

基于深度卷积编解码网络的 fNIRS 成像技术研究

李铁妮¹, 刘东远¹, 张鹏睿¹, 李志勇¹, 高峰^{1,2*}¹天津大学精密仪器与光电子工程学院, 天津 300072;²天津市生物医学检测技术与仪器重点实验室, 天津 300072

摘要 在功能性近红外光谱 (fNIRS) 成像技术的实现中, 扩散光学层析成像 (DOT) 具有改善定量性和分辨率的巨大潜力, 但其效果受制于生理干扰 (呼吸、心跳和低频振荡等)、检测系统的随机噪声以及有限测量数据量带来的不适应性。为增强 fNIRS-DOT 成像的性能, 本文提出了一种基于模型先验信息的深度卷积编解码网络重建方法, 利用分层半三维重建算法实现对表层和深层脑血氧变化信息的初步区分, 发挥卷积、编解码网络对空间特征的学习能力, 实现对深层脑激活信息的提取重建。为验证所提重建方法的有效性, 开展了数值模拟和仿体实验, 并将其与传统重建方法进行对比。结果表明, 所提重建法不仅可以显著提高重建精度, 极大地缩短重建时间, 而且具有优异的泛化能力, 为实现动态 fNIRS 成像提供了重要参考。

关键词 生物光学; 功能性近红外光谱成像; 分层半三维重建; 深度卷积编解码网络

中图分类号 TN219 文献标志码 A

DOI: 10.3788/CJL230734

1 引言

功能性近红外光谱 (fNIRS) 成像以其应用简易性、便携/可穿戴性、低体位约束性, 为神经活动测量提供了解决方案, 已作为传统神经成像技术的重要补充被应用于脑功能临床研究领域^[1-2]。近年来, 研究人员开始聚焦于扩散光学层析成像 (DOT) 技术。该技术以高精度光子输运模型和高密度源探交叠阵列作为支撑, 可有效提高成像方法的重建精度和空间分辨率^[3-4]。将该技术与非线性迭代等方法结合可以实现组织体内部光学参数的重建。然而, 生物组织具有高散射特性, 而且 DOT 探测的数据量与待重建参数数量相差悬殊, 导致其逆问题存在严重的不适应性。此外, 重建过程的准确性还会受呼吸、心跳、低频振荡等生理噪声以及随机噪声的影响^[5]。研究人员常利用传统代数重建法 (ART)、正则化方法等应对上述问题, 但这些方法存在计算成本高、重建耗时长、重建结果精度不足等弊端^[6-9]。

目前, 深度学习算法已被广泛应用于医用光学成像领域的逆问题研究中^[10], 其中既包括测量-图像的“端到端”图像重建, 也包括基于模型的图像重建方法。该类算法具有重建时间短、重建图像质量高等优势, 已初步展现出卓越的应用潜力, 但“端到端”图像重建往往需要通过对大量数据集进行学习才可以准确建立输入输出间的对应关系^[11-12]。基于此, 笔者提出了一种

基于半三维 DOT (S3D-DOT) 模型先验信息的深度卷积编解码网络 (DCNN) 重建算法, 旨在将 S3D-DOT 技术缓解逆问题不适应性优势与深度学习算法提取空间激活特征信息的优势融合, 实现图像重建质量的显著提高。笔者通过一系列数值模拟和仿体实验验证了所提算法的有效性、优异的可移植性和泛化能力, 并在此基础上探讨了以时间信息为第三维度的 3D-DCNN 模型对任务相关吸收变化信息的动态重建能力, 为实时 fNIRS-DOT 成像提供了新的解决思路。

2 基本原理

2.1 S3D-DOT 分层重建算法

从解剖学角度来看, 大脑组织呈现分层特点。考虑到脑脊液层的特性和近红外光穿透深度, 本研究将大脑模型简化为头皮颅骨 (SS) 层和灰质 (CC) 层结构, 同时结合实际深度分布情况又将 SS 层和 CC 层分别称为表层和深层。S3D-DOT 分层重建算法缓解不适应性的核心是假设各层光学参数在深度方向上不发生变化, 以此获得高精度光子输运模型支持的分层吸收变化图像。具体表述为, 分别沿着 SS 层和 CC 层的深度方向对敏感度矩阵进行积分, 得到各层的 S3D 敏感度矩阵 J_{SSD}^{SS} 和 J_{SSD}^{CC} , 此时边界光强变化信息可以表示为各层的敏感度矩阵与该层 X-Y 平面吸收变化的乘积^[13], 即

收稿日期: 2023-04-17; 修回日期: 2023-05-25; 录用日期: 2023-05-29; 网络首发日期: 2023-06-15

基金项目: 国家自然科学基金 (62075156, 62205239)

通信作者: *gaofeng@tju.edu.cn

$$\delta M = \begin{bmatrix} J_{S3D}^{SS} & J_{S3D}^{CC} \\ \delta \mu_a^{SS} \\ \delta \mu_a^{CC} \end{bmatrix}, \quad (1)$$

式中： $\delta M = [\delta M(\xi_1, \zeta_1) \delta M(\xi_2, \zeta_2) \cdots \delta M(\xi_D, \zeta_S)]^T$ 表示位于点 ζ 的光源和位于点 ξ 的探测器组成的探测通道测得的光强变化, S 表示光源总数, D 表示探测位置总数; $\delta \mu_a^{SS}$ 和 $\delta \mu_a^{CC}$ 分别表示 SS 层和 CC 层的吸收变化数据矩阵。在实际应用中, 由于生理干扰和激活分布存在交织混叠, CC 层的 S3D-DOT 重建结果中仍存在一定的干扰信息, 本文借助深度学习算法来进一步提高图像的重建准确度。

2.2 DCNN 网络重建算法

2.2.1 训练数据集

大脑血氧含量随时间波动变化的规律可反映不

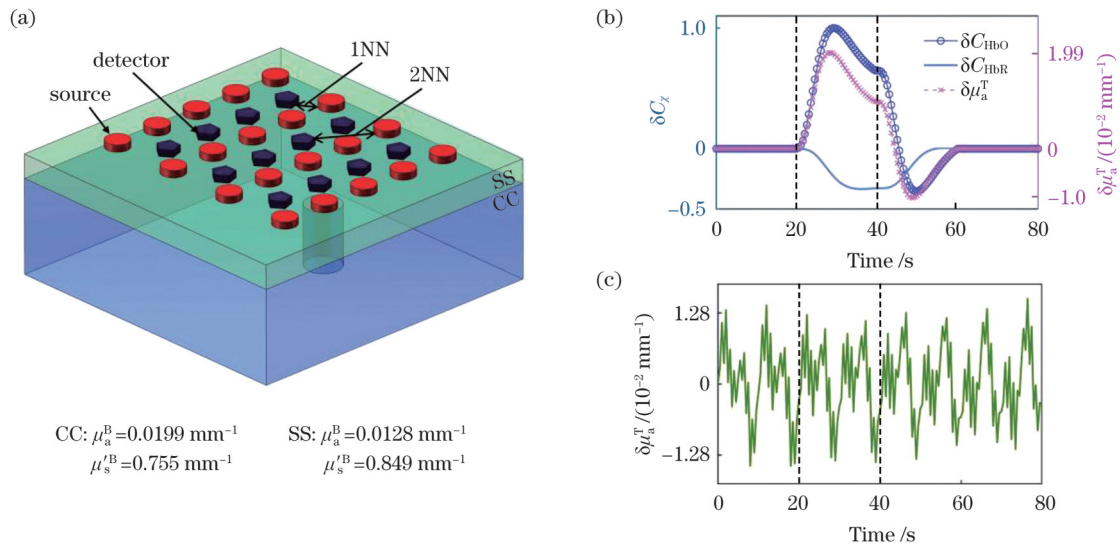


图1 训练数据集设置方式。(a)双层颅脑模型;(b) $\theta_T=1$ 时CC层任务相关的HbO、HbR浓度变化曲线以及吸收变化;(c) $\theta_I=1$ 时由生理干扰引起的SS层吸收变化波动曲线

Fig. 1 Setup of training dataset. (a) Two-layer brain-emulating model; (b) task-related HbO and HbR concentration change curves and the absorption perturbation in CC layer when $\theta_T=1$; (c) time courses of the absorption perturbation induced by the physiological interferences in SS layer when $\theta_I=1$

为模拟任务相关兴奋的相关情况,采用双伽马函数表示标准血流动力学响应(cHRF),将双伽马函数与任务函数进行卷积计算得到脱氧血红蛋白(HbR)和

同脑区的工作状态,对于探索大脑工作机制和临床诊断具有重要意义。为对所提算法进行合理验证,采用典型测量范式完成数据集构建:总时长80 s,前后分别设置20 s和40 s的基线态,20~40 s之间为任务状态,模拟采样频率为2 Hz。采用尺寸为130 mm×130 mm×50 mm双层平板模型模拟人脑结构,SS层厚度为12 mm,CC层厚度为38 mm。在CC层嵌入圆柱体模拟实际兴奋区,圆柱体的厚度为25 mm,半径7.5 mm,如图1(a)所示。 μ_a^B 为背景吸收系数, μ_s^B 为背景约化散射系数。采用6927个节点组成的36973个四面体单元对模型进行剖分,入射波长为830 nm,利用扩散方程获得20源×12探交叠布配下第一近邻(1NN)和第二近邻(2NN)通道的测量信息。

氧合血红蛋白(HbO)的浓度变化 δC_x ,其中 $x \in \{\text{HbO}, \text{HbR}\}^{[14]}$ 。对 δC_x 与消光系数 ϵ_x 的乘积求和,获得任务相关的吸收系数变化,即

$$\delta \mu_a^T(\lambda_w, \mathbf{r}, t_i) = \theta_T \frac{\sum_x \epsilon_x \delta C_x(t_i)}{\max \left[\sum_x \epsilon_x \delta C_x(t_i) \right]} \mu_a^B(\lambda_w, \mathbf{r}, t_i), \mathbf{r} \in \Omega_{CC}^T, \quad (2)$$

式中: θ_T 表示由任务刺激引起的吸收系数变化的幅度; $\mu_a^B(\lambda_w, \mathbf{r}, t_i)$ 表示特定波长和位置下的背景吸收系数; Ω_{CC}^T 表示CC层的兴奋区域。

为模拟生理干扰对重建结果的影响,选用空间幅度呈高斯分布的正弦波形分别表示心跳、呼吸和低频振荡,三种干扰的高斯分布中心点互不相同。任务相关的吸收系数变化为

$$\begin{cases} \delta \mu_a^I(\lambda_w, \mathbf{r}, t) = \frac{\theta_I \Psi_I(\mathbf{r}, t)}{\max [\Psi_I(t)] \mu_a^B(\lambda_w, \mathbf{r}, t)}, \\ \Psi_I(\mathbf{r}, t) = A_c^G(\mathbf{r}) \sin(2\pi f_c t) + A_r^G(\mathbf{r}) \sin(2\pi f_r t) + A_m^G(\mathbf{r}) \sin(2\pi f_m t) \end{cases}, \quad (3)$$

式中: $A_c^G(r)$ 、 $A_r^G(r)$ 和 $A_m^G(r)$ 分别表示心跳、呼吸和低频振荡空间幅度的高斯分布; f_c 、 f_r 和 f_m 表示心跳、呼吸和低频振荡的频率, 分别设置为 1.1、0.2、0.095 Hz; θ_1 表示生理干扰相关吸收变化的最大幅度。此外, 为模拟随机噪声, 在测量数据中增加了最低信噪比达 10 dB 且强度与光强平方根成正比的高斯噪声。

在模拟数据集中设置三种不同的 θ_T/θ_1 组合来丰富数据集, 以兼顾不同脑区以及受试对象之间生理干扰、任务相关吸收变化的幅度差异。设置 θ_T/θ_1 组合分别为 0.5/0.2、0.2/0.2、0.1/0.5。共计生成 4000 组模拟数据用于网络训练, 其中训练集和验证集比例为 9:1。

2.2.2 网络模型结构

如前所述, 可通过分层 S3D-DOT 算法获得大脑各层的激活图像。以 CC 层结果作为输入信息完成

DCNN 网络模型的搭建, DCNN 网络模型结构如图 2 所示。该网络使用编码器-解码器结构, 其中, 编码网络将输入数据的特征提取至隐藏层, 解码网络将目标信息从隐藏层中重构至输出层。本模型的输出信息是显示 CC 层吸收系数变化的高精度重建图像。编码网络共设三个单元, 卷积层、批标准化、激活层和最大池化层组成一个单元。编码网络中卷积核的大小设置为 3×3 , 以最大限度保留输入图像中的真实兴奋信息; 各单元中卷积核的数量依次成二倍增加, 以对所提取的信息进行充分利用。在解码网络中, 通过解卷积层实现上采样(以还原图像信息), 借助全零填充和卷积层的设置保证输出图像与输入图像大小一致。为与网络输出数据格式相匹配, 在进行网络训练时将待学习的真实图像格式调整为 1×2500 , 网络训练完成后对输出数据进行格式还原得到重建图像。

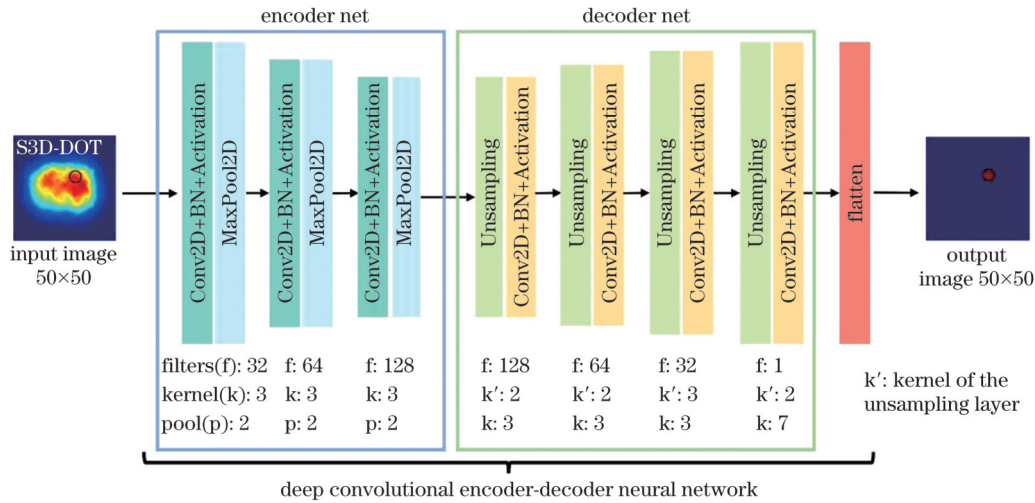


图 2 DCNN 网络模型结构

Fig. 2 DCNN model structure

2.2.3 网络训练设置和性能评估指标

对 DCNN 进行训练时采用初始化的权重和偏差变量, 利用梯度优化算法有监督地更新权重, 选用均方误差作为损失函数, Tanh 函数作为激活函数, 利用 Adam 优化器完成梯度优化, 学习率为 0.0001。采用 4 个定量指标对所提算法的重建性能进行评估, 这 4 个定量指标分别为绝对偏差误差 ABE、均方误差 MSE、空间保真度 DF 和结构相似性指数 SSIM, 它们在公式中分别记为 I_{ABE} 、 I_{MSE} 、 I_{DF} 、 I_{SSIM} 。

$$\left\{ \begin{array}{l} I_{ABE} = \frac{\sum_{i=1}^N |x_{true(i)} - x_{recon(i)}|}{N} \\ I_{MSE} = \frac{\sum_{i=1}^N (x_{true(i)} - x_{recon(i)})^2}{N} \\ I_{DF} = \omega/D_{ROI} \\ I_{SSIM} = \frac{(2\bar{x}_{true}\bar{x}_{recon} + c_1)(2\sigma_{true}\sigma_{recon} + c_2)}{(\bar{x}_{true}^2 + \bar{x}_{recon}^2 + c_1)(\sigma_{true}^2 + \sigma_{recon}^2 + c_2)} \end{array} \right. , (4)$$

式中: $x_{true(i)}$ 和 $x_{recon(i)}$ 分别表示有限元节点 i 处的真实吸收系数和重构吸收系数; ROI 表示兴奋区域; ω 表示重建 ROI 的半峰全宽; D_{ROI} 表示 ROI 的直径; \bar{x}_{true} 和 \bar{x}_{recon} 分别表示真实吸收系数和重构吸收系数的平均值; σ_{true} 和 σ_{recon} 分别表示真实吸收系数和重构吸收系数的协方差; c_1 和 c_2 是防止被小分母除而设的固定常数, 本文中取 0.000001; N 表示节点个数。ABE、MSE 用于衡量重建图像与真实图像的接近程度, DF 用于衡量重建图像的空间分辨能力, SSIM 用于衡量重建吸收变化图像与真实图像之间的结构差异。理论上, 重建图像的精度越高, ABE 和 MSE 的数值越小, DF 和 SSIM 越接近于 1。

3 实验验证

3.1 数值模拟实验

在传统的 DOT 重建中, 最典型的重建方法是 ART 迭代方法。该方法可基于矩阵行计算提供绝对的定量解, 并凭借强鲁棒性得到了广泛应用, 但其存在

定量性不足、迭代缓慢等缺点^[15-16]。为评估所提算法的有效性和可移植性,单独设置与上述训练数据集不同的 400 组测试数据($\theta_T=0.5, \theta_I=0.1$),并将 DCNN 与 ART 的重建结果进行对比分析。网络训练过程中每次迭代送入样本数为 16,共计训练 400 次。图 3(a)展示了部分时间点下的重建图像,结果表明,基于模型先验的 DCNN 算法可以有效抑制干扰信号的影响,在微弱兴奋时间点下优势更加明显,具有优异的泛化能

力。图 3(b)为评估指标计算结果,可见:与 ART 相比,DCNN 的各项评估指标均得到了有效提升。对 400 组测试数据所得重建结果进行评估,结果显示:与 ART 相比,DCNN 方法的 ABE 平均降低了 7.28%,MSE 平均降低 67.73%,DF 平均提升了 70%;DCNN 方法的 SSIM 平均值大于 0.998。此外,DCNN 重建用时 5.67 s,ART 平均用时 482.97 s,DCNN 相比 ART 展现出了显著的时间优势。

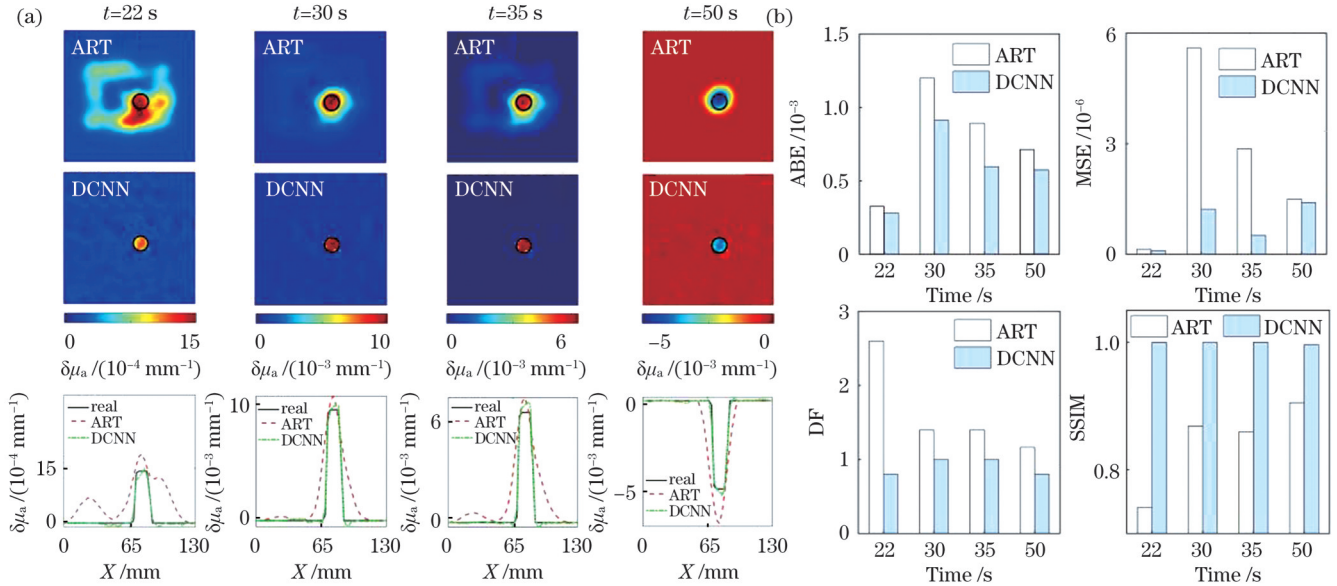


图 3 弱干扰下 DCNN 网络的数值模拟结果。(a)CC 层吸收系数变化重建图像的对比;(b)重建结果的定量评估

Fig. 3 Simulation results of DCNN under weak interference. (a) A comparison of reconstructed absorption efficiency perturbation images in CC-layer; (b) quantitative evaluation of reconstruction

进一步地,对强噪声干扰下的算法性能进行了评估,调整 θ_T 为 0.2, θ_I 为 0.5,其他参数保持不变,生成 400 组测试数据。同样,将初步重建图像分别放入 DCNN 和 ART 网络中进行优化,部分时间点下的重建结果对比如图 4 所示。可见,强噪声下传统重建算

法已无法准确重建兴奋分布,而 DCNN 仍能对兴奋分布进行有效重建,空间信息提取能力得到验证。结合剖面图可知强干扰下 DCNN 网络对背景的重建质量有所下降,这是由于为保证重建结果的高准确度,选用了背景平滑程度有限的 Tanh 激活函数。计算 DCNN

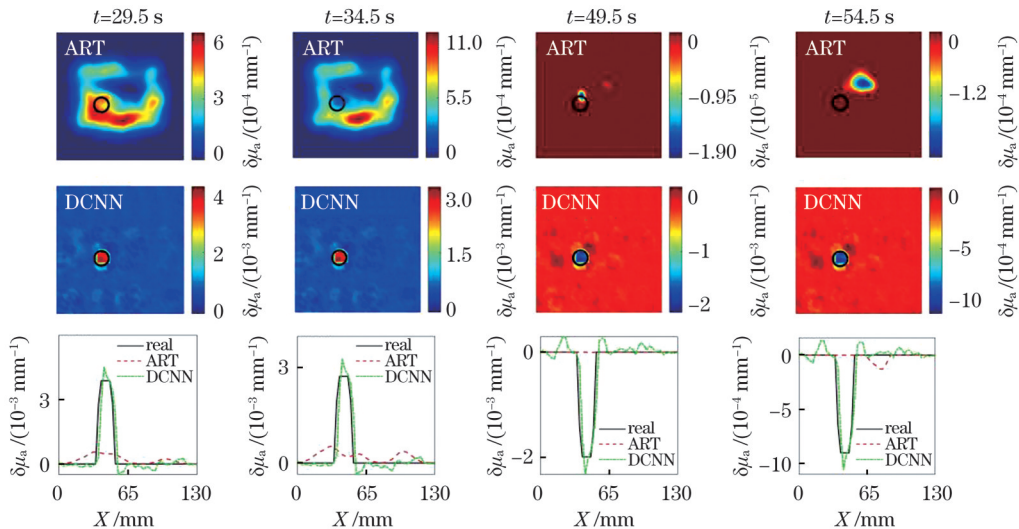


图 4 强干扰下 DCNN 网络的数值模拟结果

Fig. 4 Simulation results of DCNN under strong interference

重建结果的评估指标, ABE 均值为 7.09×10^{-4} , MSE 均值为 1.28×10^{-6} , DF 均值为 0.93, SSIM 均值为 0.99, 空间保真度和结构相似性表现优异。总体来说, 重建精度仍得到了保证。

接着, 为验证 DCNN 网络对复杂兴奋区域的重建能力, 开展了双目标体数值模拟实验。在该实验中, 双层颅脑模型结构保持不变, 在 CC 层设置双圆柱作为兴奋区域, 双圆柱的位置随机, 半径均为 7.5 mm, 两圆

柱无交叠, 其他参数与单目标体强干扰实验保持一致, 生成 4000 组双目标体数据并以 8:1:1 的比例完成网络训练和测试。部分时间点下的重建结果如图 5 所示, 可见, DCNN 网络可以基本实现对双目标体设置下兴奋区域的位置识别和干扰信息滤除, 但在该复杂重建情景下, 背景平滑程度受限。此时, DCNN 的 DF 均值为 0.95, SSIM 均值为 0.98, 识别准确度高, 结构相似性强, 空间分辨能力得到有效提升。

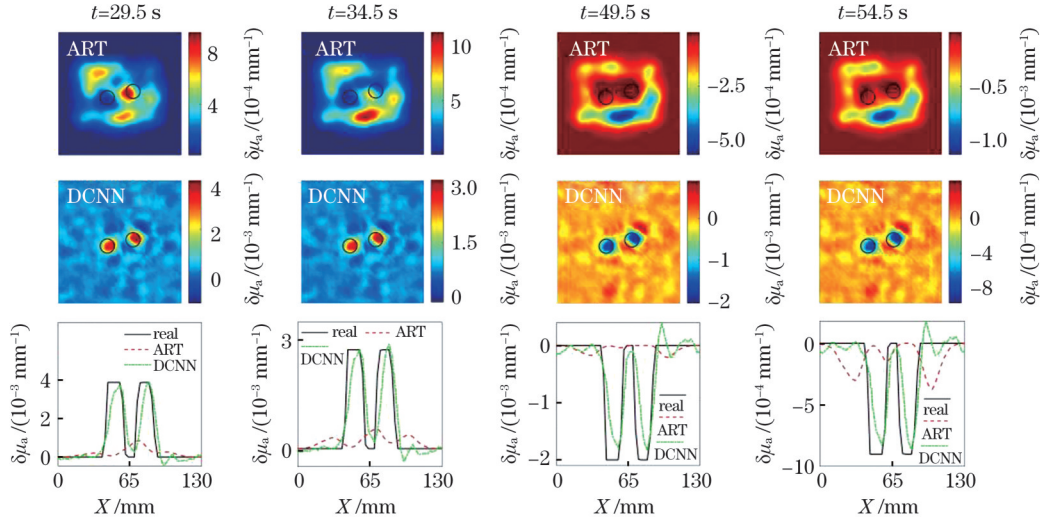


图 5 双目标体重建图像

Fig. 5 Reconstructed images of double targets

3.2 仿体实验

标准组织仿体实验不仅可为算法评估提供客观标准, 而且是开展临床试验前不可或缺的检测步骤, 可为算法的优化更新提供重要参考。为保证模型一致, 制作了如图 6 所示的规格为 $130 \text{ mm} \times 130 \text{ mm} \times 50 \text{ mm}$ 的聚甲醛仿体 ($\mu_a^b = 0.0040 \text{ mm}^{-1}$, $\mu_s^b = 1 \text{ mm}^{-1}$), 其中: 表层厚度为 12 mm, 表层中设置了 4 个贯穿孔作为生理干扰区域, 贯穿孔的直径分别为 5.5 mm 和 8.5 mm; 深层中设置了半径为 7.5 mm、深度为 38 mm

的圆柱形凹槽作为激活区域。利用印度墨水稀释液、脂肪乳和蒸馏水配制液态仿体(模拟兴奋), 吸收对比度分别为背景的 1 倍、1.2 倍、1.5 倍。采用倒置测量方式, 将深层作为上层, 表层作为下层。借助硅胶软管配合蠕动泵将液态仿体灌注至背景仿体的凹槽和贯穿孔中, 分别用于模拟兴奋区域和生理干扰区。测量过程由本团队自主研发的基于锁相光子计数技术的 20 源 12 探脑功能成像系统完成, 设置系统的积分时间为 $500 \text{ ms}^{[17]}$ 。




图 6 仿体实验设置。(a) 聚甲醛仿体模型结构图; (b) 聚甲醛仿体实物图

Fig. 6 Setup of phantom experiments. (a) Structural representation of the polyformaldehyde phantom; (b) picture of the polyformaldehyde phantom

为更好地对实验结果进行阐述,对不同区域液态仿体的吸收对比度进行区分:兴奋区域的吸收对比度设为 C_T , 5.5 mm 贯穿孔内的吸收对比度设为 $C_{5.5}$, 8.5 mm 贯穿孔内的吸收对比度设为 $C_{8.5}$ 。图 7 展示了部分对比度组合下 DCNN 和 ART 方法所得重建图像及其评估结果。当 $C_{5.5}=1$ 和 $C_{8.5}=1$ 时可获得高精度重建图像,说明 DCNN 重建方法具有优异的随机噪声滤除能力;当

$C_{5.5}=1$ 和 $C_{5.5}=1.2$ 时,DCNN 方法对兴奋区域有更高的识别准确度;随着生理干扰的增强,DCNN 对背景区域的重建质量受到一定影响,但对兴奋区域的重建准确性始终优于 ART 方法。由定量评估结果可以看出,对于不同的目标-背景吸收系数对比度,DCNN 方法重建图像的 ABE 和 MSE 均小于 ART 方法,DF 和 SSIM 相比 ART 方法更接近理想数值,具有更高的重建质量。

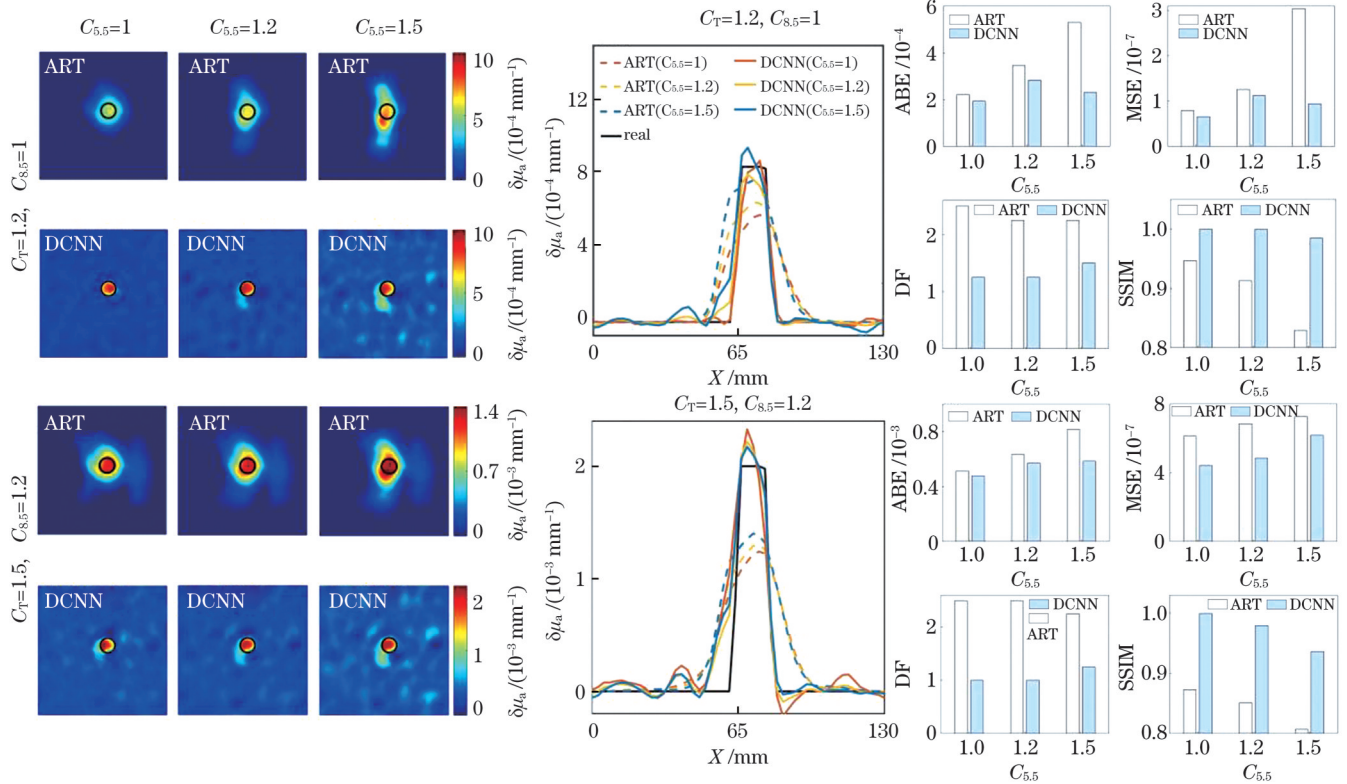


图 7 仿体实验结果

Fig. 7 Phantom experimental results

相较于数值模拟实验,仿体实验中无法保证网络训练数据集和真实实验情况完全一致,各贯穿孔所模拟的生理干扰对实际探测数据的影响程度无法准确得到,而且实验过程中存在不可避免的人为误差。在后续工作中,为进一步提升算法的泛化能力和重建能力,从而在真实应用场景中获得更好的重建效果,笔者拟结合多模态(核磁等)的已知图像信息对网络模型训练数据进行丰富。

4 讨 论

如前所述,相较于传统重建算法,所发展的 DCNN 重建方法可以显著提升重建质量,但单次仅可处理一个采样点的激活信息,对时间特征利用不足。在连续动态 fNIRS 应用中,激活信息的时间变化遵循血流动力学响应规律,为综合利用时间空间信息,在二维网络结构的基础上引入时间信息作为第三维度,发展了如图 8 所示的 3D-DCNN 网络。综合考虑硬件资源和时间成本,以 10 个采样点为例对网络进行设计。

在该网络模型中,输入信息是按时序排列的 S3D-DOT 重建的 CC 层图像,经过网络计算后最终输出了重建精度更高的激活分布图像序列。将 DCNN 的卷积层和池化层调整为三维,并对用于上述强干扰数值模拟实验的数据集的格式进行调整,完成网络训练和验证。训练过程中网络迭代次数设为 600 次,每次迭代送入样本数为 32,其余参数设置不变。

图 9(a)展示了在不同时刻分别采用 DCNN 和 3D-DCNN 得到的重建图像及其剖面图。可见,3D-DCNN 的噪声抑制能力、兴奋区域位置和形状识别能力更加优异,而且重建准确度更高。DCNN 和 3D-DCNN 的评估指标计算结果如图 9(b)所示,3D-DCNN 的各项指标均取得了理想的结果,且多数优于 DCNN,说明三维网络同样具有理想的空间信息提取能力。图 9(c)展示了不同重建方法对兴奋区域吸收系数变化-时间曲线的恢复情况,从整体任务周期来看,三维网络对大脑兴奋程度的时间变化趋势具有更好的分辨能力。但网络结构的升维带来了参数量的大

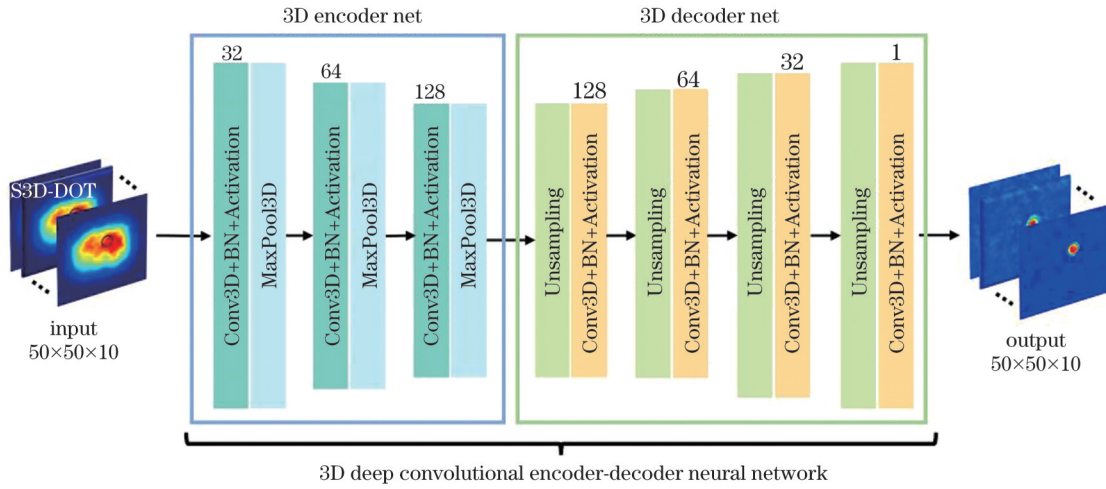


图 8 3D-DCNN 网络模型结构
Fig. 8 3D-DCNN model structure

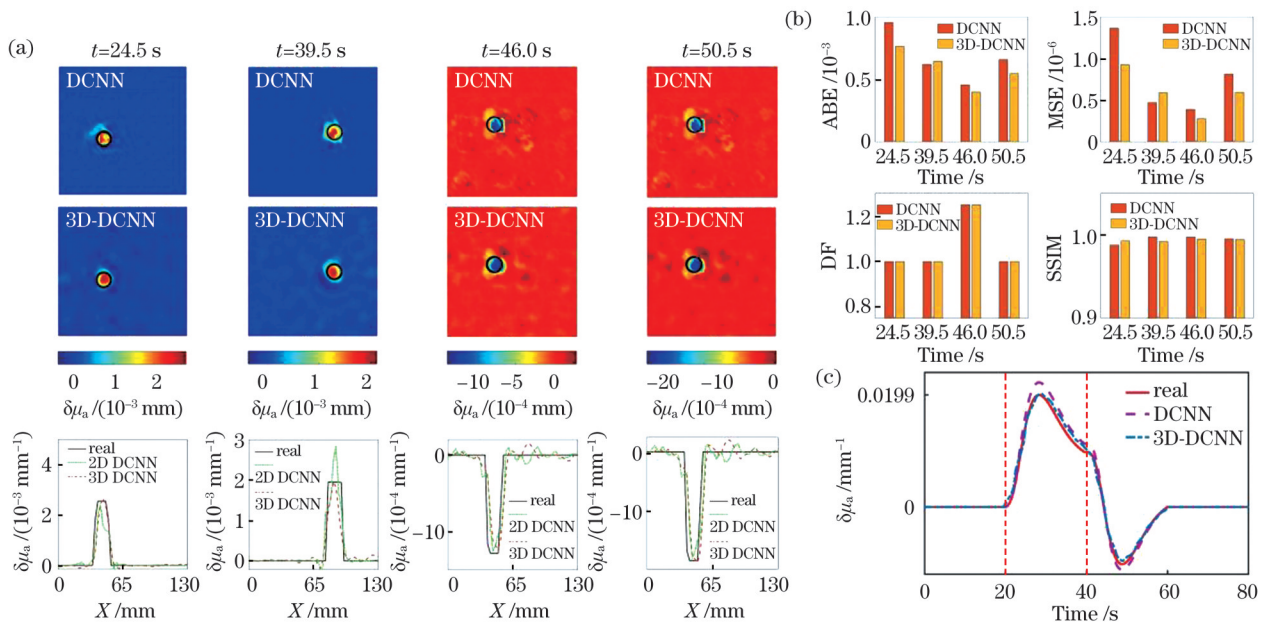


图 9 3D-DCNN 网络数值模拟实验结果。(a) 部分时间点下重建的 CC 层吸收系数变化图；(b) 部分时间点下重建结果定量评估比较；(c) 兴奋区域平均吸收系数变化-时间曲线

Fig. 9 Simulation results of 3D-DCNN. (a) A comparison of absorption coefficient perturbation images in CC layer reconstructed at the selected time points; (b) quantitative estimation comparison of reconstruction results at the selected time points; (c) time-courses of average absorption coefficient perturbation in the deep activated region

幅增加,网络收敛速度变慢,同时对硬件设备提出了更高要求,使进一步的研究工作受到诸多限制。

5 结 论

当前, fNIRS-DOT 脑功能成像发展所限制主要为逆问题不适定性严重、重建图像精度不够、对生理干扰和随机噪声的抑制不足。本文提出了一种基于模型先验的深度卷积编解码网络重建方法,以 S3D-DOT 重建结果为模型先验信息,利用 DCNN 网络完成重建精度提升。针对所提方法开展了一系列数值模拟和仿体实验。以低噪声干扰下数值模拟实验的成像结果为例,所提方法的 SSIM 平均值大于 0.998,重建用时为

5.67 s, ABE、MSE 和 DF 相比传统 ART 算法分别降低了 7.28%、67.73% 和 70%。这说明所提方法可在有效抑制噪声、提高重建结果空间分辨率的同时显著提升重建速度,为高效 fNIRS-DOT 成像的进一步发展和临床应用等提供了新的解决方案。

参 考 文 献

- [1] Althobaiti M, Al-Naib I. Recent developments in instrumentation of functional near-infrared spectroscopy systems[J]. Applied Sciences, 2020, 10(18): 6522.
- [2] Herold F, Wiegel P, Scholkmann F, et al. Applications of functional near-infrared spectroscopy (fNIRS) neuroimaging in exercise-cognition science: a systematic, methodology-focused review[J]. Journal of Clinical Medicine, 2018, 7(12): 466.

- [3] Fishell A K, Burns-Yocum T M, Bergonzi K M, et al. Mapping brain function during naturalistic viewing using high-density diffuse optical tomography[J]. *Scientific Reports*, 2019, 9: 11115.
- [4] Aihara T, Shimokawa T, Ogawa T, et al. Resting-state functional connectivity estimated with hierarchical Bayesian diffuse optical tomography[J]. *Frontiers in Neuroscience*, 2020, 14: 32.
- [5] Duan L, Zhao Z P, Lin Y L, et al. Wavelet-based method for removing global physiological noise in functional near-infrared spectroscopy[J]. *Biomedical Optics Express*, 2018, 9(8): 3805-3820.
- [6] Intes X, Ntziachristos V, Culver J P, et al. Projection access order in algebraic reconstruction technique for diffuse optical tomography [J]. *Physics in Medicine and Biology*, 2002, 47(1): N1-N10.
- [7] Cao X, Zhang B, Wang X, et al. An adaptive Tikhonov regularization method for fluorescence molecular tomography[J]. *Medical & Biological Engineering & Computing*, 2013, 51(8): 849-858.
- [8] Li A, Miller E L, Kilmer M E, et al. Tomographic optical breast imaging guided by three-dimensional mammography[J]. *Applied Optics*, 2003, 42(25): 5181-5190.
- [9] Brooksby B A, Dehghani 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.
- [10] 王慧泉, 吴念, 赵喆, 等. 基于深度学习的扩散光学层析成像重建综述[J]. *激光与光电子学进展*, 2020, 57(4): 040003.
- Wang H Q, Wu N, Zhao Z, et al. Diffuse optical tomography reconstruction based on deep learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 040003.
- [11] Cai C J, Deng K X, Ma C, et al. End-to-end deep neural network for optical inversion in quantitative photoacoustic imaging[J]. *Optics Letters*, 2018, 43(12): 2752-2755.
- [12] Feng J C, Sun Q W, Li Z, et al. Back-propagation neural network-based reconstruction algorithm for diffuse optical tomography[J]. *Journal of Biomedical Optics*, 2018, 24(5): 051407.
- [13] Liu D Y, Zhang P R, Zhang Y, et al. Suppressing physiological interferences and physical noises in functional diffuse optical tomography via tandem inversion filtering and LSTM classification [J]. *Optics Express*, 2021, 29(18): 29275-29291.
- [14] Bonomini V, Zucchelli L, Re R, et al. Linear regression models and k-means clustering for statistical analysis of fNIRS data[J]. *Biomedical Optics Express*, 2015, 6(2): 615-630.
- [15] Yamada Y, Okawa S. Diffuse optical tomography: present status and its future[J]. *Optical Review*, 2014, 21(3): 185-205.
- [16] Liu D Y, Zhang Y, Bai L, et al. Combining two-layer semi-three-dimensional reconstruction and multi-wavelength image fusion for functional diffuse optical tomography[J]. *IEEE Transactions on Computational Imaging*, 2021, 7: 1055-1068.
- [17] 丁雪梅, 王兵元, 刘东远, 等. 基于锁相光子计数的多通道脑功能成像系统[J]. *中国激光*, 2019, 46(1): 0107001.
- Ding X M, Wang B Y, Liu D Y, et al. Multi-channel brain functional imaging system based on lock-in photon counting[J]. *Chinese Journal of Lasers*, 2019, 46(1): 0107001.

Deep Convolutional Encoder-Decoder Neural Network Approach for Functional Near Infrared Spectroscopic Imaging

Li Tieni¹, Liu Dongyuan¹, Zhang Pengrui¹, Li Zhiyong¹, Gao Feng^{1,2*}

¹College of Precision Instruments and Optoelectronics Engineering, Tianjin University, Tianjin 300072, China;

²Tianjin Key Laboratory of Biomedical Detecting Techniques and Instruments, Tianjin 300072, China

Abstract

Objective Functional near-infrared spectroscopy (fNIRS) is currently widely applied in clinical research on functional brain activity states because of the advantages of fNIRS over conventional *in vivo* brain function detection techniques. fNIRS is a non-invasive and non-radiative technique that is resistant to electromagnetic interferences, provides a reasonable temporal/spatial resolution, and facilitates direct detection of blood oxygen metabolism. As an emerging reconstruction strategy for fNIRS, diffuse optical tomography (DOT) can complete the 3D reconstruction of optical parameters based on accurate photon transport models and can significantly improve the quantitative accuracy and spatial resolution of typical optical tomography techniques. Owing to the reflection measurement geometry of DOT, the detection data are affected by superficial physiological interferences (cardiac pulsation, respiration, and low-frequency oscillations) and random noises (photon-shot and instrumental noises) that originate from the scalp-skull layer; these interferences and noises affect the accuracy and precision of the reconstruction results. In addition, owing to limited boundary measurements, the inverse problem of the DOT has a non-negligible ill-posedness. Thus, handling the ill-posedness of the DOT inverse problem and suppressing physiological interferences and random noise are critical tasks in fNIRS-DOT neuroimaging. In this study, a model-based reconstruction-informed and deep learning approach, composed of a semi-three-dimensional (S3D) DOT and deep convolutional encoder-decoder neural network (DCNN), is developed to improve the reconstruction accuracy and suppress physiological interferences and random noises.

Methods First, an S3D-DOT model is developed based on the properties of near-infrared light activation information distribution in the depth direction and reasonable assumptions about the structural characteristics of the brain. The S3D-DOT model can help in reducing the number of unreconstructed parameters, handle the ill-posedness of the DOT inverse problem, and preliminarily discriminate perturbation maps corresponding to the surface and cerebral-cortex (CC) layer. The preliminary reconstructed image is then used as an input to the subsequent DCNN model, which is composed of two parts, viz. a decoder network and an encoder network. The DCNN model can collect the spatial feature information of the image, effectively separate the activation and interference information, and accurately reconstruct the activation feature in the CC layer map. In general, the proposed model-

informed deep-learning architecture is supported by physical models, exploits the spatial-information-extraction capability of convolution and encoding-decoding networks, and can provide highly quantitative and accurate reconstruction results in different application scenarios.

Results and Discussions The structural design of the network, parameter selection process, and training process are described in detail. To verify the effectiveness of the proposed method, numerical simulations and phantom experiments are conducted using the fNIRS-DOT system. The final reconstructed images of the proposed method are compared with those obtained using the algebraic reconstruction technique (ART), and appropriate quantitative evaluation indices are selected for the computational analysis. The results of the numerical simulation experiments at specific time points show that the DCNN can effectively suppress the effects of physiological interference and random noise and improve the reconstruction accuracy, with a mean structure similarity index (SSIM) value of >0.998 (Fig. 3). DCNN is more advantageous than the ART at a weak excitation time point, and the corresponding time required for reconstruction is significantly less. Subsequently, the performance of the DCNN model is examined under strong noise interferences. The corresponding results demonstrate that the conventional method cannot accurately reconstruct the excitation distribution under these conditions, whereas the proposed algorithm can still guarantee the validity of the reconstruction results (Fig. 4). Additionally, the reconstruction capability of the DCNN in complex scenarios is verified through dual-target simulations (Fig. 5). Furthermore, practical applicability of the proposed method is preliminarily examined through phantom experiments. The results indicate that the method can accurately filter random noise; however, the reconstructed image is still affected by physiological interferences when its relative intensity is large (Fig. 7). Finally, a 3D deep convolutional encoder-decoder neural network (3D-DCNN) model is proposed to enhance the network's ability to utilize temporal - spatial information and reasonably predict the changes in the excitatory brain regions. The results of the numerical simulation experiments prove that the 3D-DCNN model is more sensitive to small absorption changes and can accurately reconstruct the complete time courses of the average absorption perturbation in the activated region (Fig. 9).

Conclusions In this study, a model-based reconstruction-informed and deep learning approach is developed for enhancing the fNIRS-DOT performance. This proposed approach adopts the S3D-DOT model and DCNN to reduce image artifacts induced by physiological interferences and random noise. This method requires less hardware devices and provides an explicit physical explanation, an excellent accuracy and generalization for different scenes, and a fast reconstruction speed. To assess the effectiveness of the proposed method, a series of preliminary numerical simulations and phantom experiments are conducted, and the results are compared with those of the traditional reconstruction method. The results show that this method can significantly improve the quantification of images, greatly reduce the reconstruction time, and facilitate an excellent generalization, thereby providing an important new reference for dynamic fNIRS-DOT imaging.

Key words bio-optics; functional near-infrared spectroscopic imaging; layered semi-three-dimensional reconstruction; deep convolutional encoder-decoder neural network