电磁层析成像算法[J]. 天津工业大学学报, 2023, 42(1): 44–51.
- Li Xiuyan, Li Mingting, Li Xiaojie, et al. An electromagnetic tomography algorithm based on improved U-Net model[J]. Journal of Tiangong University, 2023, 42(1): 44–51(in Chinese).
- [15] Yi X, Walia E, Babyn P. Generative adversarial network in medical imaging: A review[J]. Medical Image Analysis, 2019, 58: 101552.
- [16] Mardani M, Gong E H, Cheng J Y, et al. Deep generative adversarial neural networks for compressive sensing MRI[J]. IEEE Transactions on Medical Imaging, 2019, 38(1): 167–179.
- [17] Li X Y, Zhang R Z, Wang Q, et al. SAR-CGAN: Improved generative adversarial network for EIT reconstruction of lung diseases[J]. Biomedical Signal Processing and Control, 2023, 81: 104421.
- [18] Zhang H Y, Wang Q, Zhang R H, et al. Image reconstruction for electrical impedance tomography (EIT) with improved Wasserstein generative adversarial network (WGAN)[J]. IEEE Sensors Journal, 2023, 23(5): 4466–4475.
- [19] Sanchez F A S, Khambampati A K, Kim K Y. Generative adversarial network model for two-phase flow imaging by electrical impedance tomography[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 4507212.
- [20] Frid-Adar M, Diamant I, Klang E, et al. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification[J]. Neurocomputing, 2018, 321: 321–331.
- [21] Chan H P, Hadjiiski L M, Samala R K. Computer-aided diagnosis in the era of deep learning[J]. Medical Physics, 2020, 47(5): e218–e227.
- [22] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]// 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2242–2251.
- [23] Yang H R, Sun J, Carass A, et al. Unsupervised MR-to-CT synthesis using structure-constrained CycleGAN[J]. IEEE Transactions on Medical Imaging, 2020, 39(12): 4249–4261.
- [24] Lei J, Mu H P, Liu Q B, et al. Tensor-based dynamic reconstruction method for electrical capacitance tomography [J]. Measurement Science and Technology, 2017, 28(3): 035403.
- [25] Xu Z Q, Zhang Y J, Miao J G, et al. Global attention mechanism based deep learning for remaining useful life prediction of aero-engine[J]. Measurement, 2023, 217: 113098.

本文引文格式:

李秀艳, 虞坤, 王琦, 等. 基于改进 CycleGAN 网络的电磁层析成像算法[J]. 天津工业大学学报, 2026, 45(2): 77–85.

Li Xiuyan, Yu Kun, Wang Qi, et al. Electromagnetic tomography algorithm based on improved CycleGAN network [J]. Journal of Tiangong University, 2026, 45(2): 77–85(in Chinese).

(责任编辑:孙广宇)