

基于卷积神经网络的双层生物组织光学参数反演研究

鲍瑞, 刘庆文*, 刘远远, 何祖源

上海交通大学区域光纤通信网与新型光通信系统国家重点实验室, 上海 200240

摘要 生物组织的吸收系数和散射系数与组织的生理状态相关, 是检测人体健康状态的重要指标。当前双层生物组织模型的光学参数反演方案中, 吸收系数和散射系数的预测精度受到上层组织厚度等参数的影响较大, 限制了模型的实际应用范围。为此, 提出一种对上层组织厚度等参数不敏感的吸收和散射系数反演方法。通过采集漫反射光信号的空间和时间分布信息, 并利用卷积神经网络来反演双层生物组织的吸收系数和散射系数, 在随机的上层组织厚度和折射率等参量下实现较高的吸收系数和散射系数反演精度。在仿真实验中, 基于改进的蒙特卡罗模拟获得双层皮肤模型在不同空间探测位置处、不同时刻的漫反射光强信息, 然后利用卷积神经网络实现对两层皮肤组织吸收系数和散射系数的预测。结果表明: 在固定的上层组织厚度和折射率参数下, 吸收系数和散射系数反演的平均相对误差均小于 4%; 而当上层组织厚度和折射率存在随机变化时, 吸收系数和散射系数的平均相对误差仍小于 8%。相较其他方法, 所提的测量方案和反演算法进一步提升了反演精度和扩展了实际应用场景, 为生物组织光学参数的无创测量提供了新思路。

关键词 生物光子学; 组织光学参数; 漫反射率; 蒙特卡罗模拟; 卷积神经网络

中图分类号 O439

文献标志码 A

doi: 10.3788/LOP202259.0617018

Inversion Algorithm for Optical Properties of Double-Layer Tissue Based on Convolutional Neural Network

Bao Rui, Liu Qingwen*, Liu Yuanyuan, He Zuyuan

State Key Laboratory of Advanced Optical Communication Systems and Networks, Shanghai Jiao Tong University, Shanghai 200240, China

Abstract The absorption and scattering coefficients of biological tissue are related to the physiological state of the tissue, which are important parameters for the detection of human health. The prediction accuracy of absorption and scattering coefficients in the current optical property inversion method of the double-layer biological tissue model is greatly affected by parameters such as the thickness of the upper layer tissue, which limits the scope of application. In this study, an inversion method of absorption and scattering coefficients is proposed, which is insensitive to parameters such as the thickness of upper layer tissue, in which the spatial and temporal distribution information of diffuse reflectance is collected; then, convolution neural network algorithm is applied to predict the absorption and scattering coefficients of double-layer biological tissue. The inversion accuracy of absorption and scattering coefficients is high under the random parameters of thickness and refractive index of upper layer tissue. In the simulation experiment, using a modified Monte-Carlo simulation, the diffuse reflectance of the double-layer skin

收稿日期: 2021-12-15; 修回日期: 2022-01-06; 录用日期: 2022-01-11

基金项目: 国家自然科学基金面上项目(62175147)、上海交通大学医工交叉研究基金(YG2017QN62)

通信作者: *liuqingwen@sjtu.edu.cn

model at different space detection positions and different time is obtained, and the convolution neural network is trained and tested using the simulation data to predict the absorption and scattering coefficients of two-layer skin tissue. Results show that the mean relative errors of absorption and scattering coefficients are less than 4% when the upper layer tissue thickness and refractive index are constant, whereas when the upper layer tissue thickness and refractive index change randomly, the mean relative errors of absorption and scattering coefficients are still less than 8%. Compared with other methods, the measurement scheme and inversion algorithm proposed in this study improve the prediction accuracy and expand the practical application prospect and provide a new method for the noninvasive measurement of biological tissue optical properties.

Key words biophotonics; optical properties of tissue; diffuse reflectance; Monte-Carlo simulation; convolutional neural network

1 引言

生物组织的光学参数反映了组织内部的微观结构和生化物质的含量信息,因而准确测量的组织光学参数能够在临床上指导疾病的早期筛查和代谢状况的监测^[1-2]。无创测量生物组织光学参数的过程一般可分为两个阶段:首先获得与生物组织相互作用后的漫反射光信号,然后分析漫反射光信号与生物组织光学参数的映射关系,反演生物组织的光学参数。根据测量漫反射光信号方式的差异,目前主要存在时间分辨、空间分辨以及二者经傅里叶变换后所对应的频域测量等方案,而映射模型则包括漫射近似、逆蒙特卡罗和神经网络等多种反演算法^[3-4]。

生物组织在不同深度处的结构和功能往往不同,形成分层结构。单层的生物组织模型假设生物组织整体具有相同的状态,以降低光传输模型和反演算法的复杂度。王利军^[5]利用光纤阵列型空间分辨漫反射测量系统和人工神经网络算法获得了仿体模拟液的吸收和散射系数。Panigrahi等^[6]测量了生物组织的空间频域成像结果,并通过随机森林回归等反演模型对手部皮肤组织的吸收和约化散射系数进行反演。两层或多层生物组织模型更接近生物组织的实际结构,尤其是考虑到光在生物组织中的穿透深度和计算复杂度,双层生物组织模型得到了较多的研究。Sharma等^[7]测得双层仿体样品距离入射光源 370 μm 和 740 μm 两个空间位置处的漫反射光谱信息,并利用基于逆蒙特卡罗查找表的反演方法对各层光学参数进行预测,吸收和约化散射系数的归一化均方根偏差均大于 10%,且吸收系数反演的稳定性受到上层厚度变化的显著影响。天津大学李刚研究组^[8]根据测量位置与入射光源的距离关系将空间分辨漫反射信号分为两部分,信号

依次通过神经网络和遗传算法分别实现上层和下层介质吸收和散射系数的反演,蒙特卡罗仿真结果表明各层光学参数的预测均方根误差不超过 10%。然而该方案的实现要求上层介质厚度值恒为 5 mm,且模型的反演精度依赖于对漫反射数据的人为划分方式。Yang等^[9]基于空间和时间域漫反射相结合的测量方案,同样根据空间探测的位置关系分段处理漫反射数据,逐个迭代反演生物组织各层的光学参数,其局限在于实验过程中上层组织的吸收和散射系数是固定的,因而该方法主要针对下层组织的光学参数进行反演。

基于以上分析可以看出,目前基于双层生物组织光学参数的反演方案在上层组织厚度等参数为已知的固定值时精度较高,而对于上层介质厚度等参数存在变化情况下的反演效果却难以保证,限制了无创光学参数检测技术的实际应用场景。为此,本文提出了一种对上层介质厚度等参数变化不敏感的组织光学参数反演技术,在获取生物组织漫反射光的空间和时间上的分布信息后,通过卷积神经网络模型实现对两层组织吸收和散射系数的检测。基于改进的蒙特卡罗模型进行了数值仿真实验,结果显示上层组织厚度和折射率的变化对该模型反演精度的影响较小,为无创测量生物组织光学参数的实现提供了新的方案。

2 基本原理

2.1 生物组织的光学参数

光子在生物组织中传播时会发生反射、折射、吸收和散射等现象,影响光子运动状况的主要光学参数包括吸收系数 μ_a 、散射系数 μ_s 、各向异性因子 g 和折射率 n 等^[10]。其中, g 和 n 对生物内部生化物质含量等状态不敏感,光子与生物组织相互作用主要是吸收和散射过程,故 μ_a 和 μ_s 是检测组织生理状态

的主要参数。

皮肤组织因分布广泛、便于测量的特点成为无创生物组织检测主要的研究对象。真实的皮肤结构包括表皮层和真皮层两部分,且各层次的生化成分有所不同。因此,对皮肤组织的检测尤其适合采用双层模型。表皮层和真皮层具有不同的光学参数,特别是对于吸收系数而言,吸收过程在表皮层中主要由黑色素等色素物质体现,而在真皮层中则主要是血液中的血红蛋白、血糖和胆红素等化学成分所导致的^[11-12]。获得皮肤组织不同层次的吸收系数能够实现对不同化学成分的含量测定。双层生物组织的吸收系数表达式为

$$\mu_a(\lambda) = \sum_{i=1}^2 \sum_{j=1}^m \epsilon_{i,j}(\lambda) \times c_{i,j}, \quad (1)$$

式中: $\mu_a(\lambda)$ 为组织总的吸收系数; i 为当前组织的层数; j 表示当前层组织中第 j 个产生吸收的生色团类型; $\epsilon_{i,j}(\lambda)$ 为不同生色团对应的摩尔消光系数; $c_{i,j}$ 为不同生色团的物质的量浓度。

2.2 基于蒙特卡罗模拟的空间-时间漫反射信号模型

皮肤组织是强吸收、高散射的混沌介质。其散射特性使得光子在介质中发生随机游走而具有不同的运动轨迹,同时组织的吸收特性导致光子在运动过程中光强的衰减,因此探测到的漫反射光强随光子在组织中进行距离的变化而变化,且与生物组织的吸收和散射系数都存在相关性。改进的朗伯-比尔定律(MLBL)^[13]表达式为

$$I(r) = I_0 \sum_{L_{i_1}} \exp(-\mu_a L_{i_1}) + B, \quad (2)$$

式中: I_0 为入射光强; $I(r)$ 为与入射光源距离为 r 处的漫反射光强; L_{i_1} 为第 i_1 个光子的运动轨迹长度; B 表示组织内部背景引起的损耗。

分析(2)式可知,一方面,不同空间探测位置处的漫反射光强整体上会随着与入射光之间距离(SDS)的增大而减小;另一方面,在每个空间位置处,从光源到达此处的各光子运动轨迹长度不同,使得该位置处接收到的光强随时间变化而变化,时间延迟越久的光子,有着更高的几率进入下层组织。基于此,提出一种结合空间和时间分辨漫反射的测量方案,即在生物组织表面的不同 SDS 位置处,利用光反射仪技术^[14-15]分辨具有不同散射光路长度的光子,实现对时间域漫反射信息的测量,然后利用卷积神经网络对数据进行处理,并通过数

值仿真对这一方案进行了验证。

在传统的多层介质蒙特卡罗(MCML)仿真模型^[16]的基础上进行改进,进一步追踪各个光子的运动轨迹距离,从而同时获得漫反射光信号的空间和时间分布信息。基于蒙特卡罗模拟的空间-时间漫反射信号模型仿真的基本设定如下:在与入射光距离0.1~1.0 cm内以0.1 cm的均匀间距设置10个SDS,在各SDS位置处收集组织表面逸出的漫反射光子,确定光子强度的同时统计其到达该探测位置的时间延迟,即对应的运动轨迹长度。每次仿真时发射 10^6 个光子,以获得稳定的漫反射光信号分布和减小随机误差。图1为双层皮肤组织的空间-时间漫反射信号测量方案,其中 $R_d(r, t)$ 表示 SDS 为 r 处的光电探测器接收到的漫反射光强随时间 t 的变化情况。

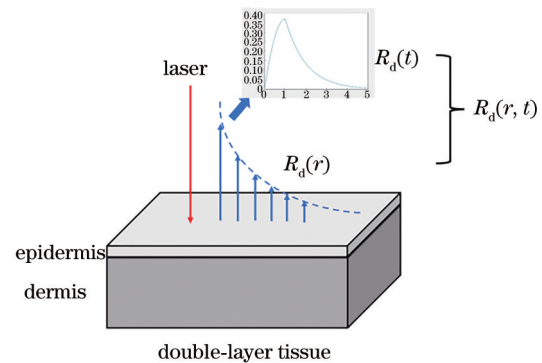


图1 双层皮肤组织的空间-时间漫反射信号测量方案
Fig. 1 Space-time diffuse reflectance signal measurement scheme for double-layer skin tissue

根据皮肤的结构特性和光学特点建立表皮层和真皮层双层介质模型,在初始的仿真中,将表皮层的厚度 d_1 和折射率 n 均设为定值,其中表皮层厚度为1 mm,同时设置真皮层厚度为49 mm,以满足MCML模型的半无限边界条件^[16]。双层介质外部的折射率 n_0 设为1,而表皮层和真皮层的折射率均设为 $n=1.35$ 。各向异性因子 g 在皮肤中一般的取值范围为0.68~0.96^[17],故这里设置 $g=0.80$ 。双层介质皮肤模型的吸收系数和散射系数主要是依据各类光传输模型已验证的生物组织的实际范围进行设置的,其中表皮层吸收系数 μ_{a1} 的范围为10~20 cm^{-1} ,真皮层吸收系数 μ_{a2} 的范围为1~5 cm^{-1} 。考虑到皮肤真皮层与表皮层散射系数是近似的,故简化模型,将二者统一为组织散射系数 μ_s ,范围为30~50 cm^{-1} ^[18-20]。每一次仿真设定的 μ_{a1} 、 μ_{a2} 和 μ_s 是在各自范围内随机产生的。图2表示在 $\mu_{a1}=10 \text{ cm}^{-1}$, $\mu_{a2}=1 \text{ cm}^{-1}$ 和 $\mu_s=50 \text{ cm}^{-1}$ 的组织光学参数下仿真获

得的不同空间探测位置处漫反射光强随时间的变化信息,其中图 2(a)~(j)分别对应与入射光距离为

0.1~1.0 cm 时均匀设置的 10 个 SDS 位置的时间分辨漫反射数据。




图 2 各空间探测位置处漫反射信号随时间的变化曲线。(a)~(j) SDS 为 0.1, 0.2, 0.3, ..., 1.0 cm 时的仿真结果

Fig. 2 Variation curves of diffuse reflection signal with time at each spatial detection position. (a)~(j) Simulation results at SDS of 0.1, 0.2, 0.3, ..., 1.0 cm, respectively

为了保留漫反射信号空间上的强度衰减和时间上的峰值延迟的特征,将其转换为空间域和时间域的二维矩阵。矩阵的行指不同的空间探测位置,即在 0.1~1.0 cm 范围内均匀设置的 10 个 SDS; 矩阵的列则代表不同的时刻,这里为了压缩矩阵数据量,将 0~100 ps 的时间范围划分为 30 个等长连续的时间段,对多个时间采样点的漫反射光子数进行组合累加。

以上的仿真设定参照了目前皮肤光学参数反演的一般方案,即将表皮层厚度 d_1 和组织折射率 n 设为某个固定的经验值进行研究,然而实际上 d_1 和 n 都会影响光子与生物组织的相互作用过程与结果。因此,单一的模型参数设定不符合皮肤组织厚度分布和折射率大小在不同的个体或测量部位中存在变化的实际情况^[21],故本文进一步探究在 d_1 和 n 数值不固定的条件下吸收系数和散射系数的反演结果。基于这一点,在上述仿真的基础上,设定 d_1 和 n 为一定范围内的随机值,其中 $d_1 \in (0.10 \text{ cm}, 0.15 \text{ cm})$, $n \in (1.30, 1.45)$ 。分别对仅 d_1 变化、仅 n 变化、 d_1 和 n 二者同时变化三种情况进行仿真,各获

得 2000 组不同吸收系数和散射系数组合的对应的空间-时间分布漫反射信息,以验证在二者存在扰动时光学参数反演模型的准确性。

2.3 卷积神经网络反演算法

根据已知的具有空间-时间分布特点的漫反射信息反演出生物组织的光学参数,需要建立非线性模型来确定对应关系。通过卷积神经网络(CNN)实现双层生物组织中各层光学参数的反演,该模型的核心结构包括卷积层、池化层和全连接层等。其中卷积层利用一定大小的卷积核提取输入图像中各个小区域的特征;在池化层中,滤波器对卷积层的输出进行降采样,去除冗余信息的同时降低数据尺寸;而全连接层主要通过和激活函数进行卷积输出各光学参数的反演结果^[22]。经过多次训练测试,确定 CNN 光学参数反演模型的结构如图 3 所示,包括一个输入层、两个卷积层和池化层的交替组合、两个全连接层。同时,设定网络的损失函数为均方误差(MSE),并在 CNN 的训练过程中通过 Adam 梯度下降算法调整和优化各层的网络参数。




图 3 卷积神经网络反演模型

Fig. 3 Convolutional neural network inversion model

1) 输入层(Input):输入为经过归一化处理后的 10 个 SDS 位置处 30 个时间间隔内的漫反射光子数分布,即大小为 10×30 的二维空间-时间漫反射矩阵。

2) 卷积层(Conv):卷积核(kernel)的个数为 32,大小为 2×2 ,同时选择 ReLU 函数作为激活函数。

3) 池化层(Pooling):采用最大值池化的降采样方案,滤波器的尺寸为 2×2 ,步长(stride)设为 2。

4) 全连接层(Dense):第一个全连接层设置 64 个节点,第二个全连接层设置 3 个节点,即输出反演结果 μ_{a1} 、 μ_{a2} 和 μ_s 。激活函数均选择 linear,同时在两个全连接层间增加 dropout,随机删除 20% 的神经元以避免过拟合现象。

基于 keras 深度学习框架搭建 CNN 反演模型^[23],将各次仿真获得的 2000 组空间-时间分布漫反射信息中的 1400 组数据作为训练集用于模型训练,利用余下的 600 组数据测试模型反演吸收和散射系数的性能。图 4 为 CNN 反演模型训练与测试的一般过程。

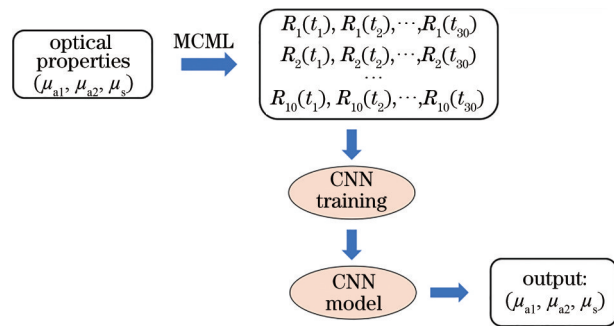


图 4 卷积神经网络反演模型的训练与测试

Fig. 4 Training and testing of convolutional neural network inversion model

采用平均相对误差(MRE)和决定系数(R^2)评估反演模型的预测性能,其中 MRE 的值越小, R^2 越接近 1,表示模型具有更高的反演精度。MRE 和 R^2 的计算公式分别为

$$E_{MR} = \frac{1}{n_{\text{sample}}} \sum_{i_2=1}^{n_{\text{sample}}} \left| \frac{y_{i_2} - \hat{y}_{i_2}}{y_{i_2}} \right|, \quad (3)$$

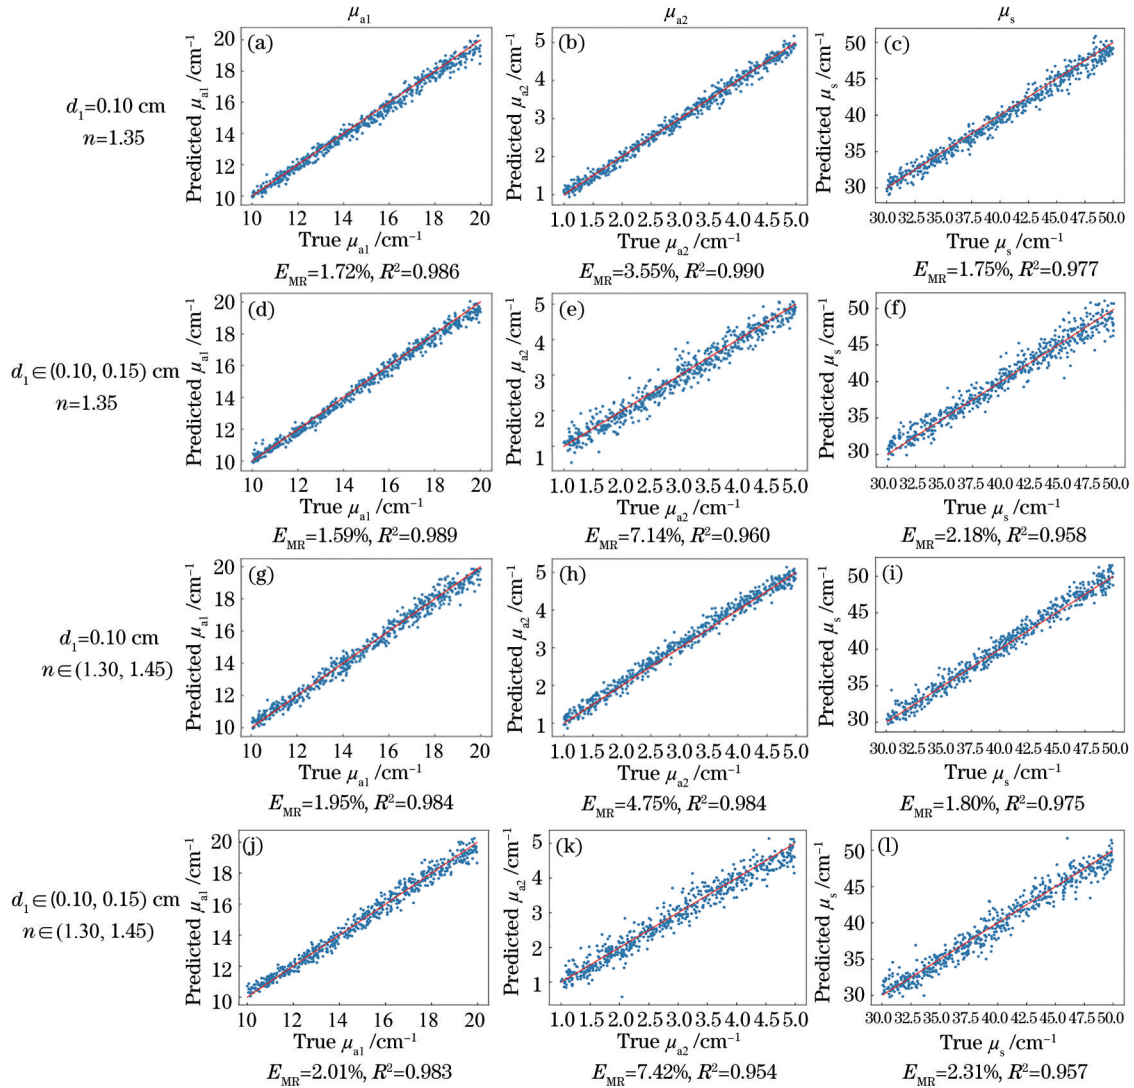
$$R^2 = 1 - \frac{\sum_{i_2=1}^{n_{\text{sample}}} (y_{i_2} - \hat{y}_{i_2})^2}{\sum_{i_2=1}^{n_{\text{sample}}} (y_{i_2} - \bar{y})^2}, \quad (4)$$

式中: n_{sample} 为测试集样本数量; y_{i_2} 为真实光学参数值; \hat{y}_{i_2} 为预测光学参数值; \bar{y} 为真实光学参数的平均值。

3 分析与讨论

基于改进的 MCML 模型分别对双层介质模型进行多次仿真实验,并根据以上仿真数据对 CNN 反演模型进行训练和测试。每次训练时取 20 组漫反射矩阵为集合同时训练,经过 100 次迭代后停止。然后利用测试集对模型反演的表皮层吸收系数 μ_{a1} 、真皮层吸收系数 μ_{a2} 和组织散射系数 μ_s 与预先设定的光学参数进行比较拟合,同时讨论在表皮层厚度 d_1 和组织折射率 n 不确定时模型的预测精度。图 5 为在不同的 d_1 和 n 设置情况下各测试集数据中预测的组织光学参数,其中图 5(a)~(c) 分别为在 $d_1 = 0.10 \text{ cm}$ 且 $n = 1.35$ 仿真条件下 μ_{a1} 、 μ_{a2} 和 μ_s 的反演结果,图 5(d)~(f) 分别为在 $d_1 \in (0.10, 0.15) \text{ cm}$ 且 $n = 1.35$ 仿真条件下 μ_{a1} 、 μ_{a2} 和 μ_s 的反演结果,图 5(g)~(i) 分别为在 $d_1 = 0.10 \text{ cm}$ 且 $n \in (1.30, 1.45)$ 仿真条件下 μ_{a1} 、 μ_{a2} 和 μ_s 的反演结果,图 5(j)~(l) 分别为在 $d_1 \in (0.10, 0.15) \text{ cm}$ 且 $n \in (1.30, 1.45)$ 仿真条件下 μ_{a1} 、 μ_{a2} 和 μ_s 的反演结果。

分析仿真实验的结果可以得出,在 $d_1 = 0.10 \text{ cm}$, $n = 1.35$ 的情况下,各层组织光学参数的预测值和真实值之间具有良好的对应关系,各参数的 MRE 均小于 4%,决定系数 R^2 也都大于 0.97。其中 μ_{a1} 、 μ_{a2} 和 μ_s 的 MRE 分别为 1.72%、3.55% 和 1.75%,决定系数 R^2 分别为 0.986、0.990 和 0.977。

图 5 双层生物组织光学参数(μ_{a1} , μ_{a2} 和 μ_s)的反演结果Fig. 5 Inversion results of optical properties of double-layer tissue (μ_{a1} , μ_{a2} , and μ_s)

当 d_1 为 (0.10, 0.15) cm 范围内的随机值且 $n=1.35$ 时, μ_{a1} 的 MRE 为 1.59%, 这与 d_1 为定值时的反演结果趋于一致, 说明 μ_{a1} 的反演结果未受到 d_1 变化的影响。而 μ_{a2} 和 μ_s 的预测误差则出现了不同程度上升, 其 MRE 分别增至 7.14% 和 2.18%, 决定系数 R^2 则分别降为 0.960 和 0.958。类似地, 当 $d_1=0.10$ cm 且 n 为 (1.30, 1.45) 范围内的随机值时, 各层吸收系数 μ_{a1} 和 μ_{a2} 的反演精度相较于 n 为定值的情况均存在微弱下降, 此时二者的 MRE 分别为 1.95% 和 4.75%。而 n 的改变基本未对 μ_s 的反演结果产生影响, 其 MRE 为 1.80%, 决定系数 R^2 为 0.975, 与 n 为定值情况下的反演表现大致相同。

最后讨论当 d_1 为 (0.10, 0.15) cm 和 n 为 (1.30, 1.45) 范围内的随机值时的情况, 相较于 d_1 和 n 均为定值时的预测结果, 此时模型对各光学参

数的反演性能都呈一定下降趋势。尤其是 μ_{a2} 的预测精度相对最低, 但此时其 MRE 仍为 7.42%, 决定系数 R^2 是 0.954。

比较分析 d_1 和 n 的变化对反演结果的影响, 二者对 μ_{a1} 和 μ_s 的预测未出现性能上的显著下降, 但 μ_{a2} 的预测误差则有所增大。具体来看, d_1 的变化是影响 μ_{a2} 和 μ_s 反演结果的主要因素, 而 n 的不确定性则使得 μ_{a1} 的反演精度有所降低。总体而言, 所提基于空间-时间分布漫反射的卷积神经网络反演模型对各层组织光学参数的预测精度较高, 在 d_1 和 n 同时变化时模型对各层光学参数的 MRE 均不超过 8%, 且决定系数 R^2 也都大于 0.95。

同时, 进一步分析比较了反向传播神经网络 (BPNN)、支持向量回归 (SVR) 和随机森林回归 (RFR) 等传统机器学习算法反演双层生物组织各

光学参数的性能情况。其中,在固定的 d_1 和 n 条件下, BPNN 模型反演的 μ_{a1} 和 μ_{a2} 的 MRE 分别增至 3.27% 和 7.13%, 决定系数 R^2 则分别降为 0.957 和 0.964。当 d_1 和 n 随机变化时, 此时 SVR 模型输出的 μ_{a2} 和 μ_s 的 MRE 分别为 10.76% 和 3.60%, 二者的决定系数 R^2 分别为 0.921 和 0.904; 而 RFR 模型中 μ_{a1} 和 μ_{a2} 反演结果的 MRE 则进一步增大为 3.29% 和 11.56%, 决定系数 R^2 则仅为 0.959 和 0.898。

通过评估 BPNN、SVR 和 RFR 的反演结果可以得出, 传统的机器学习算法反演的光学参数的误差更大, 且难以保证实现同时对 μ_{a1} 、 μ_{a2} 和 μ_s 三者较高精度反演, 同时模型的预测性能在 d_1 和 n 随机变化时亦存在较为明显下降。相对比下, 利用 CNN 反演双层生物组织光学参数的方案在精度上有所提升, 同时对 d_1 和 n 的随机变化具有更低的敏感性, 进一步验证了所提方案反演双层生物组织光学参数的有效性。

4 结 论

将空间和时间分辨的漫反射光信号测量方案结合起来, 根据实际皮肤结构建立双层组织模型, 利用改进的 MCML 模型获得不同组织光学参数下具有空间和时间分布特点的漫反射率分布信息, 并通过卷积神经网络反演模型预测实际生物组织的光学参数。仿真实验结果表明, 所提方法反演获得的各层光学参数的 MRE 均小于 4%, 决定系数 R^2 大于 0.97。同时验证了在表皮层厚度和组织折射率存在变化的情况下, 所提方案对表皮层吸收系数和组织散射系数仍具有较好的反演性能, 为下一步实现组织化学成分的无创测量和结构探测提供了新的方法。

参 考 文 献

- [1] Mourant J R, Freyer J P, Hielscher A H, et al. Mechanisms of light scattering from biological cells relevant to noninvasive optical-tissue diagnostics[J]. *Applied Optics*, 1998, 37(16): 3586-3593.
- [2] Kafian-Attari I, Nippolainen E, Semenov D, et al. Tissue optical properties combined with machine learning enables estimation of articular cartilage composition and functional integrity[J]. *Biomedical Optics Express*, 2020, 11(11): 6480-6494.
- [3] Cuccia D J, Bevilacqua F P, Durkin A J, et al. Quantitation and mapping of tissue optical properties using modulated imaging[J]. *Journal of Biomedical Optics*, 2009, 14: 024012.
- [4] Zhang Q, Zhang L M, An J Y, et al. Optical parameter measurement method for mucosal lesion recognition in spatially resolved sub-diffusive regime [J]. *Acta Optica Sinica*, 2021, 41(24): 2417001.
张琪, 张丽敏, 安敬仪, 等. 面向黏膜组织病变识别的亚扩散域空间分辨光学参数测量方法[J]. *光学学报*, 2021, 41(24): 2417001.
- [5] Wang L J. Study of spatially resolved diffuse reflectance of small and highly absorbing tissues[D]. Tianjin: Tianjin University, 2009: 67-77.
王利军. 强吸收小体积生物组织的空间分辨漫反射研究[D]. 天津: 天津大学, 2009: 67-77.
- [6] Panigrahi S, Gioux S. Machine learning approach for rapid and accurate estimation of optical properties using spatial frequency domain imaging[J]. *Journal of Biomedical Optics*, 2018, 24: 071606.
- [7] Sharma M, Hennessy R, Markey M K, et al. Verification of a two-layer inverse Monte Carlo absorption model using multiple source-detector separation diffuse reflectance spectroscopy[J]. *Biomedical Optics Express*, 2013, 5(1): 40-53.
- [8] Lin L, Chen Y Q, Li G, et al. A novel method for determination of the optical properties of two-layer tissue model from spatially resolved diffuse reflectance [J]. *Proceedings of SPIE*, 2005, 5630: 486-497.
- [9] Yang L, Wabnitz H, Gladysz T, et al. Space-enhanced time-domain diffuse optics for determination of tissue optical properties in two-layered structures[J]. *Biomedical Optics Express*, 2020, 11(11): 6570-6589.
- [10] Chen Y Q. A study on basic transduction theory for noninvasive measurement of tissue components using spectroscopy[D]. Tianjin: Tianjin University, 2005: 14-16.
谌雅琴. 生物组织化学成分无创分光检测基本传感理论的研究[D]. 天津: 天津大学, 2005: 14-16.
- [11] Lister T, Wright P A, Chappell P H. Optical properties of human skin[J]. *Journal of Biomedical Optics*, 2012, 17: 090901.
- [12] Xu G, Dong L Q, Kong L Q, et al. Parameters inversion algorithm of biological tissues based on a neural network model[J]. *Acta Optica Sinica*, 2021, 41(11): 1117001.
徐歌, 董立泉, 孔令琴, 等. 基于神经网络模型的生物组织参数反演算法[J]. *光学学报*, 2021, 41(11): 1117001.

- [13] Bhatt M, Ayyalasomayajula K R, Yalavarthy P K. Generalized Beer-Lambert model for near-infrared light propagation in thick biological tissues[J]. *Journal of Biomedical Optics*, 2016, 21(7): 076012.
- [14] Kufcsák A, Bagnaninchi P, Erdogan A, et al. Time-resolved spectral-domain optical coherence tomography with CMOS SPAD sensors[J]. *Optics Express*, 2021, 29(12): 18720-18733.
- [15] Xue P. Development of high-performance optical coherence tomography[J]. *Chinese Journal of Lasers*, 2021, 48(15): 1517001.
薛平. 高性能光学相干层析成像的研究[J]. *中国激光*, 2021, 48(15): 1517001.
- [16] Wang L H, Jacques S L, Zheng L Q. MCML: Monte Carlo modeling of light transport in multi-layered tissues[J]. *Computer Methods and Programs in Biomedicine*, 1995, 47(2): 131-146.
- [17] Wang Y J. Research on numerical simulation of light propagation and optical measurement for biological tissue[D]. Harbin: Harbin Institute of Technology, 2016: 10-12.
王玉娇. 生物组织光分布的数值模拟及测量研究[D]. 哈尔滨: 哈尔滨工业大学, 2016: 10-12.
- [18] van Gemert M J C, Jacques S L, Sterenborg H J C M, et al. Skin optics[J]. *IEEE Transactions on Biomedical Engineering*, 1989, 36(12): 1146-1154.
- [19] Saidi I S, Jacques S L, Tittel F K. Mie and Rayleigh modeling of visible-light scattering in neonatal skin [J]. *Applied Optics*, 1995, 34(31): 7410-7418.
- [20] Mignon C, Tobin D J, Zeitouny M, et al. Shedding light on the variability of optical skin properties: finding a path towards more accurate prediction of light propagation in human cutaneous compartments [J]. *Biomedical Optics Express*, 2018, 9(2): 852-872.
- [21] Rawlings A V. Ethnic skin types: are there differences in skin structure and function?[J]. *International Journal of Cosmetic Science*, 2006, 28(2): 79-93.
- [22] Yamashita R, Nishio M, Do R K G, et al. Convolutional neural networks: an overview and application in radiology[J]. *Insights into Imaging*, 2018, 9(4): 611-629.
- [23] Chauhan K, Ram S. Image classification with deep learning and comparison between different convolutional neural network structures using Tensorflow and Keras [J]. *International Journal of Advance Engineering and Research Development*, 2018, 5(2): 533-538.