

引用格式: SUN Zhilong, ZHANG Jie, LIU Zongyang, et al. Diffuse Optical Tomography Method Based on Multi-information Fusion and Stacked Auto-encoder Network[J]. Acta Photonica Sinica, 2022, 51(12):1217001

孙志龙,张杰,刘宗洋,等. 基于多信息融合和栈式自编码网络的扩散光学层析方法[J]. 光子学报,2022,51(12):1217001

基于多信息融合和栈式自编码网络的扩散光学层析方法

孙志龙¹,张杰²,刘宗洋²,高峰^{2,3},张丽敏^{2,3}

(1 天津大学 国际工程师学院, 天津 300072)

(2 天津大学 精密仪器与光电子工程学院, 天津 300072)

(3 天津市生物医学检测技术与仪器重点实验室, 天津 300072)

摘要:针对传统扩散光学层析(DOT)成像方法获取的图像精度较低,且主要对规则的圆形异质体进行重建的问题,本文利用解剖图像提供的结构先验信息并结合具有网络模型简单、需要调整的网络参数少、网络训练速度快等优点的栈式自编码(SAE)网络,发展了基于多信息融合和SAE网络的DOT图像重建方法。为验证所提方法的可行性和有效性,进行了一系列的数值模拟和定量评估。实验结果表明,与无先验信息方法相比,该方法可有效提高低吸收对比度(1.5)情况下的图像质量,使得平均绝对误差降低62%,均方误差降低11%,定量重建率值由139%降低为107%更接近100%。对单目标和双目标椭圆形异质体重建时,融合先验信息的方法获得重建图像的位置、尺寸、形状以及吸收系数更接近真实值,与无先验信息方法相比平均绝对误差至少降低8%,均方误差至少降低5%,定量重建率值更接近100%。

关键词:扩散光学层析成像技术;先验信息;栈式自编码神经网络;乳腺肿瘤;图像重建

中图分类号: TP29

文献标识码: A

doi:10.3788/gzxb20225112.1217001

0 引言

扩散光学层析(Diffuse Optical Tomography, DOT)作为一种新型的功能光学成像技术,其利用波长范围在600~900 nm的近红外光入射生物组织体,根据在生物组织边界得到的光流量,从而重构组织内部光学特性的三维分布^[1]。该技术具有无创、无电离辐射以及可提供生物组织生理学信息等优势,在乳腺肿瘤成像和脑功能成像等领域极具应用潜力^[2-4]。在DOT成像过程中,近红外光在组织中传播具有强散射特性,且边界测量数据远小于需要重构的组织体光学参数个数^[5]。因此,为提高DOT图像重建质量,国内外研究人员发展了多种图像重建优化算法。其中,常用的策略为非线性迭代算法中添加不同类型的正则化项,基本思想是在每次迭代过程中添加额外的惩罚项进行正则化约束,以抑制测量噪声和减小模型误差所带来的影响,从而获得不适定问题的稳定近似解。典型的正则化方法包括L1范数正则化和L2范数正则化^[6]。基于L2范数的正则化方法可有效的重建DOT图像,但L2范数具有平滑效应,对图像边缘恢复较差。L1范数则可以保持边缘,但易出现阶梯效应,导致图像产生虚假边缘。此外,国内外学者提出将扩散光学层析成像技术与现有的医学成像模态结合发展成为多模态成像技术。如BROOKSBY B A和邓勇等分别把磁共振成像(Magnetic Resonance Imaging, MRI)和微型计算机断层扫描系统提供的解剖结构图像作为结构先验信息,以Laplace算子的形式引入到正则化方法中以提高DOT图像重建质量^[7-8]。实验结果均表明,多模态方法可

基金项目:国家自然科学基金(Nos. 82071971, 81671728, 81801745, 81871393, 62075156, 81971656),天津市自然科学基金(No. 19JCYBJC28600)

第一作者:孙志龙(1993—),男,硕士研究生,主要研究方向为扩散光学层析成像方法。Email: szlfdzb@163.com

导师(通讯作者):张丽敏(1980—),女,副教授,博士,主要研究方向为生物医学光子学。Email: zhanglm@tju.edu.cn

收稿日期:2022-05-13;**录用日期:**2022-06-22

<http://www.photon.ac.cn>

以提高重构光学参数图像的空间分辨率和量化度。但是,多模态成像方法首先需要对结构图像进行分割,且图像分割的准确性取决于操作者的经验水平。此外,这些方法无法从根本上避免DOT逆向问题的不稳定性,导致图像空间分辨率低和量化度低,以及由于多次迭代导致重建耗时长。

近年来,人工神经网络以其抽象特征提取和识别、较强的模型构建和泛化能力被广泛应用于图像重建领域。FENG Jinchao等提出了基于反向传播神经网络(Back Propagation Neural Network, BPNN)的DOT图像获取方法,通过直接建立边界光信息与吸收系数的对应关系,克服逆问题求解的不稳定性,但BPNN训练速度较慢并且模型泛化能力不足^[9]。YEDDER H B等和YOO J等提出基于卷积神经网络的DOT图像重建方法。神经网络泛化能力进一步提高,但是网络参数较多,计算量更大,对于计算机性能要求高^[10-11]。在各种神经网络中,栈式自编码(Stacked Auto-Encoder, SAE)具有网络模型简单,需要调整的网络参数少,网络训练速度快的优点。此外,SAE的无监督预训练过程,可为多层神经网络训练找到一个良好的初始权重和偏差,有利于抑制输入数据中的噪声干扰,并在基于误差反向传播算法的微调过程中减少训练时间^[12]。目前,基于人工神经网络的DOT图像重建研究多对规则的圆形异质体进行图像重建,但针对形状欠规则异质体的图像重建还没有相关研究。

为此,本文面向DOT技术在乳腺肿瘤成像中的实际应用,发展了基于多信息融合和SAE网络的DOT图像重建方法。该方法将MRI获取的解剖图像与DOT中测量得到的边界光流量经过预处理后作为输入值,经过SAE网络模型,最终输出DOT光学参数图像。为验证该方法的有效性,本文进行了基于圆形和椭圆形的单异质体以及双异质体模拟。并与无结构图像先验信息时的基于SAE的DOT成像结果进行了对比。此外,设置了平均绝对值误差、均方误差和定量重建率三个指标对图像重建质量进行评估。

1 研究方法

1.1 光在生物组织中的传播

对乳腺组织等较厚组织体,近红外光在其内部的传输规律可由扩散方程,即辐射传输方程的一阶球谐展开近似描述。其中,稳态扩散方程描述为

$$[\nabla D(\mathbf{r})\nabla - \mu_a(\mathbf{r})c]\Phi(\mathbf{r}, \mathbf{r}_s) = \delta(\mathbf{r}, \mathbf{r}_s) \quad (1)$$

式中, $D(\mathbf{r}) = c/(3\mu_s'(\mathbf{r}))$ 为扩散系数, c 为组织内光速, $\mu_s'(\mathbf{r})$ 为约化散射系数, $\mu_a(\mathbf{r})$ 为吸收系数, $\Phi(\mathbf{r}, \mathbf{r}_s)$ 为光子密度, $\delta(\mathbf{r}, \mathbf{r}_s)$ 表示在 \mathbf{r} 处的迷向光源。为求解上述方程常结合Robin边界条件

$$\Phi(\mathbf{r}, \mathbf{r}_s) + 2kD(\mathbf{r})\mathbf{s}_n \cdot \nabla \Phi(\mathbf{r}, \mathbf{r}_s)|_{\mathbf{r} \in \partial\Omega} = 0 \quad (2)$$

式中, $\partial\Omega$ 表示边界,参数 $k = (1 + R_{\text{eff}})/(1 - R_{\text{eff}})$, $R_{\text{eff}} = -1.4399n^{-2} + 0.7099n^{-1} + 0.6681 + 0.0636n$ 为有效反射系数, n 为组织体对环境的相对折射率,通常 Φ 可以基于有限元法求解^[13]。

1.2 基于SAE神经网络的图像重建

基于神经网络的DOT图像重建策略摒弃了求解反向问题的复杂和耗时过程。本文只有吸收系数 μ_a 是需要重建,约化散射系数 μ_s' 为已知常数。以未融合先验信息时基于SAE网络的DOT图像重建为例,网络的输入数据为边界光流量 $\Phi_i (i = 1, 2, 3, \dots, m)$,输出数据集为相应的吸收系数 $\mu_{a,j} (j = 1, \dots, N)$ 。其中, m 为测量数据个数, N 为有限元节点数。

1.2.1 栈式自编码器网络模型

本文使用的栈式自编码人工神经网络包含两个自编码器(Autoencoder, AE),SAE的训练过程包括无监督的预训练及有监督的微调两个过程^[14-15],如图1所示。

在预训练阶段,第一个AE1器将原始输入数据 Φ 映射到SAE网络的第一个隐藏层,通过最小化重构误差获得网络的权重 \mathbf{W}_1 和偏置 \mathbf{b}_1 。随后第二个AE2器将第一个隐藏层的输出结果作为其输入,继续最小化重构误差获得网络权重 \mathbf{W}_2 和偏置 \mathbf{b}_2 。在无监督预训练结束后,添加全连接层作为SAE的输出层并对网络整体的权重及偏置进行微调。预训练得到的权重和偏置 $\mathbf{W}_k, \mathbf{b}_k (k = 1, 2)$,被用作各神经层间权重和偏置的初始值。SAE网络第二个隐藏层和输出层之间的权重 \mathbf{W}_3 和偏置 \mathbf{b}_3 被随机初始化。最后网络基于误差反向传播原理

通过计算预测输出值和期望输出值间的均方误差来最小化其损失函数,以求对网络模型中的权重和偏

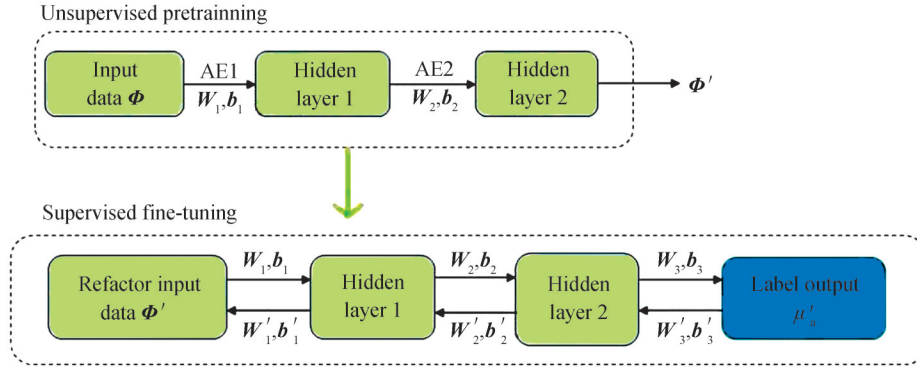


图1 SAE训练过程

Fig. 1 SAE training process

置进行微调得到最佳的参数 $W'_k, b'_k (k = 1, 2, 3)$ 。其损失函数定义为

$$J = \sum_j^N \|\mu_{a,j} - \mu'_{a,j}\|^2 / 2N \quad (3)$$

式中, $\mu_{a,j}$ 和 $\mu'_{a,j}$ 分别为第 j 个样本的实际值和神经网络预测值, N 为总的数据集样本数。

1.2.2 自编码 AE 网络

AE 是一种由编码器和解码器组成的无监督学习神经网络模型, 如图 2^[16] 所示。编码器作用是将输入数据的特征提取至隐藏层, 而解码器将输入数据从隐藏层中重构出来。AE 网络的训练过程使得输入和输出大小相同, 主要原理描述为




图2 自编码器网络结构图

Fig. 2 Autoencoder network diagram

对于编码过程, 对 AE 网络的输入: m 个输入样本 $\Phi_i (i = 1, 2, 3, \dots, m)$ 进行编码处理, 通过式(4)的编码函数 f 对原始输入 Φ 编码, 输出到隐藏层向量 $h_k (k = 1, \dots, n)$, n 为隐藏层神经元个数

$$h = f(\Phi) = W\Phi + b_1 \quad (4)$$

式中, W 是一个 $n \times m$ 的权重矩阵, $b_1 \in R^n$ 是输入层与隐藏层间的偏置。

对于解码过程, 通过式(5)的解码函数 \hat{f} 将隐藏层输出 h 映射到输出层, 完成对输入样本 Φ 的重构

$$\Phi' = \hat{f}(h) = W^T h + b_2 \quad (5)$$

式中, W^T 是一个 $m \times n$ 的权重矩阵, $b_2 \in R^m$ 是隐藏层与输出层间的偏置, Φ' 表示对原始输入数据 Φ 进行重构后的信息。AE 网络最终训练的结果为 $\Phi' = \hat{f}(f(\Phi)) \approx \Phi$, 保留输入数据的主要特征, 降低数据中的噪声

影响。

为了得到模型的最优参数 \mathbf{W} 、 \mathbf{W}^T 、 \mathbf{b}_1 、 \mathbf{b}_2 ，通过计算原始样本输入 Φ 和重构后的 Φ' 间均方误差来最小化其损失函数。

1.2.3 网络有监督微调阶段

SAE网络有监督微调阶段主要包括：输入层(L_0)、全连接隐藏层(L_1)和预测输出层(L_2)。神经网络进行微调原理图如图3所示。

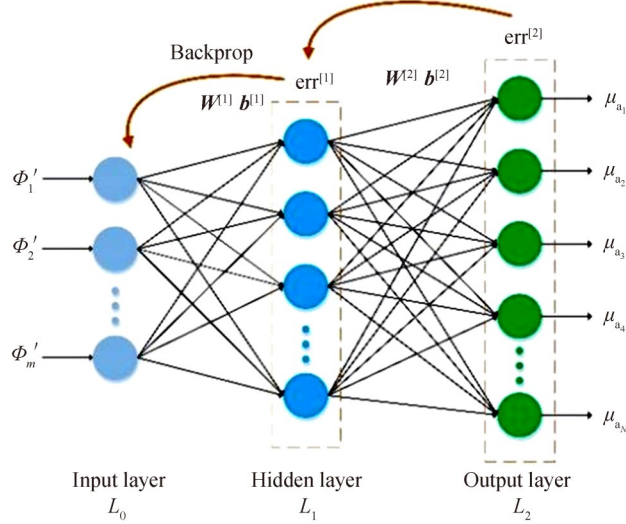


图3 网络微调原理图

Fig. 3 Schematic of network fine-tuning

使用已经初始化权重 $\mathbf{W}^{[l]}$ 和偏差变量 $\mathbf{b}^{[l]}$ ，根据迭代结果，计算输出层预测值和真实值 μ_a 的均方误差。将误差分摊给各层所有单元，从而获得各层单元的误差，进而调整各层之间的权重和偏差。本研究使用Adam优化器基于学习率来控制神经网络的调整速度，激活函数使用的是Sigmoid函数。

1.3 评价指标

为了定量评估两种方法在DOT重构中的性能，计算了平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Square Error, MSE)和定量重建率(Quantitativeness Ratio, QR)三个度量指标^[17-19]

$$\text{MAE} = \sum_{i=1}^N |\mu_{a, \text{true}(i)} - \mu_{a, \text{pre}(i)}| / N \quad (6)$$

$$\text{MSE} = \left(\sum_{i=1}^N |\mu_{a, \text{true}(i)} - \mu_{a, \text{pre}(i)}| / N \right)^2 + \sum_{i=1}^N |\mu_{a, \text{pre}(i)} - \bar{\mu}_{a, \text{pre}}|^2 / N \quad (7)$$

$$\text{QR} = \max(\mu_{\hat{a}_{\text{pre}}}) / \max(\mu_{a_{\text{true}}}) \times 100\% \quad (8)$$

式中， $\mu_{a, \text{true}(i)}$ 、 $\mu_{a, \text{pre}(i)}$ 分别是有限元节点第 i 处真实值以及神经网络预测的吸收系数。 $\bar{\mu}_{a, \text{pre}}$ 为预测吸收系数的平均值， N 为有限元节点总数。此处，MAE和MSE均用于评估重建图像与真实图像之间的误差。前者，MAE计算了平均误差，MSE同时计算了平均误差和标准偏差。QR计算重建目标体吸收系数与真实吸收系数的比值，用于重建方法的定量性评估。理论上MAE和MSE越低，说明重建结果越好，QR越接近100%，表示重建图像的吸收系数值越接近真实值。

2 结果分析

2.1 数据集的生成

在半径40 mm的二维圆形仿体中嵌入异质体来模拟乳腺肿瘤组织，将仿体离散为8762个三角形和4526个有限元节点。为了生成用于神经网络训练的数据集，嵌入大小、位置和吸收系数不同异质体，其中，圆形异质体半径分别为6 mm、8 mm和10 mm，椭圆异质体的半长轴变化范围为6~10 mm，半短轴变化范围为4~8 mm，步长均为2 mm。利用随机函数生成120个异质体中心坐标；背景吸收系数设为 0.0034 mm^{-1} ，约

化散射系数设为 1 mm^{-1} 。异质体-背景的吸收系数的对比度(异质体吸收系数与背景吸收系数比值)为 $1.5 \sim 3.0$,步长为 0.5 ,约化散射系数与背景一致。双异质体与单异质体仿体生成基本一致,区别在于双异质体仿体内部有两个位置随机分布的异质体,且两异质体不重合。

设置共 16 个同轴源探测对均匀布配在仿体的边界,如图 4 所示。当某一光源激发时,除自身以及两侧邻近的位置外,共 11 个位置探测,一组得到 16×11 (176) 个测量数据用于图像重建。为了模拟真实测量值,在计算测量值中加入 40 dB 的随机高斯噪声。




图 4 二维圆形仿真模型
Fig. 4 2D circular simulation model

为了使得数据特征更加明显,需要对测量数据进行预处理

$$\Phi_{\text{sca}} = (\Phi / \Phi_{\text{bac}} - \Phi_{\text{ave}}) / \sigma \quad (9)$$

式中, Φ_{bac} 是在仿体的光学参数均为背景值时测得一组边界光流量, Φ 是加入异质体后测量得到的边界光流量, Φ_{ave} 为单个样本的平均值, σ 为单个样本的标准差,经过数据预处理之后数据 Φ_{sca} 的均值为 0, 方差为 1。

与光学仿体相对应模拟生成 MRI 图像,如图 5 所示。生成灰度图像的大小为 51×51 , 总共 2 601 个像素点,在输入网络之前做最大值最小值归一化预处理。将经过预处理的测量值 (176) 和灰度图像信息 (2 601) 进行融合,作为一组数据的输入 (2 777), 网络输出为吸收系数 (4 526), 共获得 5 670 组样本数据,划分为训练集 3 780 组,验证集 1 620 组,测试集 270 组。

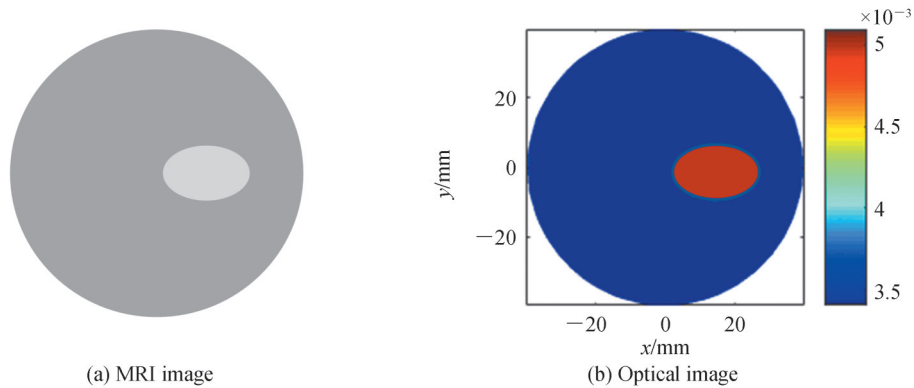


图 5 模拟异质体分布的 MRI 图像和对应的光学图像
Fig. 5 MRI image and corresponding optical image that simulate target distributions

对于 SAE, 根据经验将隐藏层 1 和隐藏层 2 的神经元数量分别设置为 100 和 300。此外,神经网络的学习率均设置为 0.001, 最小批次分别设置为 20 组,预训练次数为 2 000, 微调次数为 300。

2.2 数值模拟实验

为了评估和比较融合先验信息前后SAE网络重建图像的性能,进行了一系列的数值模拟,并对实验结果进行了定性和定量的比较。主要对四种情况进行了对比。

1)随机分布的圆形异质体,目标体半径固定10 mm,吸收对比度分布为1.5、2.0、2.5和3.0。图6的第一行是无先验信息方法的重建图像(No prior),第二行是融合先验信息方法的重建图像(Prior),第三行是沿着穿过仿体和异质体中心线的吸收系数剖面,黑色圆圈代表真实异质体。

从图6可以看出当异质体半径均为10 mm,在不同吸收对比度下,添加先验信息与否均可重建出异质体的位置和尺寸,且随着吸收对比度的提高,重建图像的质量均有所提高。当吸收对比度为1.5时,无先验信息方法的重建图像中异质体边缘轮廓模糊,伪影较多,且吸收系数过高估明显,而融合先验信息方法对重建结果有明显的改善。

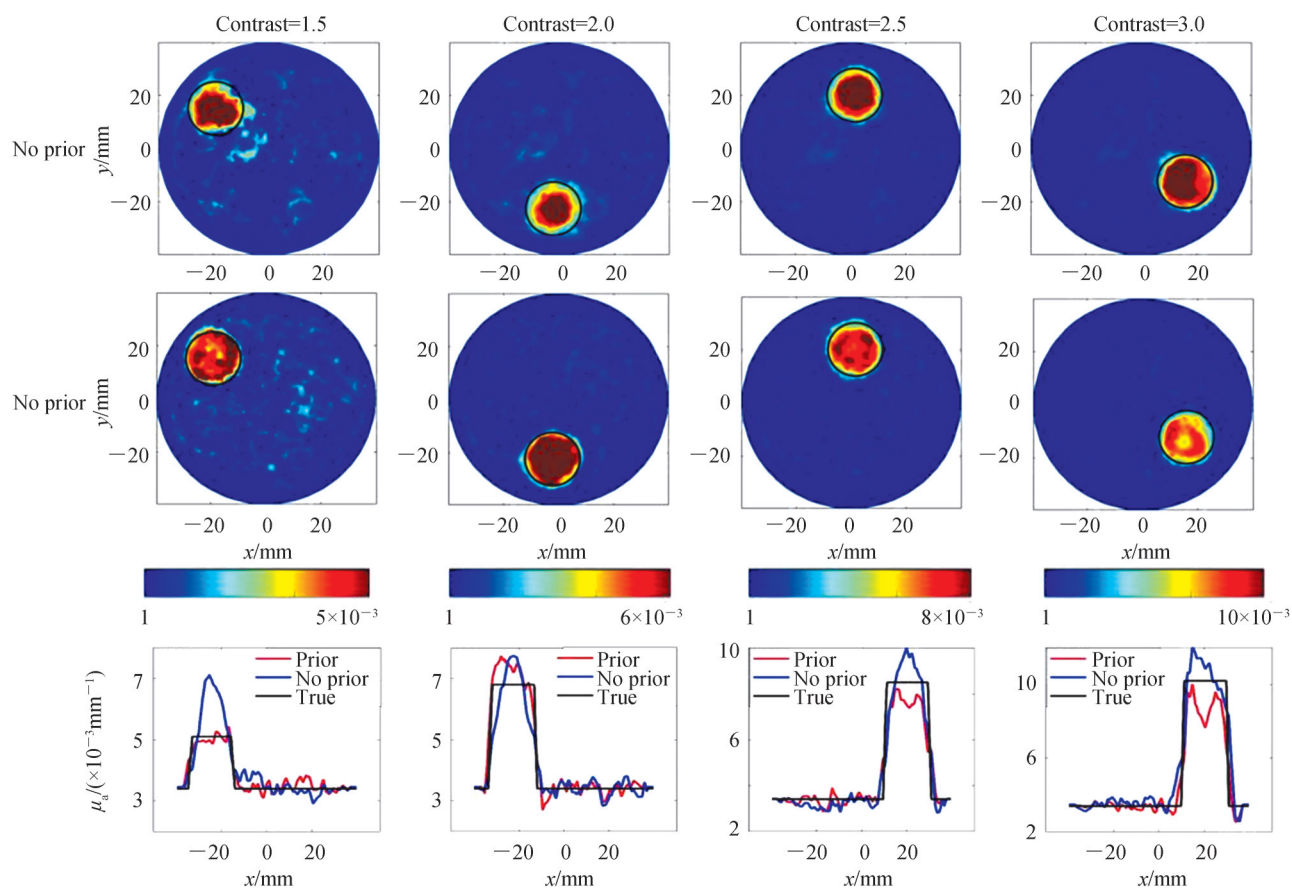


图6 不同吸收对比度下,基于无先验信息和融合先验信息的圆形单异质体重建及剖面

Fig. 6 Reconstructed images and profiles of a single circular target with different absorption contrasts based on no prior and prior methods

为进一步定量比较两种方法,表1列出了重建图像的MAE、MSE和QR值,且为了容易对比,给出了表1对应的条形图(图7)。从表1和图7可以发现,融合先验信息方法的重建图像的MAE均明显小于无先验信息方法所得的值,而MSE仅在吸收对比度为2时略微大于无先验信息方法对应的值。其原因是吸收对比度为2时,无先验信息方法获取的图像较真实值偏小,导致其标准偏差值偏小。此外,融合先验信息方法重建图像的QR值也更加接近100%。定量分析表明融合先验信息方法图像重建质量更高。

2)随机分布的圆形异质体,吸收对比度固定为3.0,半径分别为6 mm、8 mm和10 mm。图8是采用融合先验信息和无先验信息两种方法获得的重建图像以及对应的异质体吸收系数剖面。可以观察到两种方法均可较准确地重建图像,但是,小半径时,融合先验信息方法重建图像的轮廓更加清晰,且量化度更优。

表 1 圆形单异质体不同目标-背景吸收系数对比度重建图像评估指标计算结果
 Table 1 Calculation results of evaluation indexes for a single circular target reconstruction with different absorption contrasts

Metric	MAE		MSE		QR	
Contrast	Prior	No prior	Prior	No prior	Prior	No prior
1.5	9.07×10^{-5}	1.47×10^{-4}	1.18×10^{-4}	1.32×10^{-4}	107%	139%
2.0	1.48×10^{-4}	1.70×10^{-4}	2.68×10^{-4}	2.46×10^{-4}	128%	127%
2.5	1.49×10^{-4}	1.72×10^{-4}	3.38×10^{-4}	3.47×10^{-4}	96%	119%
3.0	1.88×10^{-4}	2.27×10^{-4}	3.89×10^{-4}	4.87×10^{-4}	99%	131%




图 7 表 1 对应的条形图
 Fig. 7 Bar charts corresponding to Table 1

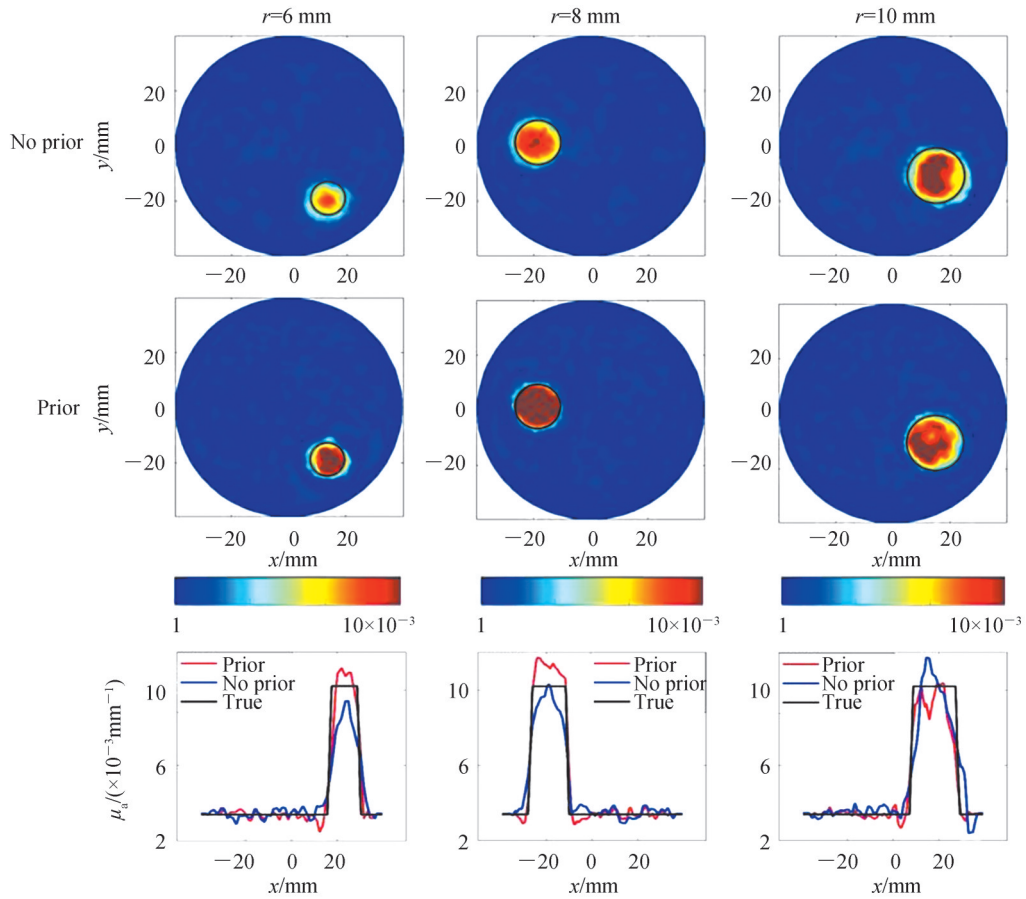


图 8 不同半径下基于无先验信息和融合先验信息的圆形单异质体重建及剖面
 Fig. 8 Reconstructed images and profiles of a single circular target with different radii based on no prior and prior methods

表2和图9分别是重建图像的MAE、MSE和QR值以及对应的条形图。进一步定量比较可以发现融合先验信息方法重建图像的MAE在不同半径下均优于无先验信息方法的重建值,表明重建图像与真实图像差距较小。与第一种情况相同,融合先验信息方法重建图像的MSE值没有显示出绝对优势。从QR值可以看出,无先验信息方法的QR值在小半径和大半径时分布显示了低估和过高估计,而融合先验信息方法的QR值具有一定程度的过高估。综合对比发现,吸收对比度与异质体尺寸相比对重建结果影响较大,因此下文对椭圆形异质体重建图像结果评估时,仅研究了不同吸收对比度的情况。

表2 圆形单异质体相同吸收对比度不同半径重建图像评估指标计算结果
Table 2 Calculation results of evaluation indexes for a single circular target reconstruction with different radii and the same absorption contrasts

Metric		MAE		MSE		QR	
r/mm	Prior	No prior	Prior	No prior	Prior	No prior	
6	1.47×10^{-4}	1.83×10^{-4}	1.82×10^{-4}	1.81×10^{-4}	118%	92%	
8	1.27×10^{-4}	1.69×10^{-4}	3.34×10^{-4}	2.97×10^{-4}	118%	102%	
10	1.92×10^{-4}	2.38×10^{-4}	4.37×10^{-4}	4.64×10^{-4}	102%	128%	

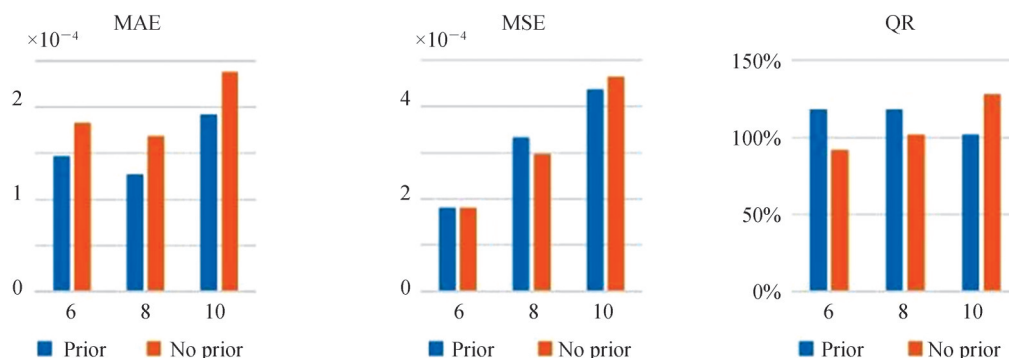


图9 表2对应的条形图
Fig. 9 Bar charts corresponding to Table 2

3) 随机分布的单个椭圆形异质体,吸收对比度分别为1.5、2.0、2.5和3.0。图10是两种方法获得的重建图像以及对应的吸收系数剖面。当异质体为椭圆形时,融合先验信息方法的图像重建结果在异质体位置、尺寸、形状以及量化度方面均优于无先验信息方法的结果。尤其当吸收系数对比度较小时,无先验信息方法重建的异质体中心位置有明显的偏差且形状有明显的膨胀。在其它吸收系数对比度下,无先验信息方法重建图像存在膨胀且边缘轮廓模糊的现象。此外,从剖面图可以看出融合先验信息方法重建图像的量化度更接近真实值,而无先验信息方法重建结果在低吸收对比度和高吸收对比度时分别表现出明显的过高估和低估。

为进一步定量比较两种方法,单个椭圆异质体重建图像的MAE、MSE和QR值比较见表3以及相应的条形图见图11。可以看到融合先验信息方法的三个评估指标均表现出明显的优势。以吸收系数对比度1.5为例,融合先验信息方法比无先验信息方法重建图像的MAE和MSE分别减少了40.1%和46.8%,且其QR值(101%)比无先验信息方法的QR值(130%)更接近100%。其它组数据也可以观察到类似结果,即融合先验信息方法重建图像的MAE和MSE显著降低,并且QR值也更接近100%。这些结果表明融合先验信息方法重建图像有更高的精度。

4) 随机分布的双椭圆异质体,吸收系数对比度分别为1.5、2.0、2.5和3.0。图12中,两种方法均可有效预测异质体的位置。比较两种方法获取的重建图像可以看到,无先验信息方法重建图像的背景伪影较多,异质体的边缘轮廓也不够清晰,且除吸收对比度为2.5外,同一仿体中两个相同的异质体的重建结果在形状、尺寸和量化度上有明显的差异。进一步观察吸收系数剖面可以看到融合先验信息方法的剖面更接近真实值,而无先验信息方法获取的吸收系数在低吸收对比度时量化度较差,随着吸收对比度增大吸收系数有明

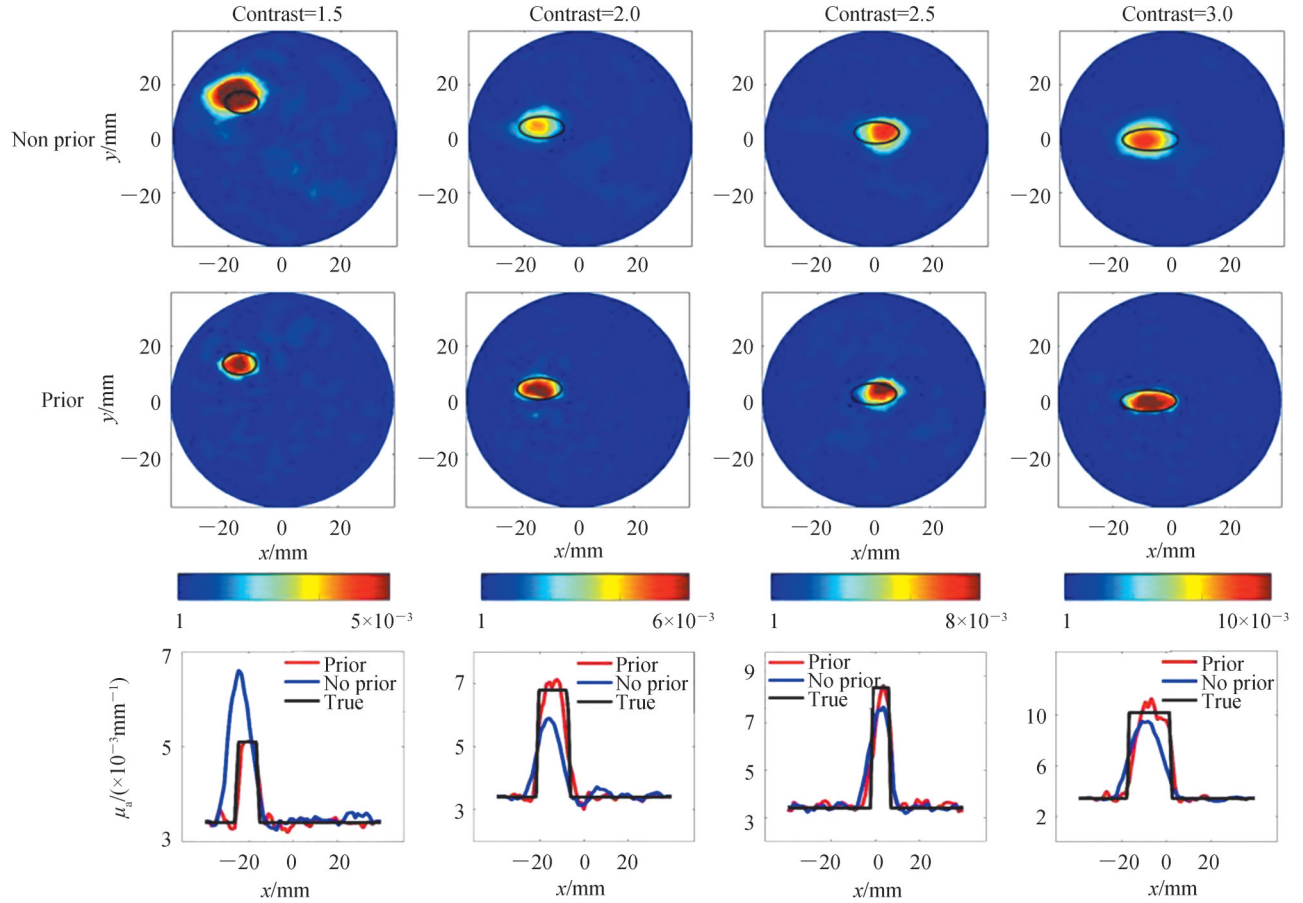


图 10 不同吸收对比度下,基于无先验信息和融合先验信息的椭圆形单异质体重建及剖面

Fig.10 Reconstructed images and profiles of a single elliptic target with different absorption contrasts based on no prior and prior methods

表 3 椭圆形单异质体不同目标-背景吸收系数对比度重建图像评估指标计算结果

Table 3 Calculation results of evaluation indexes for a single elliptic target reconstruction with different absorption contrasts

Metric	MAE		MSE		QR	
Contrast	Prior	No prior	Prior	No prior	Prior	No prior
1.5	5.09×10^{-5}	8.71×10^{-5}	4.60×10^{-4}	8.65×10^{-4}	101%	130%
2.0	7.13×10^{-5}	8.70×10^{-5}	1.02×10^{-4}	1.32×10^{-4}	108%	76%
2.5	1.25×10^{-5}	1.66×10^{-4}	9.62×10^{-5}	1.72×10^{-4}	102%	94%
3.0	1.35×10^{-4}	1.46×10^{-4}	2.17×10^{-4}	2.54×10^{-4}	109%	89%

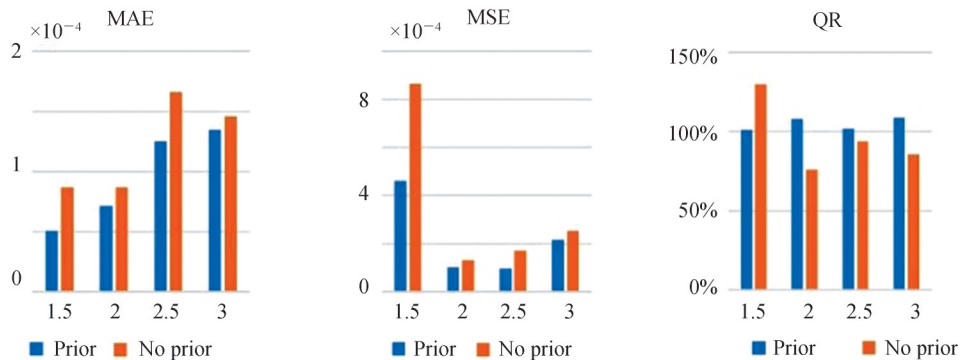


图 11 表 3 对应的条形图

Fig. 11 Bar charts corresponding to Table 3

显的过高估现象,而融合先验信息方法在不同吸收对比度情况下均与真实值接近。

表4为图12各组图像的MAE、MSE和QR值,并绘制对应条形图13。同样以吸收系数对比度1.5为例,融合先验信息方法重建的图像比无先验信息方法重建图像的MAE和MSE分别减少了34.9%和53.7%,并且QR值分别是98%和56%,融合先验信息方法的QR值更接近100%,表4中的其它数据也可以观察到类似结果。总体来说,可以看出融合了先验信息使得重建图像MAE和MSE都显著减少,并且QR也更加接近100%,即融合先验信息可以得到更好的重建结果。

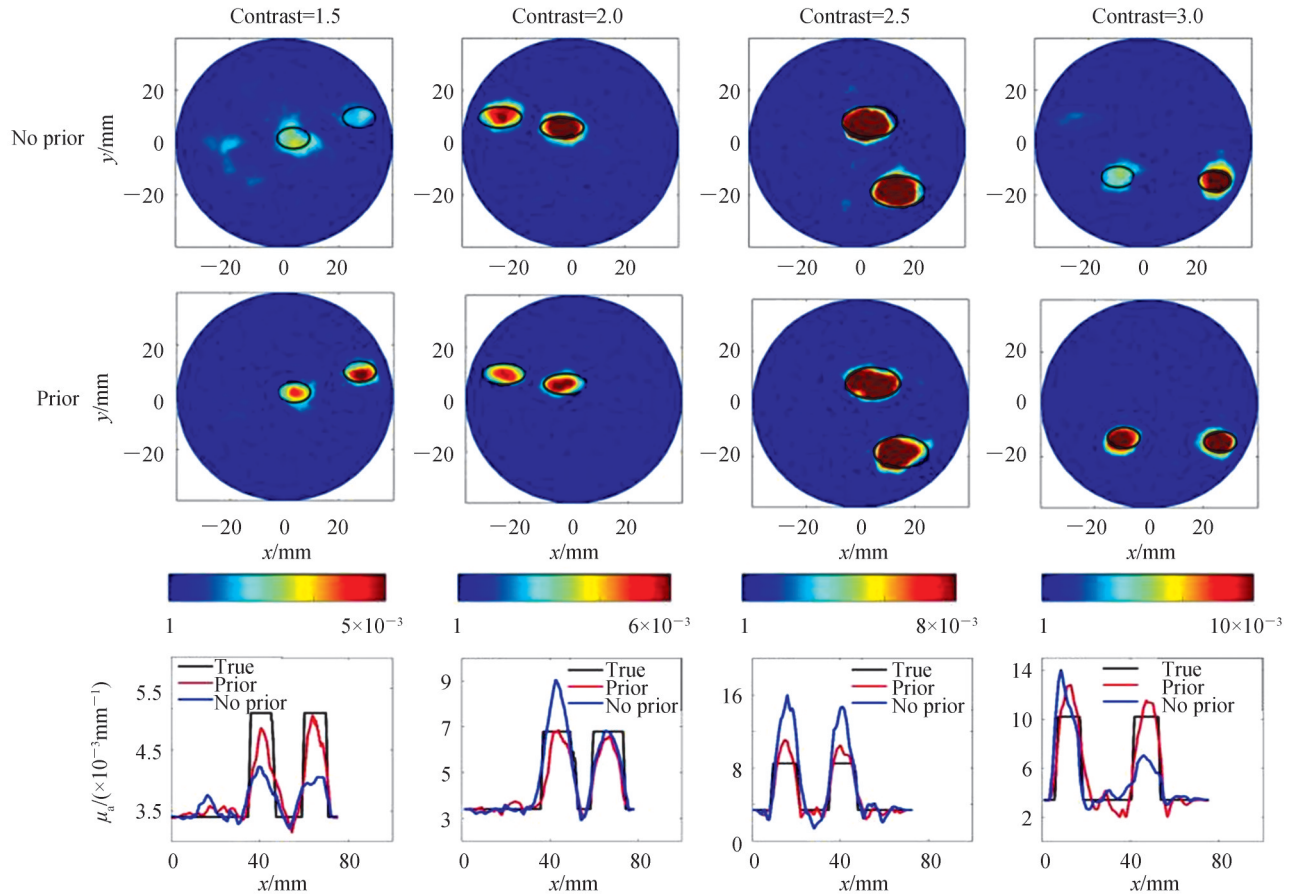


图12 不同吸收对比度下,基于无先验信息和融合先验信息的双椭圆形异质体重建及剖面

Fig. 12 Reconstructed images and profiles of double elliptic targets with different absorption contrasts based on no prior and prior methods

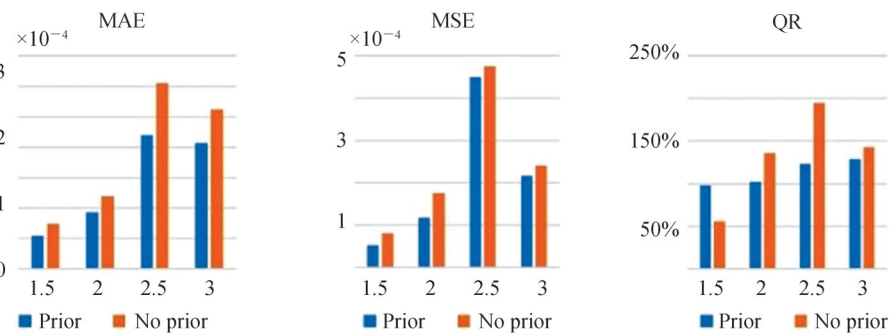


图13 表4对应的条形图

Fig. 13 Bar charts corresponding to Table 4

表 4 双椭圆异质体不同目标-背景吸收系数对比度重建图像评估指标计算结果
 Table 4 Calculation results of evaluation indexes for double elliptic targets reconstruction with different absorption contrasts

Metric	MAE		MSE		QR	
	Prior	No prior	Prior	No prior	Prior	No prior
Contrast						
1.5	5.48×10^{-5}	7.39×10^{-5}	5.28×10^{-5}	8.12×10^{-5}	98%	56%
2.0	9.32×10^{-5}	1.20×10^{-4}	1.18×10^{-4}	1.76×10^{-4}	102%	136%
2.5	2.20×10^{-4}	3.05×10^{-4}	4.50×10^{-4}	4.75×10^{-4}	123%	195%
3.0	2.07×10^{-4}	2.62×10^{-4}	2.16×10^{-4}	2.41×10^{-4}	129%	143%

3 结论

为了提高 DOT 的重建图像质量,本文发展了一种融合先验信息 SAE 神经网络方法的 DOT 图像重建方法。为验证该方法的有效性,对融合先验信息与无先验信息两种方法的实验结果进行了比较和定量评估。其中,具有不同吸收对比度和不同尺寸的圆形单异质体模拟结果表明,融合先验信息方法重建结果与真实图像更接近,且当吸收对比度比较小时,融合先验信息方法对于重建图像质量改善较为明显。在异质体吸收对比度为 1.5 时,与无先验信息方法相比,MAE 降低 62%,MSE 降低 11%,QR 由 139% 降低为 107%,更接近 100%。需要说明的是,当圆形异质体吸收对比度大于 1.5 且半径较大时,理论上更容易获得异质体图像,因此两种方法均取得了较好的图像重建质量。对于包含形状欠规则的单个和两个的异质体进行图像重建,融合先验信息方法能够让背景清晰、异质体尺寸和位置准确、异质体吸收系数更接近真实值。尤其当异质体吸收系数比较小,融合先验信息可以减小预测误差。定量分析表明,融合先验信息的方法使得重建图像的 MAE、MSE 都显著减小,与无先验信息方法相比 MAE 至少降低 8%,MSE 至少降低 5%,QR 更接近 100%。综合评估表明,融合先验信息能有效提高成像精度和改善重建图像的质量。

参考文献

- [1] ARRIDGE S R, SCHOTLAND J C. Optical tomography: forward and inverse problems[J]. Inverse Problems, 2009, 25(12):1541-1548.
- [2] YEDDER H B, SHOKOUFI M, CARDOEN B, et al. Limited-angle diffuse optical tomography image reconstruction using deep learning [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2019, 11764:66-74.
- [3] FENG Jinchao, JIANG Shudong, XU Junqing, et al. Multiobjective guided priors improve the accuracy of near-infrared spectral tomography for breast imaging[J]. Journal of Biomedical Optics, 2016, 21(9):90506.
- [4] CHEN Chen, TIAN Fenghua, LIU Hanli, et al. Diffuse optical tomography enhanced by clustered sparsity for functional brain imaging[J]. IEEE Transactions on Medical Imaging, 2014, 33(12):2323-2331.
- [5] ARRIDGE S R. Optical tomography in medical imaging[J]. Inverse Problems, 1999, 15(2):R41-R93.
- [6] CAO N, NEHORAI A, JACOB M. Image reconstruction for diffuse optical tomography using sparsity regularization and expectation-maximization algorithm[J]. Optics Express, 2007, 15(21):13695-13708.
- [7] BROOKSBY B A, DEGHANI H, POGUE B W, et al. Near-infrared (NIR) tomography breast image reconstruction with a priori structural information from MRI: algorithm development for reconstructing heterogeneities[J]. IEEE Journal of selected Topics in Quantum Electronics, 2003, 9(2): 199-209.
- [8] 邓勇, 张喧轩, 罗召洋, 等. 融合结构先验信息的稳态扩散光学断层成像重建算法研究[J]. 物理学报, 2013, 62(1): 014202.
- [9] FENG Jinchao, SUN Qiuwan, LI Zhe, et al. Back-propagation neural network-based reconstruction algorithm for diffuse optical tomography.[J]. Journal of Biomedical Optics, 2018,24(5):051407.
- [10] YEDDER H B, TAIB A B, SHOKOUFI M, et al. Deep learning based image reconstruction for diffuse optical tomography[C]. Machine Learning for Medical Image Reconstruction, 2018, 11074:112-119.
- [11] YOO J, SABIR S, HEO D, et al. Deep learning diffuse optical tomography[J]. IEEE Transaction on Medical Imaging, 2020, 4:877-887.
- [12] HOSSEINZADEH M, AHMED O H, M YGHAFOR et al. A multiple multilayer perceptron neural network with an adaptive learning algorithm for thyroid disease diagnosis in the internet of medical things[J]. Journal of Supercomputing, 2020, 77(4):3616-3637.
- [13] DEGHANI H, EAMES M E, YALAVARTHY P K, et al. Near infrared optical tomography using NIRFAST:

- Algorithm for numerical model and image reconstruction [J]. *Communications in Numerical Methods in Engineering*, 2009, 25(6):711-732.
- [14] ALI A, FAN Y Y. Unsupervised feature learning and automatic modulation classification using deep learning model [J]. *Physical Communication*, 2017, 25:75-84.
- [15] OHZEKI M. Statistical-mechanical analysis of pre-training and fine tuning in deep learning [J]. *Journal of the Physical Society of Japan*, 2015, 84(3): 034003.
- [16] GEDDES T A, KIM T, NAN L, et al. Autoencoder-based cluster ensembles for single-cell RNA-seq data analysis [J]. *BMC Bioinformatics*, 2019, 20(1): 660-671.
- [17] POGUE B W, SONG X, TOSTESON T D, et al. Statistical analysis of nonlinearly reconstructed near-infrared tomographic images: Part I-theory and simulations [J]. *IEEE Transactions on Medical Imaging*, 2002, 21(7):755-763.
- [18] SONG Xiaomei, POGUE B W, TOSTESON T D, et al. Statistical analysis of nonlinearly reconstructed near-infrared tomographic images: Part II—experimental interpretation. [J]. *IEEE Transactions on Medical Imaging*, 2002, 21(7): 764-771.
- [19] CUADROS A P, ARCE G R. Coded aperture optimization in compressive X-ray tomography: a gradient descent approach [J]. *Optics Express*, 2017, 25(20):23833-23849.

Diffuse Optical Tomography Method Based on Multi-information Fusion and Stacked Auto-encoder Network

SUN Zhilong¹, ZHANG Jie², LIU Zongyang², GAO Feng^{2,3}, ZHANG Limin^{2,3}

(1 *Tianjin International Engineering Institute, Tianjin University, Tianjin 300072, China*)

(2 *College of Precision Instrument and Optoelectronics Engineering, Tianjin University, Tianjin 300072, China*)

(3 *Tianjin Key Laboratory of Biomedical Detecting Techniques and Instruments, Tianjin 300072, China*)

Abstract: Diffuse Optical Tomography (DOT) is a new functional optical imaging technique that demonstrates the potential applications in breast tumor imaging and functional brain imaging. It has the advantages of being non-invasive, non-ionizing radiation, and providing physiological information about biological tissues. The image reconstruction process of DOT, that is, the inverse problem, is ill-posed, resulting in a low degree of quantification and spatial resolution of the reconstructed image. Traditional DOT image reconstruction methods cannot completely solve the problem of low imaging accuracy, mainly reconstruct the target with a regular shape (circle). In recent years, artificial neural networks have been widely used in the field of image reconstruction with their strong feature extraction and recognition capabilities. In this paper, Stacked Auto-Encoder (SAE) neural network is proposed to improve the DOT image quality. SAE is a relatively simple model where fewer network parameters need to be adjusted, and therefore the training speed is fast. SAE network consists of two autoencoders, which are unsupervised learning neural network models, including encoder and decoder. The encoder works by extracting the features of the input data to the hidden layer, while the decoder reconstructs the input data from the hidden layer. A fully connected layer after the autoencoder is added as the output layer of SAE. The SAE network training process consists of two stages. The first stage is unsupervised pre-training for getting initial weights and bias values. The second stage is that based on the principle of error backpropagation, the network minimizes the loss function by calculating the mean squared error between the predicted output value and the expected output value, then optimizes the weights and biases in the network model, and finally reconstructs the optical parameter image. For practical applications, anatomical prior information incorporated into SAE neural network is utilized to reconstruct DOT images with the targets of different shapes (circle and ellipse). To simulate the tumor in breast tissues, a two-dimensional circular phantom with a radius of 40 mm is used to simulate background tissue, and the circular and elliptical targets are respectively embedded in the background phantom to simulate breast tumors. Sixteen coaxial source-detector optodes are equally arranged around the phantom boundary. For each illumination, except the 4 detectors nearest to the source position, the remaining 11 detectors are used to measure the light intensities on the boundary, leading to a total of 16×11 (176) measurements. To more closely simulate the real case, 40 dB noise is added to the measurement data. Based on the numerical optical phantoms, the corresponding

MRI images with the size of 51×51 are simulated to provide anatomical prior information. In SAE network, the normalized measurement data and the normalized gray values of the MRI image are utilized as the neural network inputs, and the optical parameters of the finite element nodes are used as the outputs to obtain DOT image. In order to verify the feasibility and effectiveness of the proposed method, a series of numerical simulation experiments with and without prior information are carried out. The experimental results are assessed and compared quantitatively using the Mean Absolute Error (MAE), Mean Square Error (MSE) and Quantitativeness Ratio (QR). The experimental results of the single circular target with different absorption contrast and different size show that the reconstruction results of the prior information-based SAE method are closer to the real image, and when the absorption contrast is low (1.5), the MAE of the fusion prior information method is reduced by 62%, the MSE is reduced by 11%, and the QR value is reduced from 139% to 107% which is closer to 100%, compared with no prior information method. It is worth mentioning that when the absorption contrast is larger than 1.5 and the radius is larger, both methods can achieve better image reconstruction quality since it is easier to recover the target in theory. For the image reconstruction of single and double targets of elliptic shapes, the prior information-based SAE method can accurately recover the size and position of the target and demonstrates high noise robustness and quantitativeness. Especially, when the absorption contrast is relatively small, the prior information-based SAE method can reduce the prediction error effectively. In addition, the quantitative analysis and comparison show that the MAE and MSE are significantly reduced by using the prior information-based SAE method. We find that the MAE is reduced by at least 8%, MSE is reduced by at least 5%, and the value of QR is closer to 100%. The comprehensive evaluation indicates that our proposed method can effectively improve the imaging accuracy and the quality of DOT reconstruction images.

Key words: Diffuse optical tomography; Prior information; Stacked auto-encoder neural network; Breast tumor; Image reconstruction

OCIS Codes: 170.3010; 170.3880; 170.3660; 170.6960