

基于多角度激发漫反射光信号的浑浊介质光学特性参数识别研究

刘宣君¹, 刘丽丽¹, 范可舟¹, 吉训生², 郭亚^{1,2*}

¹江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122;

²江南大学物联网工程学院, 江苏 无锡 214122

摘要 在介质中传播的光的吸收系数、散射系数、各向异性因子和折射率可以用于介质物理与化学特性的检测,因此,这四种参数的反演方法研究非常重要,但目前缺乏能够同时识别这四种参数的算法。针对该问题,提出利用多个角度激发的漫反射光信号增加信息的丰富性,并通过残差神经网络实现浑浊介质吸收系数、散射系数、各向异性因子和折射率识别的方法。通过蒙特卡罗模型模拟了各种条件下的漫反射光信号,对所提方法进行了验证。在仿真过程中,考虑光纤大小和发散角,并在漫反射光强信号中加入不同等级的噪声以提高网络的泛化能力和抗噪性能。结果表明,当信噪比为 40 dB 时,所提方法对浑浊介质的吸收系数、散射系数、各向异性因子以及折射率的识别结果的平均相对误差分别为 8.6%、4.6%、1.7% 和 0.9%,验证了所提方法的高精度。

关键词 生物光学; 吸收系数; 散射系数; 各向异性因子; 折射率; 光学性能; 残差神经网络

中图分类号 O436.2

文献标志码 A

DOI: 10.3788/CJL202249.1507205

1 引言

光在浑浊介质中的传播主要受介质光学性质的影响^[1],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)。其中, μ_a 主要反映化学性质(如水分、酸度和含糖量)的变化; μ_s 主要取决于内部结构和物理性质(如密度、形态特征和细胞结构组成)^[2]; g 提供了浑浊介质中不同散射组分的形状、大小和浓度的信息; n 可以反映浑浊介质的内部结构^[3]。通过测量浑浊介质的光学性质,可以确定其生理状态和病理变化^[4-5]。因此,这些光学性质的信息在生物医学诊断和食品安全检测中具有十分重要的意义^[6]。

Qin 等^[7-9]通过开发光学成像系统来重建食品光学特性,从而检测了苹果的表面完整性和内部硬度以及番茄的成熟度。Wang 等^[10]重建的人体组织吸收系数和散射系数不仅可用于检测大脑功能,还可以用于检测血管和皮肤疾病。由于扩散理论的局限性,Kienle 等^[11]研究了非接触条件下扩散反射光在组织表面的空间分布。利用蒙特卡罗模型训练神经网络以确定光学性质(吸收系数和降散射系数),降散射系数和吸收系数的识别结果的均方根误差分别为 2.6% 和 14%。Barman 等^[12]根据蒙特卡罗模型模拟了光在组织表面的漫反射光强信息,使用最小二乘法结合支持

向量机算法预测估计了光学参数。Warncke 等^[13-14]利用多个人工神经网络估计了吸收系数和降散射系数的值。Liu 等^[15]从响应角度增加了光学信号的丰富性,用误差反向传播神经网络预测估计了漫反射光强分布中吸收系数、散射系数、各向异性因子和折射率的值,预测结果的平均相对误差分别为 8.5%、10.1%、2.3% 和 5.7%。徐歌等^[16]使用神经网络模型反演生物组织的光学特性参数,以蒙特卡罗模型输出的不同检测距离处的漫反射率作为网络的输入,以生物组织的光学特性参数(吸收系数和散射系数)作为输出,最终实现对吸收系数和散射系数的识别,识别结果的平均绝对误差分别为 0.003 和 1.574。朱秋生等^[17]利用亚扩散空间分辨漫反射结合人工神经网络,实现了对生物组织约化散射系数和相函数参量的预测识别。李文艳等^[18]使用蒙特卡罗模型获取了光在生物组织中的漫反射率数据,建立了漫反射率与约化散射系数和散射相函数相关的参数(γ')之间的半经验公式,反构了约化散射系数和 γ' 。张琪等^[19]为实现黏膜组织光学特性参数的测量,使用光纤几何和蒙特卡罗模型进行数值模拟,并采用反向传播神经网络和 3D 查表法,实现了组织光学特性参数(吸收系数、约化散射系数和二阶散射定向因子)的反构。

在现有光学检测装置和蒙特卡罗仿真研究中,研

收稿日期: 2022-01-21; 修回日期: 2022-02-12; 录用日期: 2022-03-07

基金项目: 国家自然科学基金面上项目(31771680)、国家自然科学基金国际合作项目(51961125102)

通信作者: *guoya68@163.com

究者通常研究单一方向的激发光在介质中的传播特性^[20-21]。但在实际的生产应用中,介质材料表面的形状特性会影响漫反射光强的分布^[22],并且光学检测设备安装时不能一直保证光垂直入射或以固定角度入射,因此改变入射光的角度对于解决设备的安装问题具有重要的意义。另外,多个角度激发的漫射信号能够增加数据的丰富性,有利于参数识别精度和鲁棒性的提高。因此,本文从光学信号的激励角度出发来增加数据的丰富性,并利用机器学习算法实现介质光学特性参数的识别。

2 光学特性参数识别方法的建立

2.1 入射光投射到介质表面的位置坐标和方向余弦的初始化

蒙特卡罗模型已被证明是模拟光在介质中传播的有效方法^[23-26]。本文用蒙特卡罗模型模拟不同角度入射光在吸收系数、散射系数、各向异性因子和折射率随机组合的介质中的传输,并获得了不同入射角度激发光下的漫反射光强分布信息,如图 1 所示。




图 1 不同入射角激发光下的漫反射光强分布
Fig. 1 Diffuse reflection light intensity profiles under different incident angles of excitation light

在利用蒙特卡罗模型仿真光在浑浊介质中的传输时,一般将入射光子当成直径为零的点来处理,但是在实际的生产应用中,入射光束是有直径的,并且入射光束进入介质时存在一定的发散角。为了使仿真数据更加贴近实际,需要考虑入射光斑的尺寸以及发散角的影响,即结合实际应用中入射光斑的直径大小和发散角,重新初始化仿真中的入射光斑到达介质表面的位置和方向。入射光投影到介质表面的位置坐标和方向余弦的推导如下。

1) 建立入射光束截面的平面坐标系 $xoy(z)$ 和样本平面的坐标系 $x'o'y'(z')$ 。带有发散角的柱状光束以一定的入射角射向样本平面。

2) 给定 $xoy(z)$ 系统中某一点 M 在入射光束 xoy 截面上的坐标 $(x_0, y_0, 0)$ 以及光束的半径,需要计算的是在发散角存在的情况下,点 M 在 $x'o'y'(z')$ 坐标系中的坐标,将该坐标对应的点设定为点 N ,即求点 N 在样本平面 $x'o'y'(z')$ 坐标系上的坐标,如图 2 所示。

3) 确定入射光投射到介质表面的位置和方向。在




图 2 光传输中的光束截面

Fig. 2 Beam cross section during light propagation

不考虑发散角的情况下,通过平移变换和旋转变换,将 $xoy(z)$ 坐标系变换到 $x'o'y'(z')$ 坐标系中,从而确定点 M 在 $x'o'y'(z')$ 中的坐标。在考虑发散角存在的情况下,通过平移变换和旋转变换,确定点 N 在 $x'o'y'(z')$ 平面内的坐标。根据 $x'o'y'(z')$ 坐标系内 M 和 N 的坐标,计算直线 \overline{MN} 与样本平面的交点位置坐标,即可得到入射光束投射到介质表面的位置点:

$$x' = \frac{\sin \beta + \tan \gamma \cos \xi \cos \beta}{\cos \beta - \tan \gamma \cos \xi \sin \beta} (x_0 \sin \beta + D \cos \beta) + x_0 \cos \beta - D \sin \beta, \quad (1)$$

$$y' = \frac{\tan \gamma \sin \xi (x_0 \sin \beta + D \cos \beta)}{\cos \beta - \tan \gamma \cos \xi \sin \beta} + y_0, \quad (2)$$

$$z' = 0, \quad (3)$$

式中: β 为入射角; D 为光束传输到介质表面的距离; γ 为发散半角; ξ 为 $0 \sim 2\pi$ 之间的任意值。同时通过计算 $\overline{MN} / |\overline{MN}|$ 可以确定光子包移动方向的方向余弦为

$$\mu_x = \sin \gamma \cos \xi \cos \beta + \sin \beta \cos \gamma, \quad (4)$$

$$\mu_y = \sin \gamma \sin \xi, \quad (5)$$

$$\mu_z = \sin \gamma \cos \xi \sin \beta - \cos \beta \cos \gamma. \quad (6)$$

在蒙特卡罗模型中,每个光子投射到介质表面的位置不再被初始化为 $(0, 0, 0)$, 而是考虑到实际应用中入射光束的直径和发散角,被初始化为 (x', y', z') , 同时由于 z 随着介质材料厚度的增加而变大,光子方向余弦被设为 $(\mu_x, \mu_y, -\mu_z)$, 并在此基础上不断更新光子的方向和位置信息。

2.2 残差神经网络反演算法

根据第 2.1 节,可以通过蒙特卡罗模型获取多个角度激发光下的漫反射光强分布信息。本文采用残差神经网络^[27-29]建立漫反射光强分布信息与对应浑浊介质光学特性参数之间的机器学习映射关系模型,实现对浑浊介质光学参数的预测。提取漫反射光强分布图沿其长轴方向的光强值作为网络的输入,将四个光学特性参数(吸收系数、散射系数、各向异性因子和折射率)作为网络的输出,在对漫反射光强数据进行训练和测试之前,在数据中加入不同信噪比的噪声,以模拟真

实情况下的光学测量。并且对输入数据进行归一化处理,使不同角度激发光下的漫反射光强分布信息处于同一数量级,保证数据范围的一致性,使网络快速收敛。

残差神经网络可以有效地消除网络层数增加导致的梯度爆炸或梯度消失,避免网络性能的退化,有助于充分训练网络参数。每个残差网络模块的输入信息可以在模块中跨越一层网络传递,进而使得网络可以更好地学习光强数据的特征信息,提高网络预测精度。

经多次试验,本文堆叠了两个残差网络模块,每个残差网络模块中堆叠了三个 Dense 层(网络架构如图 3 所示),每个 Dense 层神经元的个数分别为 128、64 和 32,整个网络均使用 ReLU 激活函数。网络训练时,学习率设置为 0.0001,初始权重服从均值为 0、标准差为 0.1 的高斯分布,偏置值的初值均为 0.1,采用自适应估计(Adam)优化算法对网络的权值进行更新,一阶矩、二阶矩估计的指数加权平均参数分别设置为 0.9 和 0.999。

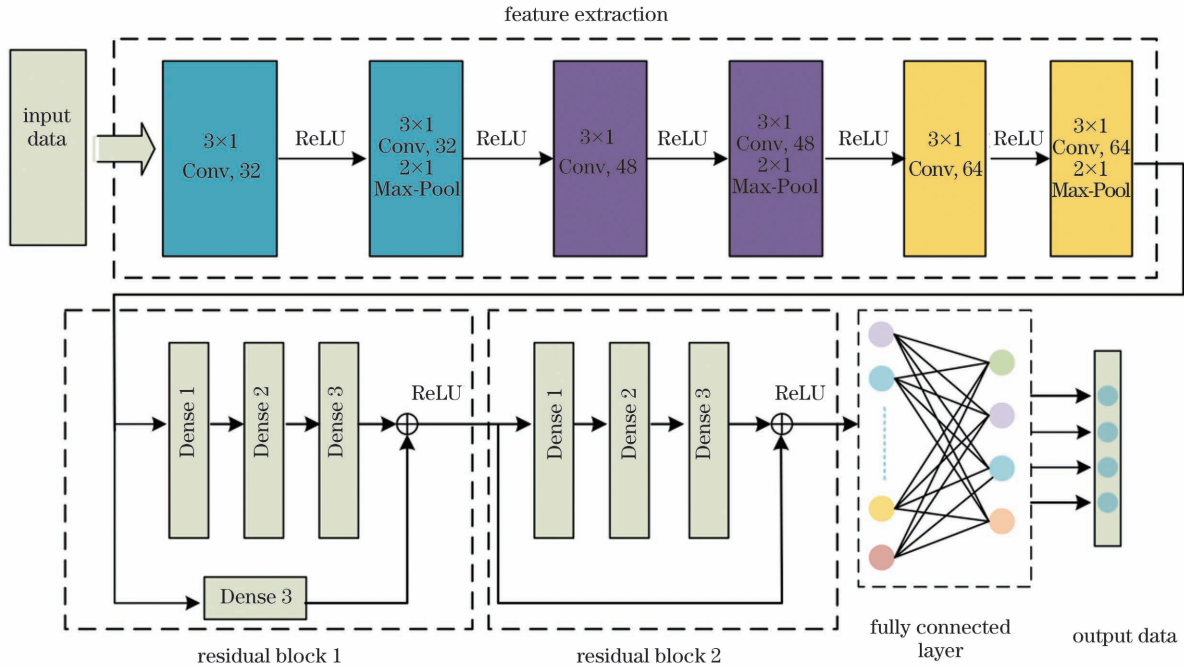


图 3 残差神经网络的架构图
Fig. 3 Architecture diagram of residual neural network

网络训练时选用平均绝对误差(MAE)作为损失函数。MAE 可以有效反映预测值误差的实际情况,并根据误差值对整个回归模型进行调优,进而有效地进行网络参数训练。使用输出网络预测的浑浊介质光学特性参数与真实输入到蒙特卡罗模型中的光学特性参数之间的平均相对误差值(MRE)评估模型的识别性能,MRE 越低表示模型预测介质的光学特性参数的精确度越高,即

$$M = \frac{1}{S} \sum_{n'=1}^S \left| \frac{y_{n'} - y'_{n'}}{y_{n'}} \right| \times 100\%, \quad (7)$$

式中: M 表示平均相对误差值; $y_{n'}$ 和 $y'_{n'}$ 分别表示第 n' 个样本数据的真实值和估计值; S 表示总的样本个数。

2.3 计算环境设置

本文中光学特性参数的识别模型采用开源框架 Tensorflow-1.13.1, Keras-2.2.2 进行部署,配置安装 Python3.7 环境实现模型结构的构建。模型的训练和测试均是在 Intel(R) Core(TM) i5-9400F CPU@2.90 GHz, 8 GB 随机存取存储器, 64 位 windows10 操作系统的计算机上执行。

3 结果与讨论

3.1 仿真数据

当入射角在 $0^\circ \sim 24^\circ$ 的范围内时,光斑逐渐从圆形变成椭圆形,但半长轴的变化率很小。从图 4 中可见,归一化半长轴从 1.00 变成 1.09,只有 9% 的变化率,




图 4 入射角度与归一化半长轴的关系
Fig. 4 Relationship between incident angle and normalized semimajor axis

会带来识别误差。当入射角为 $24^\circ \sim 60^\circ$ 时, 归一化半长轴从 1.09 变为 2.00, 高达 83.5% 的增长率能够提高识别精度。当入射角大于 60° 时, 虽然归一化半长轴会增长更多, 但考虑到实际应用中难以实现接近 90° 的入射角 (即光束几乎平行于样品平面入射), 同时过大的光斑半长轴 (过大的光斑面积) 会降低光斑光强, 进而降低信噪比, 因此本文选择 $24^\circ \sim 60^\circ$ 的入射角进行数值模拟。

在蒙特卡罗模型中, 选取入射角为 24° 、 30° 、 36° 、 42° 、 48° 、 54° 和 60° , 光斑发散半角满足 $0 \leq \gamma \leq 0.3^\circ$, 入射光斑直径为 2.6 cm, 设置入射角为 24° 时光斑截面与介质表面的距离 (D) 为 0, 初始化入射光投射到介质表面

时光子的位置和方向。设置各入射角激发光下对应的 D 分别为 0 (24°)、2 cm (30°)、4 cm (36°)、6.5 cm (42°)、10 cm (48°)、15 cm (54°) 和 20.5 cm (60°)。设定合理的光学特性参数范围, 吸收系数选定为 $0.01 \sim 50.00 \text{ cm}^{-1}$ 之间的随机数, 散射系数选定为 $1 \sim 1200 \text{ cm}^{-1}$ 之间的随机数, 各向异性因子的值选定为 $0.6 \sim 1.0$ 之间的随机数, 折射率选定为 $1 \sim 2$ 之间的随机数^[30]。最后根据蒙特卡罗模型获取不同入射角激发光下的漫反射光强分布信息。当 $\mu_a = 4.25 \text{ cm}^{-1}$, $\mu_s = 225 \text{ cm}^{-1}$, $g = 0.65$, $n = 1.3$ 时, 不同入射角激发光下的介质表面漫反射光强分布如图 5 所示。设置合理的网格划分, 每个强度分布图尺寸均为 $70 \text{ pixel} \times 70 \text{ pixel}$ 。

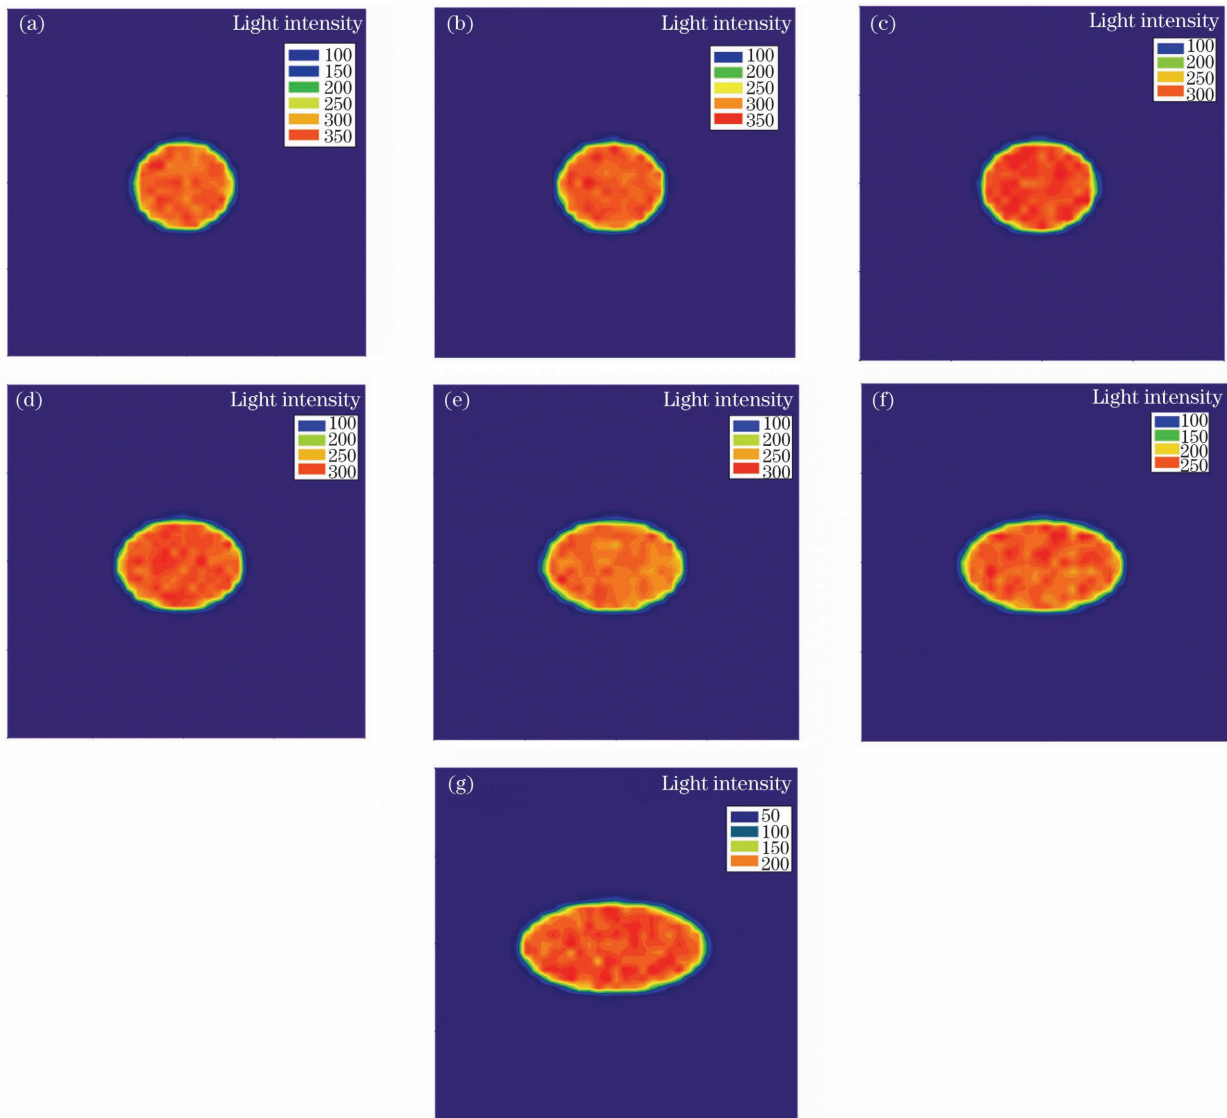


图 5 当 $\mu_a = 4.25 \text{ cm}^{-1}$, $\mu_s = 225 \text{ cm}^{-1}$, $g = 0.65$, $n = 1.3$ 时, 不同入射角激发光下的漫反射光强图。(a) 24° ; (b) 30° ; (c) 36° ; (d) 42° ; (e) 48° ; (f) 54° ; (g) 60°

Fig. 5 Diffuse reflection light intensity profiles under different incident angles of excitation light when $\mu_a = 4.25 \text{ cm}^{-1}$, $\mu_s = 225 \text{ cm}^{-1}$, $g = 0.65$, and $n = 1.3$. (a) 24° ; (b) 30° ; (c) 36° ; (d) 42° ; (e) 48° ; (f) 54° ; (g) 60°

3.2 不同入射角激发光下的漫反射光强信息的非线性

不同入射角度激发光下的漫反射光强的光斑大小和分布位置不同, 图 6 为漫反射光强度沿长轴的分布, 其中 r 为入射点距离光强记录点的距离。增加漫反射

光强分布信息的丰富性有利于多个光学特性参数的识别, 能够使光学特性参数的识别更加精确。由于入射光角度可以被调控, 如果不同入射角激发光下的漫反射光强分布是线性无关的, 它们会给参数识别带来额

外的约束,这意味着可以采用多角度激发来增加数据的丰富性。




图 6 不同入射角激发光下的漫反射光强与 r 的关系
Fig. 6 Diffuse reflection light intensity versus r at different incident angles of excitation light

通过计算由 7 条曲线数据点组成的矩阵,可知该矩阵为满秩,这说明 7 条曲线是线性无关的,并且从图 6 也可以直观地看出,7 条曲线相互独立。这是因为图 5 所示的 7 幅图像均是反映同一介质的漫反射光强,它们为光学特性参数的识别提供了独立的约束。

3.3 光学参数估计

在同一组光学特性参数 (μ_a 、 μ_s 、 g 和 n) 下,获取

不同入射角激发光下的漫反射光强分布信息,每个角度下均选取 3000 组数据,四个光学特性参数随机组合。训练数据和测试数据以 7:3 随机划分,即 2100 组数据作为训练集,900 组作为测试集,并且在进行训练和预测之前在数据中添加了信噪比 (SNR) 为 10 dB~80 dB 的噪声,整个网络在训练和测试过程中均含有噪声,网络模型识别光学特性参数的稳定性得到提高。

图 7 展示了吸收系数、散射系数、各向异性因子和折射率这四个光学参数的三维误差曲面图,其中漫反射光强分布图像个数为 1 表示只用了一个入射角激发光下的漫反射信息,以此类推。可以看出,光学参数识别结果的平均相对误差值随着漫反射图像个数的增加而降低,7 个不同角度的漫反射光强分布图将四个光学特性参数的识别结果误差分别降低了 40%、20%、4% 和 2% 左右。在样本数据中添加噪声的情况下,残差神经网络方法对光学特性参数的重构误差变化较为稳定,随着信噪比的变化,四个光学特性参数的识别误差在信噪比为 40 dB~80 dB 的情况下变化不大,基本趋于稳定。当信噪比为 40 dB 时,利用 7 个不同入射角激发光下的漫反射图像增强数据的丰富性,网络预测估计的吸收系数、散射系数、各向异性因子和折射率的值与蒙特卡罗模型的仿真值之间的平均相对误差分别为 8.6%、4.6%、1.7% 和 0.9%。如果仅仅使用一

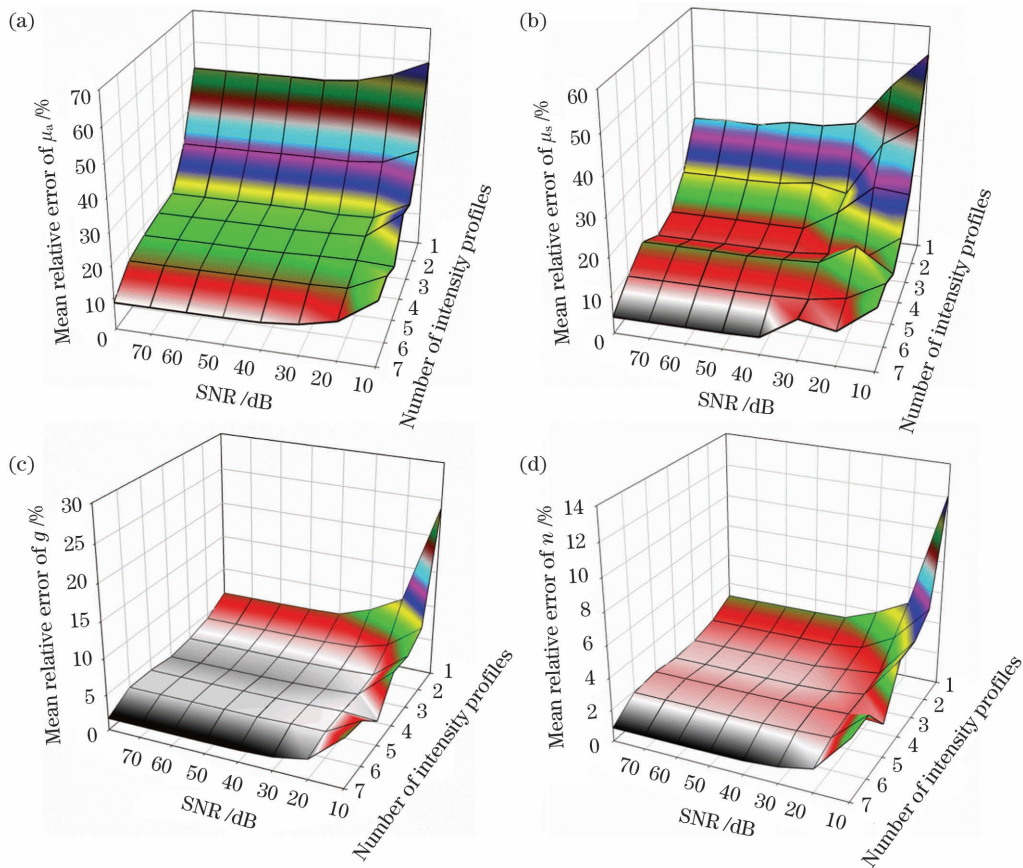


图 7 光学参数的平均相对误差随信噪比和输入的漫反射光强分布图数量的变化。(a) μ_a ; (b) μ_s ; (c) g ; (d) n
Fig. 7 Mean relative errors of optical parameter versus SNR and number of input diffuse reflection light intensity profiles.
(a) μ_a ; (b) μ_s ; (c) g ; (d) n

个角度(如 24°)激发光下的漫反射光强分布图,四个光学参数的识别结果的平均相对误差分别为 51.3%、31.2%、6.3%和 3.2%。这证明了更多入射角下的漫反射光强信息有助于参数估计。多入射角下的漫反射光强信息不仅提高了光学检测设备的灵活性,还降低了光学特性参数的识别误差。但不是越多入射角激发光就越好,从图 7 中可以看出,当使用 7 个入射角激发光下的漫反射光强图时,介质光学参数估计结果的平均相对误差变化不大,因此不需要使用更多角度激发光下的漫反射信息,这样可以节约计算时间,提高效率。所提方法有效地识别了 4 个光学特性参数,并且考虑了入射光斑大小及发散角,同时考虑了噪声。

4 结 论

利用多角度激发光下的漫反射光强分布增加了数据的丰富性,并结合残差神经网络实现了浑浊介质吸收系数、散射系数、各向异性因子和折射率的识别。当信噪比为 40 dB 时,识别结果的平均相对误差分别为 8.6%、4.6%、1.7%和 0.9%,同时考虑了入射光斑大小及发散角。与现有的预测方法相比,所提的残差神经网络方法具有更高的预测精度,这为浑浊介质的光学特性参数的检测提供了有效的方法。

参 考 文 献

- [1] Patterson M S, Wilson B C, Wyman D R. The propagation of optical radiation in tissue. II: optical properties of tissues and resulting fluence distributions[J]. *Lasers in Medical Science*, 1991, 6(4): 379-390.
- [2] Qin J W, Lu R F. Measurement of the optical properties of fruits and vegetables using spatially resolved hyperspectral diffuse reflectance imaging technique[J]. *Postharvest Biology and Technology*, 2008, 49(3): 355-365.
- [3] Nahmad-Rohen A, Garcia-Valenzuela A. Unambiguous derivation of the effective refractive index of biological suspensions and an extension to dense tissue such as blood[J]. *Journal of the Optical Society of America A*, 2021, 38(6): 775-783.
- [4] Arslan H, Pehlivanov B. Effect of purification, dehydration, and coagulation processes on the optical parameters of biological tissues[J]. *Chinese Optics Letters*, 2021, 19(1): 011701.
- [5] 马雪洁, 刘蓉, 李晨曦, 等. 高光谱在体组织成像方法的研究进展[J]. *激光与光电子学进展*, 2020, 57(8): 080002.
- [6] Ma X J, Liu R, Li C X, et al. Hyperspectral imaging of *in vivo* tissues: a review[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 080002.
- [7] Cheong W F, Prahl S A, Welch A J. A review of the optical properties of biological tissues[J]. *IEEE Journal of Quantum Electronics*, 1990, 26(12): 2166-2185.
- [8] Qin J W, Chao K L, Kim M S, et al. Hyperspectral and multispectral imaging for evaluating food safety and quality[J]. *Journal of Food Engineering*, 2013, 118(2): 157-171.
- [9] Qin J W, Kim M S, Schmidt W F, et al. A line-scan hyperspectral Raman system for spatially offset Raman spectroscopy[J]. *Journal of Raman Spectroscopy*, 2016, 47(4): 437-443.
- [10] Dhakal S, Li Y Y, Peng Y K, et al. Prototype instrument development for non-destructive detection of pesticide residue in apple surface using Raman technology[J]. *Journal of Food Engineering*, 2014, 123: 94-103.
- [11] Wang L V, Hu S. Photoacoustic tomography: *in vivo* imaging from organelles to organs[J]. *Science*, 2012, 335(6075): 1458-1462.
- [12] Kienle A, Lilge L, Patterson M S, et al. Spatially resolved absolute diffuse reflectance measurements for noninvasive determination of the optical scattering and absorption coefficients of biological tissue[J]. *Applied Optics*, 1996, 35(13): 2304-2314.
- [13] Barman I, Dingari N C, Rajaram N, et al. Rapid and accurate determination of tissue optical properties using least-squares support vector machines[J]. *Biomedical Optics Express*, 2011, 2(3): 592-599.
- [14] Warnke D, Lewis E, Lochmann S, et al. A neural network based approach for determination of optical scattering and absorption coefficients of biological tissue [J]. *Journal of Physics: Conference Series*, 2009, 178: 012047.
- [15] Chen Y W, Chen C C, Huang P J, et al. Artificial neural networks for retrieving absorption and reduced scattering spectra from frequency-domain diffuse reflectance spectroscopy at short source-detector separation [J]. *Biomedical Optics Express*, 2016, 7(4): 1496-1510.
- [16] Liu L L, Yin D H, Zhu N Y, et al. Determination of material optical properties from diffusive reflection light intensity profiles at multiple distances[J]. *Materials Research Express*, 2020, 7(2): 025403.
- [17] 徐歌, 董立泉, 孔令琴, 等. 基于神经网络模型生物组织参数反演算法[J]. *光学学报*, 2021, 41(11): 1117001.
- [18] 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.
- [19] 朱秋生, 刘迎. 用人工神经网络方法测量生物组织光学参数 γ [J]. *光子学报*, 2020, 49(8): 0817001.
- [20] Zhu Q S, Liu Y. Measuring optical parameters γ of biological tissues by artificial neural network method[J]. *Acta Photonica Sinica*, 2020, 49(8): 0817001.
- [21] 李文艳, 王兴, 刘迎. 与组织微观结构相关的散射参数 γ 及其测量方法[J]. *激光与光电子学进展*, 2019, 56(18): 181701.
- [22] Li W Y, Wang X, Liu Y. Scattering parameter γ related to tissue microstructure and measuring method [J]. *Laser & Optoelectronics Progress*, 2019, 56(18): 181701.
- [23] 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.
- [24] 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.
- [25] Reif R, A' Amar O, Bigio I J. Analytical model of light reflectance for extraction of the optical properties in small volumes of turbid media [J]. *Applied Optics*, 2007, 46(29): 7317-7328.
- [26] Palmer G M, Zhu C F, Breslin T M, et al. Monte Carlo-based inverse model for calculating tissue optical properties Part II: application to breast cancer diagnosis[J]. *Applied Optics*, 2006, 45(5): 1072-1078.
- [27] Liu F, Hohage M, Lagally M G. Surfaces and interfaces of solids, structure of [M]//Digital encyclopedia of applied physics. Weinheim: Wiley-VCH GmbH, 2003.
- [28] 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.
- [29] Guo Y, Tan J L. Monte Carlo simulation of retinal light absorption by infants [J]. *Journal of the Optical Society of America A*, 2015, 32(2): 271-276.
- [30] 汪霖. 生物组织中光子漫射方程和运输方程的解析解研究 [D]. 武汉: 武汉大学, 2018: 249.
- [31] Wang L. Study on the analytic solutions for the photon diffusion equations and transport equations in biological tissue [D].

- Wuhan: Wuhan university, 2018: 249.
- [26] 吕晨阳, 战仁军. 生物组织光学特性参数的测量方法研究[J]. 激光与光电子学进展, 2021, 58(3): 0300004.
- Lü C Y, Zhan R J. Measurement method of optical property parameters of biological tissue[J]. Laser & Optoelectronics Progress, 2021, 58(3): 0300004.
- [27] Zhu N Y, Liu X, Liu Z Q, et al. Deep learning for smart agriculture: concepts, tools, applications, and opportunities[J]. International Journal of Agricultural and Biological Engineering, 2018, 11(4): 21-28.
- [28] He K M, Zhang X Y, Ren S Q, et al. Identity mappings in deep residual networks [M] // Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9908: 630-645.
- [29] 周涛, 霍兵强, 陆惠玲, 等. 残差神经网络及其在医学图像处理中的应用研究[J]. 电子学报, 2020, 48(7): 1436-1447.
- Zhou T, Huo B Q, Lu H L, et al. Research on residual neural network and its application on medical image processing [J]. Acta Electronica Sinica, 2020, 48(7): 1436-1447.
- [30] Jacques S L. Optical properties of biological tissues: a review [J]. Physics in Medicine and Biology, 2013, 58(11): R37-R61.

Optical Property Parameter Identification of Turbid Media Based on Multi-Angle Excited Diffuse Reflection Light Signal

Liu Xuanjun¹, Liu Lili¹, Fan Kezhou¹, Ji Xunsheng², Guo Ya^{1,2*}

¹Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education, Jiangnan University, Wuxi 214122, Jiangsu, China;

²College of IoT Engineering, Jiangnan University, Wuxi 214122, Jiangsu, China

Abstract

Objective The propagation of light in turbid media is affected by the optical parameters of the media including absorption coefficient (μ_a), scattering coefficient (μ_s), isotropic coefficient (g), and refractive index (n). These optical parameters are related to the chemical properties, the internal structures, the physical properties of the media, and the boundary difference and speed of light transmission, including the shape, size, and concentration of different scattering components in the turbid media. By measuring the optical parameters of the turbid media, the material properties, physiological states and pathological changes can be determined, which is very important in various applications including biomedical diagnosis and food safety inspection. However, there is a lack of algorithms that can be simultaneously used to identify these four parameters (μ_a , μ_s , g , and n) because the measurement instruments cannot be easily installed. To solve this problem, a method based on a residual neural network is proposed here to determine the four parameters of the turbid media from the diffuse reflection light intensity profiles.

Methods First, the diffuse reflection light intensity profiles under different incident excitation light angles are obtained through the Monte Carlo simulation. The incident light spot diameter and the divergence angle are considered in the simulation process. Second, the diffuse light intensities excited under multiple angles are used to enhance the information richness. Third, a residual neural network is used to establish the machine learning mapping model between the diffuse light intensity profiles and the optical parameters of the turbid media, and the prediction of optical parameters is realized. The extracted light intensity values along the long axis are used as the input of the residual neural network, and the output is the optical parameters. Before training and testing, noise is added to the diffuse reflection data in order to simulate the optical measurements under real conditions. The input data is normalized to ensure the consistency of data range and make the network converge quickly.

Results and Discussions In the Monte Carlo simulation, different incident angles are initialized. Seven incident angles (24° , 30° , 36° , 42° , 48° , 54° , and 60°) are applied in this work (Fig. 4). The position projected by each photon on the medium surface is initialized as (x', y', z') and the photon directional cosine is set as $(\mu_x, \mu_y, -\mu_z)$. The diffuse light intensity profiles under different excitation light angles are validated to be linearly independent (Fig. 6). Thus they may provide extra effective independent constraints for the estimation of the four optical parameters. The concept of using more diffuse reflection light intensity profiles to enhance data richness is further proved by the full rank of diffuse reflective light intensity vectors along the long axis. The relative error decreases with the increase of the number of diffuse reflection light intensity profiles used here (Fig. 7). When only the diffuse reflection light intensity at one angle is used to identify the optical parameters of the media, the errors can be several times larger than those when the 7 sets of diffuse reflection light intensity profiles are used. The recognition errors of the four optical parameters have little change when the SNR is changed in the range of 40 dB–80 dB. The results show that the prediction errors for the four optical parameters (μ_a , μ_s , g , and n) are 8.6%, 4.6%, 1.7%, and 0.9%, respectively, when the noise level is 40 dB.

Compared with the existing prediction methods, the proposed residual neural network method has high prediction accuracy and short computation time.

Conclusions A method based on a residual neural network is proposed to estimate the anisotropic coefficient, absorption coefficient, scattering coefficient, and refractive index of a turbid medium. The diffuse light intensities excited under multiple angles are proved to be effective for enhancing the information richness and improving the estimation accuracy of optical parameters. The incident light spot diameter and the divergence angle are considered, and the different levels of noise are added to the diffuse light intensity signals and the generalization ability and anti-noise performance of the network are improved. The results show that the proposed method can estimate the anisotropic coefficient, absorption coefficient, scattering coefficient, and refractive index of the turbid medium accurately with a high noise level and a high efficiency. The diffuse light intensities under seven angles are enough for the determination of the four optical parameters. This work is expected to be useful for various applications including biomedical diagnosis, food safety inspection, and material property detection.

Key words bio-optics; absorption coefficient; scattering coefficient; anisotropic factor; refractive index; optical property; residual neural network