

## 基于机器学习的扫频光学相干断层扫描成像畸变校正\*

马翠<sup>1)</sup> 陈沛哲<sup>1)</sup> 杨璐<sup>1)</sup> 韩涛<sup>1)</sup> 汤赞<sup>1)</sup> 陈昌勇<sup>1)</sup> 丁志华<sup>1)2)†</sup>

1) (浙江大学光电科学与工程学院, 极端光学技术与仪器全国重点实验室, 杭州 310027)

2) (浙江大学杭州国际科创中心, 杭州 311215)

(2025年4月24日收到; 2025年6月5日收到修改稿)

光学相干断层扫描 (optical coherence tomography, OCT) 成像中不可避免的畸变常常导致成像空间与真实空间之间的不匹配, 影响测量的准确性. 为解决该问题, 本研究提出了一种基于机器学习的 OCT 图像畸变校正方法. 首先, 将带有均匀分布圆孔阵列的校准板依次在不同标记平面进行成像. 选取坐标与所有成像平面的平均坐标偏差最小的点作为参考标记点. 然后, 利用数学模型重构参考平面上所有标记点的坐标, 从而建立校准板成像空间与真实物理空间之间的映射关系. 采用多层感知机来学习这种映射关系. 利用训练完成的模型推导整个空间点的分布规律, 从而实现透镜 OCT 图像的畸变校正, 并求出透镜中心厚度与曲率半径. 校正后透镜曲率半径精度达到  $10\ \mu\text{m}$ , 误差在 1% 以内. 中心厚度精度可达  $3\ \mu\text{m}$ , 相对误差为 0.3%.

**关键词:** 光学相干层析成像, 机器学习, 畸变校正**PACS:** 42.25.Kb, 07.05.Mh, 07.05.Pj**DOI:** 10.7498/aps.74.20250545**CSTR:** 32037.14.aps.74.20250545

## 1 引言

光学相干层析成像 (optical coherence tomography, OCT)<sup>[1]</sup> 基于低相干干涉原理, 通过待测样本的背向散射光或反射光获取样本的深度信息, 具有非接触性、实时成像、成像分辨率高、成像深度大的优势<sup>[2]</sup>, 广泛应用于生物组织和光学检测领域. 然而, OCT 成像中不可避免的畸变往往导致成像空间与真实空间的失配, 这对于测量应用来说是不可接受的. 为了解决这一问题, 需要对成像中的畸变进行校正. 扫频 OCT (swept source OCT, SS-OCT) 系统的畸变主要来源于扫描成像光学系统的振镜畸变<sup>[3]</sup> 与非均匀介质的光折射畸变. 为了校正这些畸变, 研究人员发展了多种方法. Volker 等<sup>[4]</sup> 基于标定平板的标记特征点与真实空间点坐标的

差别, 从非线性扫描和非远心光路两个角度对扫描成像光学系统的畸变进行校正. Diaz 等<sup>[5]</sup> 采用多层立体标定网格, 并基于旋转、缩放和剪切模型, 构建三维畸变因子. Yao 等<sup>[6]</sup> 采用标记平板, 并基于点阵积分算法进行校正与评估. 可以看出, 迄今报道的传统畸变校正方法, 主要采用标定板与多项式数学模型来确定成像空间与真实空间的映射关系. 但是, 三维畸变因子难以用简单数学表达式来描述, 多项式数学模型拟合点数少, 难以保证拟合的准确性. 此外, 不同 OCT 系统的光学器件有所差异, 需要重新优化模型参数, 泛化能力差. 相比传统的多项式拟合, 机器学习模型隐式学习输入坐标到校正坐标的映射, 可以对高维度的数学关系进行拟合. 机器学习模型只需微调就可以适配不同的 OCT 系统, 具有强鲁棒性和泛化能力.

不同于特定解析表达式的数学模型, 基于机器

\* 国家自然科学基金 (批准号: 62035011) 资助的课题.

† 通信作者. E-mail: zh\_ding@zju.edu.cn

学习的系统描述更具鲁棒性与可靠性, 并已在光学标定中得到应用<sup>[7,8]</sup>. 然而, 不同模型适用的光学标定场景各有千秋. 卷积神经网络 (convolutional neural network, CNN)<sup>[9]</sup> 通常被用于对相机内外参数预测来校正畸变. Li 等<sup>[10]</sup> 提出了第 1 个用于校正图像的几何畸变的卷积神经网络模型, 基于输入是否有先验知识提出了单模式失真估计和多模式失真估计网络, 通过在大型的合成失真数据集学习训练学习失真图像和校正图像之间的位移场来估计失真参数, 最后通过高效的重采样方式重构出校正图像. 该方法校正效果明显优于传统校正算法. Yang 等<sup>[11]</sup> 基于 CNN 算法提出编码器-解码器结构网络对鱼眼图像进行校正, 通过在编码器和解码器的跳线连接处嵌入畸变校正层, 并引入不同的外形流特征来增加非失真信息, 使得重建结构更逼近真实图像. 可以看出, CNN 主要对图像的纹理, 几何变形等特征提取能力强, 适用于图像到图像的端到端处理<sup>[12,13]</sup>, 需要大量标注数据. 随机森林 (random forest, RF) 基于决策树的集成, 可用于分类任务<sup>[14]</sup>, 也可用于回归任务. 回归随机森林<sup>[15]</sup> 在与机器视觉相关的标定任务中具有广泛应用. 谢探阳等<sup>[16]</sup> 提出了一种基于相机畸变校正和回归随机森林的手眼标定算法. 首先对相机进行畸变校正, 采集图像坐标和对应的机械臂坐标, 用回归随机森林学习这种映射, 保证了机器视觉和机械臂的有效结合. Kato 等<sup>[17]</sup> 提出了基于随机森林模型的机器人定位误差校正系统. 通过激光跟踪仪测量机器人的定位误差, 使用随机森林模型从示教坐标, 关节角度和关节扭矩中学习机器人姿态和定位误

差之间的关系, 从而准确预测定位误差, 并使用特征提取方法识别定位误差的因素.

OCT 的畸变通常是复杂全局畸变, CNN 的局部感受野对此类畸变建模不足. 此外, 校正 OCT 畸变时要求快速有效, CNN 模型需要标注大量数据耗时较长. RF 在处理高维密集数据时效率低, 输出的是叶子节点内的均值, 平滑性差, 畸变校正效果差. 多层感知机 (multilayer perceptron, MLP)<sup>[18,19]</sup> 是一种常见的深度学习模型, 常用于 OCT 图像的畸变校正中. MLP 通过全连接层结合损失函数可以保证输出的连续性, 适合从低维到低维的回归问题<sup>[20]</sup>. 另外, MLP 模型在校正 OCT 图像畸变时仅需数百组标定点即可有良好的畸变校正效果, 耗时短且精度高.

为此, 本文提出了一种基于多层感知机模型的扫频 OCT 系统畸变校正方法. 该方法基于标定板构建的成像空间和真实空间位置数据, 通过机器学习建立成像空间和真实空间的映射关系, 并应用于全空间的位置映射, 实现扫描成像光学系统的畸变校正. 利用该校正方法实现透镜前表面的三维重建, 并基于光线追迹实现透镜后表面的三维重建, 进而实现透镜厚度和曲率半径等光学参数的无损测量.

## 2 方法

### 2.1 标定板校正理论模型

OCT 扫描成像畸变校正方法如图 1 所示, 建立笛卡尔坐标系 ( $XYZ$ ), 将标定板所在平面定义为标记平面, 并假定  $XY$  平面与标记平面平行, 标定




图 1 基于标定板的 OCT 成像畸变校正

Fig. 1. Distortion correction of OCT imaging using a calibration plate.

板移动方向为  $Z$  轴方向. 标定板上有均匀分布的“圆孔”图案, “圆孔”图案中心点构成了标记平面中的标记点阵列, 为后续畸变校正提供基准参考.

在理想成像条件下, 聚焦光束中心位置应与标定板所处标记平面的位置无关, 理论上均应落在设定的横向位置上. 然而, 在实际扫描成像系统中, 由于振镜位置偏离聚焦透镜前焦点, 透镜光轴偏离  $Z$  轴, 振镜机械颤动以及环境振动等诸多因素, 聚焦光束在不同标记平面中的横向位置会偏离预设值, 其成像深度值也会相应变化. 不妨将真实空间记为  $D_R$ , 成像空间记为  $D_I$ . 设  $\hat{P}$  为真实空间的标记点,  $P$  为成像空间的标记点, 则  $\hat{P}$  与  $P$  之间映射关系可表示为

$$f(P) = \hat{P}. \quad (1)$$

通过 OCT 系统对不同标记平面处的标定板进行依次成像及后续图像处理, 可获取  $D_I$  空间中标记点  $P(i, j)$  的坐标  $(x, y, z)_{(i, j)}$ . 其中,  $i$  表示标定板所处标记平面的序号,  $j$  表示标记平面中标记点的序号. 根据标定板“圆孔”图案的分布参数与标记平面  $Z$  向间距, 以及各标记面中的基准坐标, 可获取  $D_R$  空间中对应标记点  $\hat{P}(i, j)$  的坐标. 不失一般性, 我们选择参考标记点, 满足:

$$j_0 = \arg \min_j \left\{ \sum_{i=1}^n [(x_{(i, j)} - \bar{x}_j)^2 + (y_{(i, j)} - \bar{y}_j)^2] \right\}, \quad (2)$$

式中,  $\bar{x}_j$  和  $\bar{y}_j$  分别表示第  $j$  个标记点在所有标记

平面中  $x, y$  坐标的平均值. 将参考标记点  $j_0$  在所有标记平面中的平均横向坐标定义为基准横向坐标  $(\bar{x}_{j_0}, \bar{y}_{j_0})$ . 假设成像视场中有  $l$  行  $m$  列标记点, 其中参考标记点位于  $a_0$  行  $b_0$  列, 则第  $a$  行  $b$  列标记点在  $D_R$  中的坐标可由 (3) 式表示:

$$(\hat{x}, \hat{y})_{j=(a-1) \cdot m+b} = [\bar{x}_{j_0} + (b - b_0) \cdot dx, \bar{y}_{j_0} + (a - a_0) \cdot dy], \quad (3)$$

式中,  $dx$  和  $dy$  分别表示标定板“圆孔”图案中心在  $X$  轴和  $Y$  轴方向的间距参数. 对于  $D_R$  空间各标记平面  $S_i$  内任意标记点的纵向坐标  $(z_{idx})$ , 则可以通过离参考标记点最近的 4 个标记点 ( $idx = j_1, j_2, j_3, j_4$ ) 共同确定:

$$\begin{cases} \bar{z}_{idx} = \frac{\sum (\varepsilon_{idx} * z_{idx})}{\sum \varepsilon_{idx}}, \\ \varepsilon_{idx} = \frac{1}{\sqrt{(x_{idx} - \bar{x}_{j_0})^2 + (y_{idx} - \bar{y}_{j_0})^2}}. \end{cases} \quad (4)$$

## 2.2 机器学习模型

基于上述标记点的坐标数据对, 采用多层感知机 MLP 网络进行机器学习建模. 如图 2 所示, 该 MLP 网络由 6 个全连接模块组成, 除输出层外均包含线性层和激活函数. 通过训练过程获得最优网络参数后, 可建立如 (5) 式所示的拟合映射关系:

$$g(p) = p'. \quad (5)$$

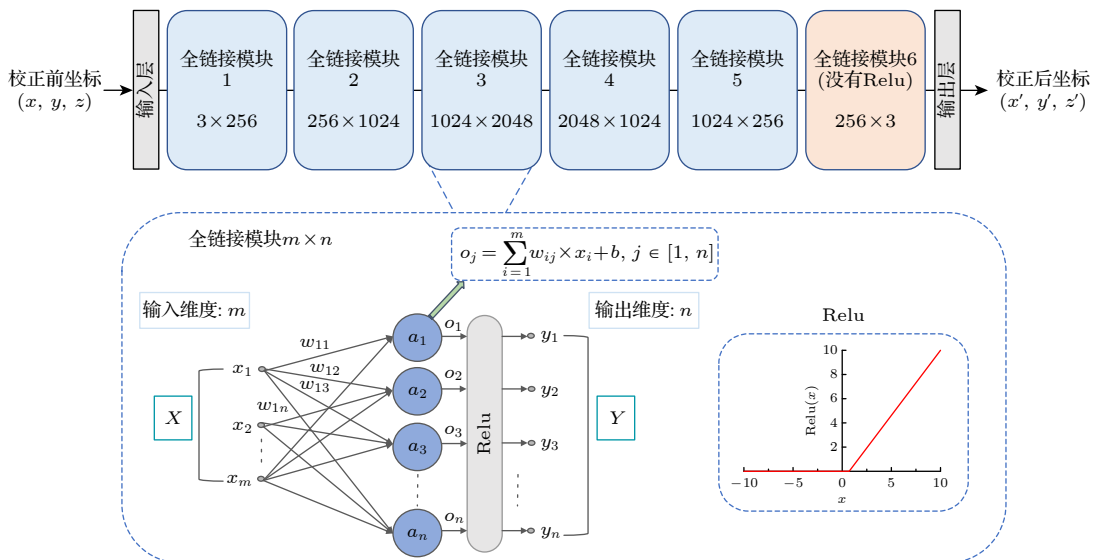


图 2 基于 MLP 网络的映射关系拟合

Fig. 2. Fitting of mapping relationship based on MLP network.

该映射关系具有空间泛化能力,可推广至全空间点集.对于成像空间  $D_I$  中的任意点  $p$  的坐标,均可通过训练后的网络模型拟合得到对应实际空间  $D_R$  中的相应点  $p'$  的坐标,从而实现空间点的精确映射.

### 3 实验系统及测量结果与讨论

#### 3.1 成像系统

扫频 OCT 系统如图 3 所示.该系统的扫频光源中心波长为 1303.5 nm,带宽为 137.13 nm,扫描频率为 100 kHz,平均功率为 22 mW.光源发出的光经光纤耦合器后以 90:10 的比例分束后,分别进入参考臂和样品臂.在参考臂光路中,光束依次通过光环形器,偏振控制器,准直光路及聚焦透镜后,最终聚焦于反射镜表面,反射光沿原光路返回.样品臂光束则通过光环形器,偏振控制器和准直器后,经 X/Y 振镜偏转,由聚焦透镜(焦距 50 mm)入射至样品表面,其背向散射光沿原路径返回.参考光与样品光在光纤耦合器处发生干涉,由平衡探测器接收,并由高速数据采集卡(最大采样速率 500 MS/s)进行数字化处理,最终传输至计算机进行图像重建.该系统轴向分辨率为 11  $\mu\text{m}$ ,横向分辨率为 1.9  $\mu\text{m}$ ,最大成像量程为 4.461 mm.实验过程中,待测样品固定在位移平台上,通过控制振镜进行步进式栅形扫描,快慢轴扫描间隔均为 5  $\mu\text{m}$ ,在一次标定板成像中,共计 1120 $\times$ 1120 个扫描点,对应 5.6 mm $\times$ 5.6 mm 的视场范围.

#### 3.2 实验结果与讨论

将标定板放置在样品台上,并尽可能让聚焦透镜的光轴垂直于标定板.沿 Z 轴移动标定板并选取 28 组标记平面,成像深度分布于 0.4—3.7 mm 区间.基于图像处理的标记点获取流程见图 4.视场中有 11 $\times$ 10 个圆孔,对应 110 个标记点.首先获得标点板的横断面图(图 4(a)),它由系列 OCT 纵截面图沿深度方向叠加投影构成,然后基于强度阈值划分“圆孔”图案区域与周边区域(图 4(b)),进而获得分割模板(图 4(c)),并基于分割模板与局域质心确定“圆孔”图案的中心点作为标记点(图 4(d)).

对所有标记平面处标定板依次进行系统成像与图像处理,可获得成像空间  $D_I$  中所有标记点的点云分布.各标记点在真实空间  $D_R$  中的坐标则通过 (3) 式和 (4) 式精确计算得到.图 5 展示了标记点在成像空间  $D_I$  与真实空间  $D_R$  中的点云分布结果.图 5(a), (b) 分别呈现出第 1 个标记平面中标记点在成像空间与真实空间的分布特征,图 5(c), (d) 则展示了所有标记点在两个空间中的整体分布情况.不难看出,在成像空间  $D_I$  中无序排列且非均匀分布的特征点,经过标定板校正后在真实空间  $D_R$  中呈现出良好的均匀特性,验证了所提出标定方法的有效性和准确性.

将成像空间  $D_I$  中所有标记点的坐标进行归一化处理作为多层感知机 (MLP) 网络的输入数据.具体而言,选取整个空间中心点 (2.8 mm, 2.8 mm, 2.23 mm),将所有输入数据归一化到 (-1, 1)

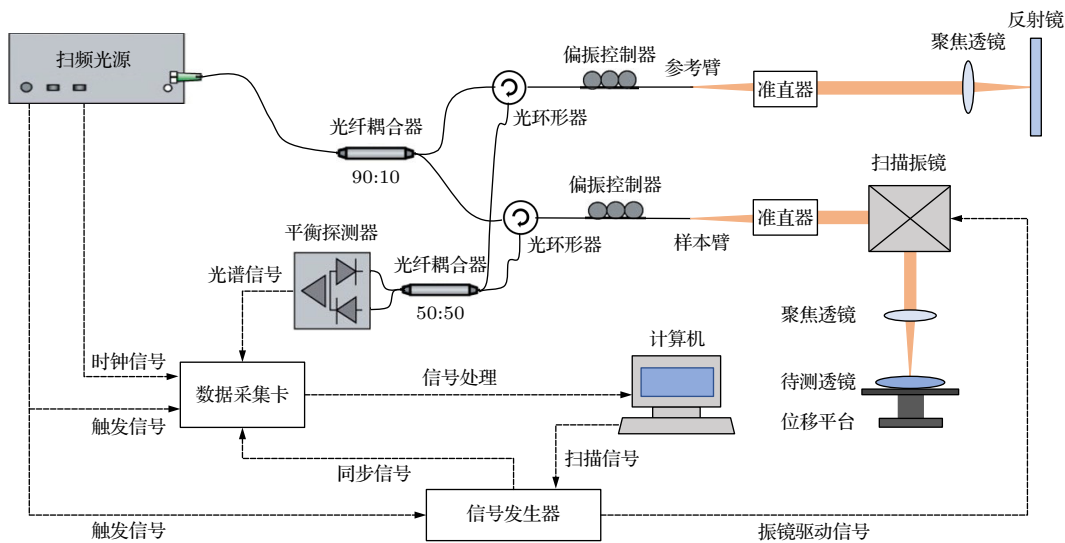


图 3 扫频 OCT 系统

Fig. 3. SS-OCT system.




图 4 成像空间中标记点及其坐标的确定流程 (a) 标定板横断面图; (b) “圆孔”区域与背景区域的划分; (c) 分割模板; (d) 基于“圆孔”区域质心的标记点分布图

Fig. 4. Process for the determination of marker points and their coordinates in the imaging space: (a) Cross-sectional view of the calibration plate; (b) division of the “circular hole” regions from the background; (c) segmentation template; (d) distribution map of marker points by centroids of the “circular hole” regions.

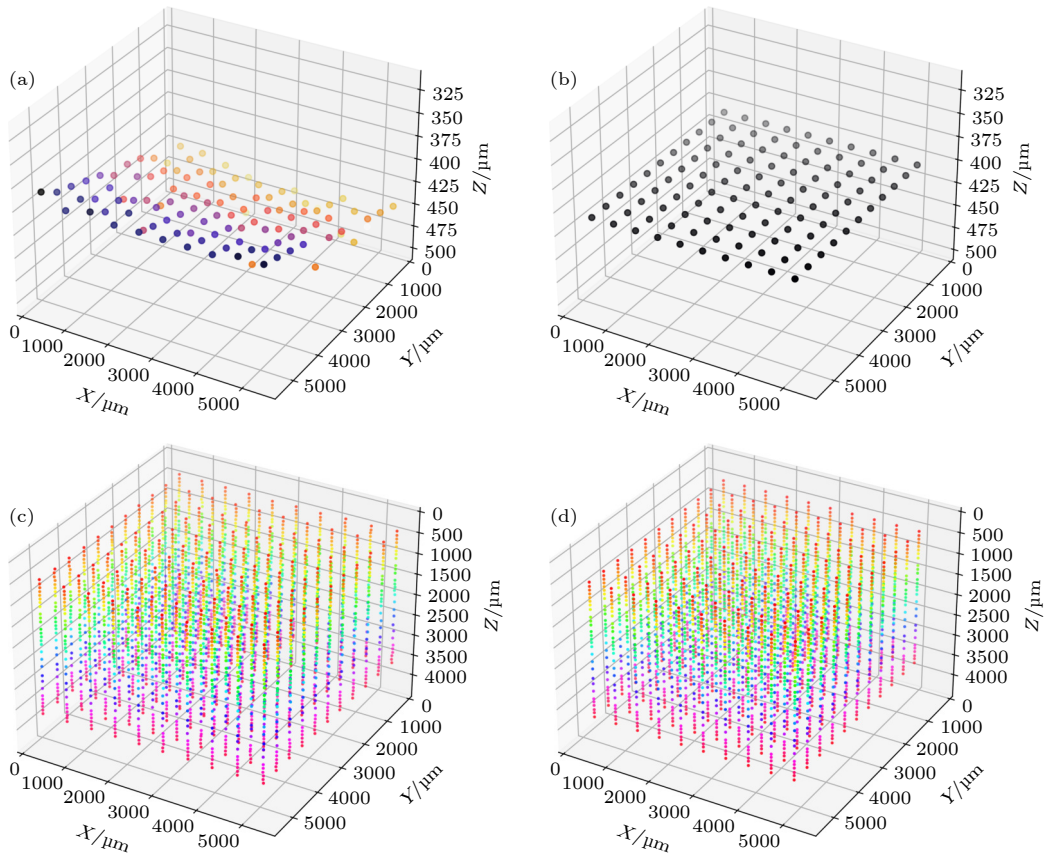


图 5 标记点点云分布 (a) 成像空间单层点云分布; (b) 真实空间单层点云分布; (c) 成像空间全部点云分布; (d) 真实空间全部点云分布

Fig. 5. Distribution of marker point clouds: (a) Single-layer point cloud distribution in imaging space; (b) single-layer point cloud distribution in real space; (c) overall point cloud distribution in imaging space; (d) overall point cloud distribution in real space.

区间内, 可以统一特征尺度, 让优化空间更平滑, 便于使用梯度下降法时快速找到最优路径, 使模型收敛更快. 记为网络输入为  $(x, y, z)_{\text{norm}}$ , norm 表示归一化. 对应真实空间的标记点归一化坐标为  $(\hat{x}, \hat{y}, \hat{z})_{\text{norm}}$ , 网络输出为  $(x', y', z')_{\text{norm}}$ . 将标记平面序号为 2, 10, 18, 26 的标记点坐标数据作为

测试集, 序号为 4, 14, 25 的数据作为验证集, 其余数据作为训练集. 定义训练过程中的损失函数, 如 (6) 式:

$$\text{loss} = |x'_{\text{norm}} - \hat{x}_{\text{norm}}| + |y'_{\text{norm}} - \hat{y}_{\text{norm}}| + \lambda |z'_{\text{norm}} - \hat{z}_{\text{norm}}|, \quad (6)$$

其中,  $\lambda$  为深度项加权系数, 增大  $\lambda$  会加大网络对  $z$

预测偏差的惩罚, 网络会倾向得到  $Z$  轴更小的结果. 实验中  $\lambda \in [1.0, 4.0]$  区间内变化, 对模型进行训练并测试, 随着  $\lambda$  的改变,  $Z$  轴偏差  $\Delta z$  和总偏差  $\Delta s$  均呈现先减小后增大的趋势, 在  $\lambda$  值为 2.5 时达到最小, 综合  $\Delta s$  和  $\Delta z$  的影响, 选择  $\lambda = 2.5$  时的训练模型作为实际畸变校正模型.

其他超参数的设置如下: 由于对三维坐标进行校正, 输入输出维度均为三维, 中间特征采用先扩展后收缩的解码器-编码器结构. 定义 4—8 层以及瓶颈层宽度等参数, 使用网格搜索, 结合验证损失和训练时间, 选择 6 层架构全连接网模型和相应节点数. 梯度下降法中权重的更新由优化器实现. 优化器选择 Adam (adaptive moment estimation)<sup>[21]</sup>, 通常将数据分批训练, 每一批单独计算损失函数梯度并更新权重<sup>[22]</sup>. 每一批的数量 (batch size) 过大时, 训练计算量大, 训练速度慢. batch size 过小时, batch 之间数据差异大, 导致训练波动大, 网络不易收敛. 学习率会影响梯度更新的步长, 使用学习率控制器种类 CosineAnnealingLR 来动态调整学习率, 将初始值设置为 0.01, 权重衰减项为 0.0005. 在训练初期使用较大的学习率更新梯度, 训练后期用较小的学习率微调, 得到最优的网络参数. 训练周期 (epoch) 为 2000, 经过 2000 轮训练后学习率按照余弦曲线降为 0.0002. 最终选取验证集上损失最小的模型权重作为最优模型. 通过将模型输出进行归一化逆变换, 可获得得到映射坐标  $(x', y', z')$ .

为定量评估模型性能, 采用总偏差  $\Delta s$  和轴向偏差  $\Delta x$ ,  $\Delta y$ ,  $\Delta z$  作为评价指标, 并选取四种回归模型与本文方法进行对比: 线性回归, K 近邻回归, 随机森林回归, XGBoost 回归. 如表 1 所示, 本方法在测试集上的预测结果与真实空间坐标之间的偏差值显著低于对比方法, 其中总偏差和轴向偏差均达到最小, 充分证明了本方法具有更高的预测精度和更好的泛化能力.

为进一步探究本文提出模型相对于未校正和传统线性回归方法的畸变校正效果, 绘制出成像空

间中未校正标记点  $P$  和模型校正后点  $P'$  与真实空间标记点  $\hat{P}$  在对应的坐标轴方向上的残差分布图. 如图 6 所示, 纵轴为  $P'$  或  $P$  在某一坐标轴中坐标相对于  $P'$  的残差, 横轴均为  $\hat{P}$  的相应坐标轴坐标. 其中, 图 6(a), (d), (g) 分别为  $P \rightarrow \hat{P}$  的  $X$ ,  $Y$ ,  $Z$  轴上的残差分布, 图 6(b), (e), (h) 分别为线性回归模型输出  $P' \rightarrow \hat{P}$  的  $X$ ,  $Y$ ,  $Z$  轴上的残差分布, 图 6(c), (f), (i) 分别为本文模型输出  $P' \rightarrow \hat{P}$  的  $X$ ,  $Y$ ,  $Z$  轴上的残差分布. 可以看出, 本文提出模型输出校正点  $P'$  与真实空间标记点  $\hat{P}$  的残差明显小于传统线性回归模型校正点  $P'$  与真实空间标记点  $\hat{P}$  的残差, 更具有鲁棒性和可靠性.

表 1 不同回归模型畸变校正效果

Table 1. Distortion correction performance of different regression models.

| 偏差值/ $\mu\text{m}$ | $\Delta x$ | $\Delta y$ | $\Delta z$ | $\Delta s$ |
|--------------------|------------|------------|------------|------------|
| 线性回归               | 11.92      | 18.68      | 9.85       | 40.45      |
| K近邻                | 6.89       | 28.13      | 41.59      | 76.6       |
| 随机森林               | 19.16      | 14.36      | 99.12      | 132.64     |
| XGBoost            | 6.68       | 45.19      | 54.18      | 106.05     |
| 本文方法               | 3.49       | 2.67       | 6.94       | 13.11      |

利用扫频 OCT 系统对平凸透镜、双凸透镜、双凹透镜 (选自南阳晶亮光电科技公司) 进行三维成像, 图 7 展示了 3 种透镜第 1 表面在校正前后的点云分布对比结果. 图 7(a), (c), (e) 分别为 3 种透镜校正前点云分布; 图 7(b), (d), (f) 为 3 种透镜校正后点云分布.

在透镜第 1 面面型参数基础上, 采用光线追迹方式完成透镜第 2 面的折射畸变校正, 最后利用最小二乘法<sup>[23]</sup>进行球面拟合, 计算出透镜的中心厚度和曲率半径. 表 2—表 4 分别展示了平凸透镜、双凸透镜、双凹透镜畸变校正前后计算的曲率半径  $R_1$ ,  $R_2$  和中心厚度  $d$  与名义标准值的差别. 表中括号内的数值分别为测量值与名义标准值的绝对误差和相对误差. 其中校正前的中心厚度计算已从光程中除去折射率, 为实际距离.

表 2 平凸透镜矫正前后参数测量结果对比

Table 2. Comparison of parameter measurement results for plano-convex lens before and after correction.

| 平凸透镜     | R1                     | R2       | $d$                 |
|----------|------------------------|----------|---------------------|
| 校正前/mm   | 129.05 (45.71%/54.84%) | —        | 1.334 (0.054%/4.2%) |
| 校正后/mm   | 83.33 (0.01%/0.01%)    | —        | 1.288 (0.008%/0.6%) |
| 名义标准值/mm | -83.34                 | $\infty$ | 1.28                |

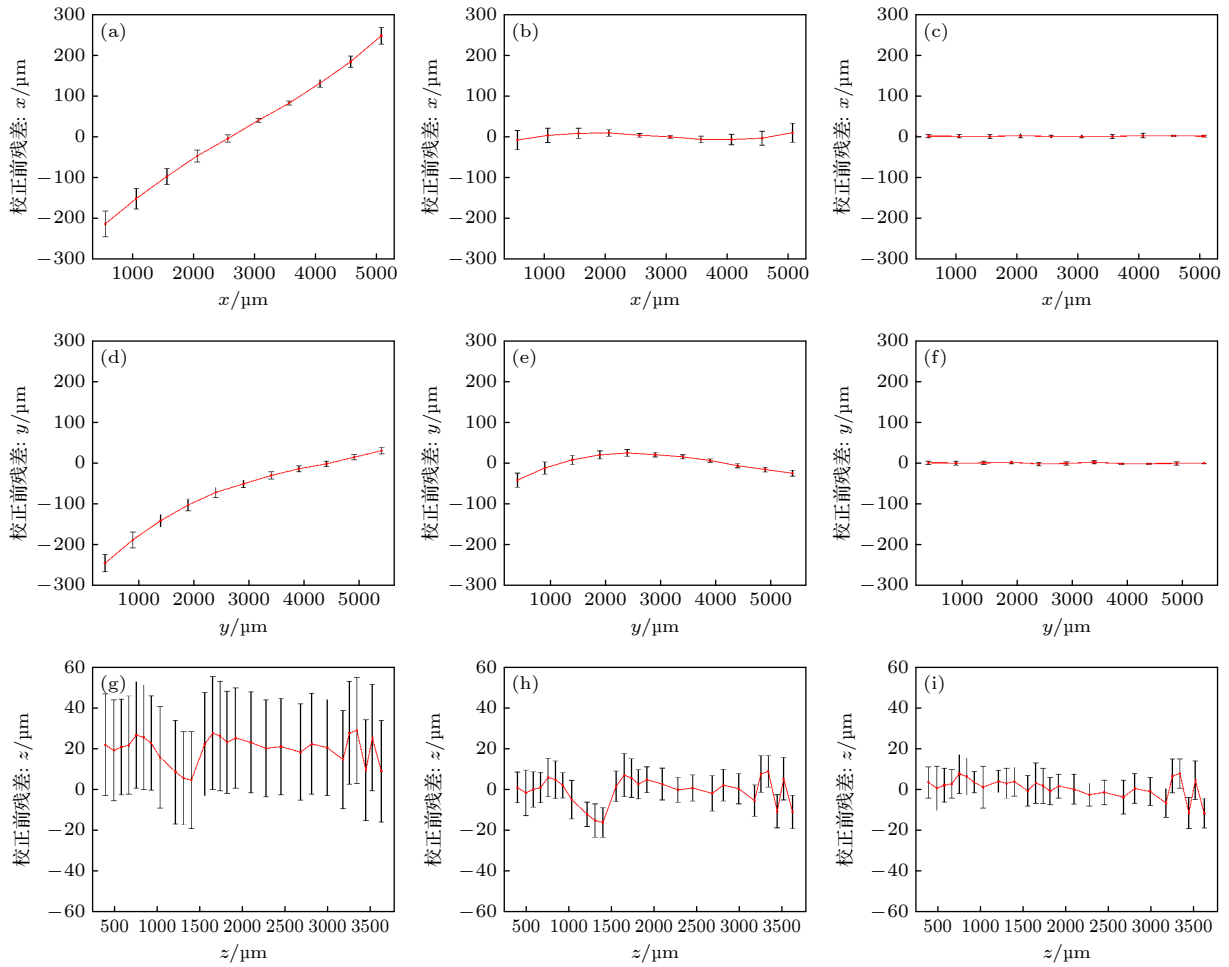


图 6 模型校正与真实点轴向残差与未校正对应真实点轴向残差分布图 (a), (d), (g) 未校正点  $P$  与对应真实空间点  $\hat{P}$  坐标的  $X, Y, Z$  轴向残差; (b), (e), (h) 线性回归模型的校正点  $P'$  与对应真实空间点  $\hat{P}$  坐标的  $X, Y, Z$  轴向残差; (c), (f), (i) 本文校正模型的校正点  $P'$  与对应真实空间点  $\hat{P}$  坐标的  $X, Y, Z$  轴向残差

Fig. 6. Comparison of axial residuals between model-corrected data and true points versus uncorrected data and true points, along with their distribution plots: (a), (d), (g) Axial residuals ( $X/Y/Z$ ) between uncorrected point  $P$  and the ground-truth spatial point  $\hat{P}$ ; (b), (e), (h) axial residuals ( $X/Y/Z$ ) between the linear regression-corrected point  $P'$  and the ground-truth spatial point  $\hat{P}$ ; (c), (f), (i) axial residuals ( $X/Y/Z$ ) between the proposed model-corrected point  $P'$  and the ground-truth spatial point  $\hat{P}$ .

表 3 双凸透镜校正前后参数测量结果对比

Table 3. Comparison of parameter measurement results for biconvex lens before and after correction.

| 双凸透镜     | R1                  | R2                  | $d$                 |
|----------|---------------------|---------------------|---------------------|
| 校正前/mm   | 30.56 (6.01%/24.5%) | 31.38 (6.83%/27.8%) | 1.958 (0.48%/2.5%)  |
| 校正后/mm   | 24.58 (0.03%/0.1%)  | 24.73 (0.18%/0.7%)  | 1.918 (0.008%/0.4%) |
| 名义标准值/mm | -24.55              | 24.55               | 1.91                |

表 4 双凹透镜校正前后参数测量结果对比

Table 4. Comparison of parameter measurement results for biconcave lens before and after correction.

| 双凹透镜     | R1                  | R2                  | $d$                 |
|----------|---------------------|---------------------|---------------------|
| 校正前/mm   | 29.87 (4.77%/19.0%) | 18.93 (6.17%/24.6%) | 0.927 (0.023%/2.4%) |
| 校正后/mm   | 25.17 (0.07%/0.2%)  | 24.94 (0.16%/0.6%)  | 0.947 (0.003%/0.3%) |
| 名义标准值/mm | 25.10               | -25.10              | 0.95                |

从表 2—表 4 可以看出, 校正后透镜曲率半径的精度达到  $10 \mu\text{m}$  量级, 相对误差在 1% 以内, 相

对于校正前有显著提升. 在中心厚度测量方面, 精度可达  $3 \mu\text{m}$ , 相对误差为 0.3%, 较校正前有明显

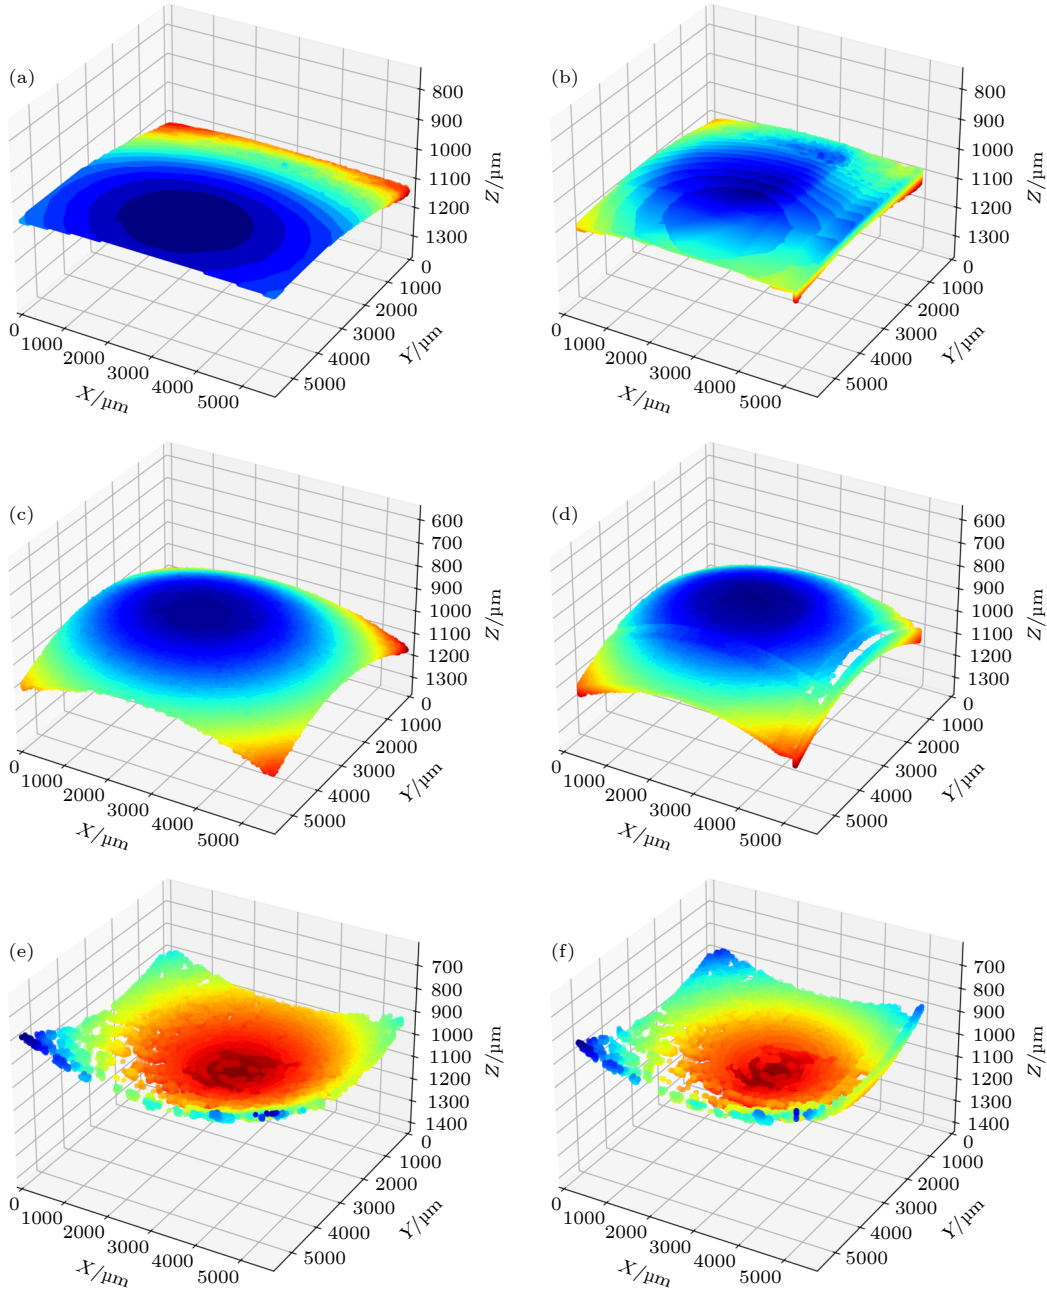


图 7 3种透镜第一面校正前后点云分布 (a) 平凸透镜校正前; (b) 平凸透镜校正后; (c) 双凸透镜校正前; (d) 双凸透镜校正后; (e) 双凹透镜校正前; (f) 双凹透镜校正后

Fig. 7. Point cloud distribution of the first surface of three types of lenses before and after correction: (a) Plano-convex lens before correction; (b) plano-convex lens after correction; (c) biconvex lens before correction; (d) biconvex lens after correction; (e) biconcave lens before correction; (f) biconcave lens after correction.

改善. 综合上述实验结果, 基于机器学习的畸变校正网络能有效校正扫频 OCT 图像中的畸变, 显著提高透镜参数的测量精度.

## 4 结 论

本文提出了一种基于机器学习的 OCT 成像畸变校正方法. 该方法通过标定平板成像构建

OCT 成像空间与真实空间标记点的映射关系, 并利用神经网络学习这些映射对, 从而实现全空间中点的映射关系拟合. 基于训练后的网络模型, 对透镜的 OCT 图像进行校正得到透镜第 1 面的点云分布. 结合光线追迹, 有效消除了透镜第 2 面的折射畸变. 最后利用最小二乘法进行球面拟合, 计算出透镜参数. 对比测量透镜厚度和曲率半径常用的差动共焦法和干涉法, 本文开发的技术具有明显优

势. 首先, 实验系统的调试环境相对宽松, 可以在日常生产环境中进行测量. 差动共焦法对待球面面型、空气扰动、系统噪声有着极端苛刻的要求, 干涉法也需要对球面顶点进行良好定焦. 本方法可实现单通过一次成像对多个透镜参数进行测算, 且保持较高精度. 其次, 干涉法和差动共焦法都需要严格保证测量光束垂直入射透镜所在平面, 且测量光束经过透镜前后表面的曲率中心. 但本方法对系统校准度和透镜摆放位姿要求都较低, 即可以在入射光路与透镜光轴不平行的情况下进行测量可用于生产测量中.

### 参考文献

- [1] Huang D, Swanson E A, Lin C P, Schuman J S, Stinson W G, Chang W, Hee M R, Flotte T, Gregory K, Puliafito C A, Fujimoto J G 1991 *Science* **254** 1178
- [2] Tomlins P H, Wang R K 2005 *J. Phys. D Appl. Phys.* **38** 2519
- [3] Ding Y T, Zhang J, Guo Y, Chen H 2024 *Laser Optoelectron. Prog.* **61** 247 (in Chinese) [丁宇韬, 张君, 郭遥, 陈昊 2024 *激光与光电子学进展* **61** 247]
- [4] Volker W, Andrew R, Sunita R, Joseph I 2002 *Opt. Express* **10** 397
- [5] Diaz J, Rahlves M, Majdani O, Reithmeier E, Ortmaier T 2012 *Optical Metrology and Inspection for Industrial Applications II* Beijing, China, November 5–7, 2012 p8563J
- [6] Yao J, Anderson A, Rolland J P 2018 *Opt. Express* **26** 10242
- [7] Jiang X Q, Fan Y Q, Wang W 2014 *J. Front. Comput. Sci. Technol.* **8** 1254 (in Chinese) [江祥奎, 范永青, 王婉 2014 *计算机科学与探索* **8** 1254]
- [8] Qi Z S, Wang Z, Huang J H, Xue Q, Gao J M 2016 *Acta Photonica Sin.* **45** 87 (in Chinese) [齐召帅, 王昭, 黄军辉, 薛琦, 高建民 2016 *光子学报* **45** 87]
- [9] Lecun Y, Bottou L, Bengio Y, Haffner P 1998 *Proc. IEEE* **86** 2278
- [10] Li X Y, Zhang B, Sander P V, Liao J 2019 *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* Long Beach, CA, USA, June 15–20, 2019 p4850
- [11] Yang S R, Lin C Y, Liao K, Zhang C J, Zhao Y 2021 *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* Nashville, TN, USA, June 20–25, 2021 p6344
- [12] Xu Q W, Wang P P, Zeng Z J, Huang Z B, Zhou X X, Liu J M, Li Y, Chen S Q, Fan D Y 2020 *Acta Phys. Sin.* **69** 014209 (in Chinese) [徐启伟, 王佩佩, 曾镇佳, 黄泽斌, 周新星, 刘俊敏, 李瑛, 陈书青, 范滇元 2020 *物理学报* **69** 014209]
- [13] Zhou J, Zhang X F, Zhao Y G 2021 *Acta Phys. Sin.* **70** 054201 (in Chinese) [周静, 张晓芳, 赵延庚 2021 *物理学报* **70** 054201]
- [14] Shukla S, Vishwakarma C, Sah A N, Ahirwar S, Pandey K, Pradhan A 2023 *Appl. Opt.* **62** 6826
- [15] Breiman L, 2001 *Mach. Learn.* **45** 5
- [16] Xie T Y, Li Y M, Zhang T, Gao T L, Shi Y C 2023 *Mod. Mach. Tool Autom. Manuf. Tech.* **2** 37 (in Chinese) [谢探阳, 李玉梅, 张涛, 高天亮, 石玉超 2023 *组合机床与自动化加工技术* **2** 37]
- [17] Kato D, Maeda N, Hirogaki T, Aoyama E, Takahashi K 2021 *21st International Conference on Control, Automation and Systems* Jeju, Korea, October 12–15, 2021 p607
- [18] Werbos P J 1981 *System Modeling and Optimization* Berlin, Germany, July 20–24, 1981 p762
- [19] Rumelhart D E, Hinton G E, Williams R J 1986 *Nature* **323** 533
- [20] Yang Y S, Wang X, Ren M J 2023 *Acta Opt. Sin.* **43** 200 (in Chinese) [杨沅松, 王晰, 任明俊 2023 *光学学报* **43** 200]
- [21] Singarimbun R N, Nababan E B, Sitompul O S 2019 *2019 International Conference of Computer Science and Information Technology (ICoSNiKOM)* Medan, Indonesia, November 28–29, 2019 p1
- [22] Cotter A, Shamir O, Srebro N, Sridharan K 2011 *Advances in Neural Information Processing Systems* Granada, Spain, December 12–15, 2011 p1647
- [23] Fitzgibbon A, Pilu M, Fisher R B 1999 *IEEE Trans. Pattern Anal. Mach. Intell.* **21** 476

## A machine learning approach to correct imaging distortions in swept-source optical coherence tomography\*

MA Cui<sup>1)</sup> CHEN Peizhe<sup>1)</sup> YANG Lu<sup>1)</sup> HAN Tao<sup>1)</sup> TANG Yun<sup>1)</sup>

CHEN Changyong<sup>1)</sup> DING Zhihua<sup>1)2)†</sup>

1) (State Key Laboratory of Extreme Photonics and Instrumentation, College of Optical Science and Engineering, Zhejiang University, Hangzhou 310027, China)

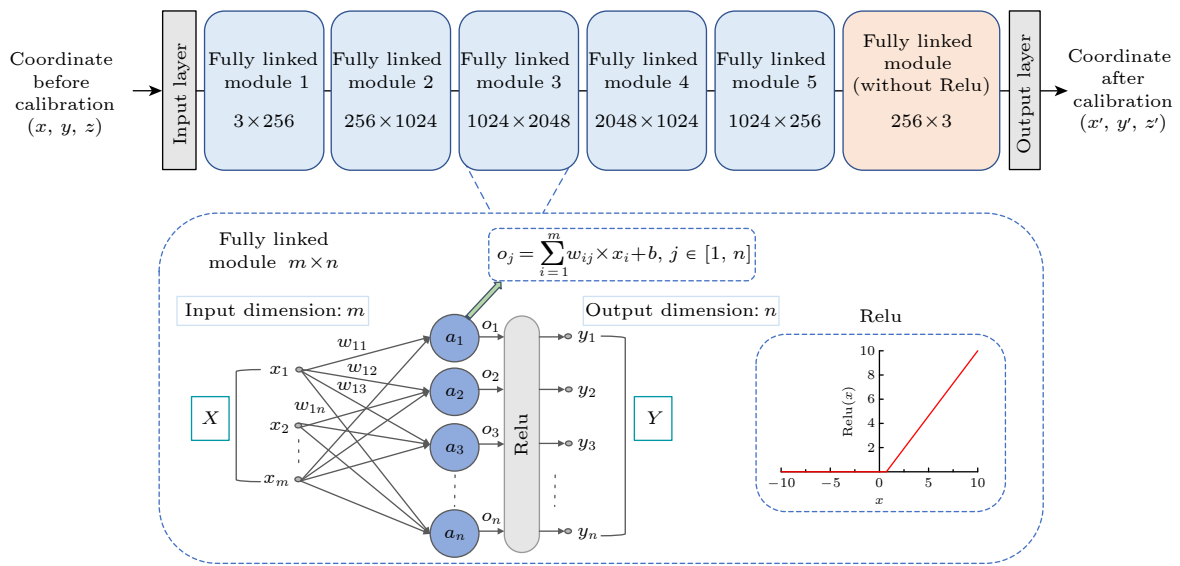
2) (Global Scientific and Technological Innovation Center, Zhejiang University, Hangzhou 311215, China)

(Received 24 April 2025; revised manuscript received 5 June 2025)

### Abstract

The inevitable distortions in optical coherence tomography (OCT) imaging often lead to mismatches between the imaging space and the real space, significantly affecting measurement accuracy. To address this issue, this study proposes a machine learning-based OCT image distortion correction method. A calibration

plate with uniformly distributed circular hole arrays is sequentially imaged at different marked planes. The point showing minimal deviation between its coordinates and the mean coordinates in all imaging planes is selected as a reference marker. A mathematical model is then used to reconstruct all marker point coordinates in the reference plane, establishing a mapping relationship between the imaging space of calibration plate and the real physical space. A multilayer perceptron (MLP) is employed to learn this mapping relationship. The network architecture consists of multiple fully-connected modules, each with a linear layer and an activation function besides the output layer. The optimal model is selected based on validation set performance, and then used to analyze the spatial distribution of points. Using a swept-source OCT system, lens images are acquired and corrected through the trained model to obtain the anterior surface point cloud. Combined with ray tracing reconstruction of the posterior surface, the lens curvature radius and central thickness are calculated. The experimental results show that after correction, the lens curvature radius is measured with an accuracy of 10  $\mu\text{m}$  (error < 1%), while the central thickness is determined, with an accuracy of 3  $\mu\text{m}$  (relative error: 0.3%). This method shows high accuracy and reliability, providing an effective solution for improving OCT measurement accuracy.



**Keywords:** optical coherence tomography, machine learning, distortion correction

**PACS:** 42.25.Kb, 07.05.Mh, 07.05.Pj

**DOI:** 10.7498/aps.74.20250545

**CSTR:** 32037.14.aps.74.20250545

\* Project supported by the National Natural Science Foundation of China (Grant No. 62035011).

† Corresponding author. E-mail: zh\_ding@zju.edu.cn



## 基于机器学习的扫频光学相干断层扫描成像畸变校正

马翠 陈沛哲 杨璐 韩涛 汤贇 陈昌勇 丁志华

### A machine learning approach to correct imaging distortions in swept-source optical coherence tomography

MA Cui CHEN Peizhe YANG Lu HAN Tao TANG Yun CHEN Changyong DING Zhihua

引用信息 Citation: *Acta Physica Sinica*, 74, 164202 (2025) DOI: 10.7498/aps.74.20250545

CSTR: 32037.14.aps.74.20250545

在线阅读 View online: <https://doi.org/10.7498/aps.74.20250545>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 用于内窥镜光学相干层析成像的小型化预标定Lissajous扫描光纤探头

A miniaturized pre-calibration based Lissajous scanning fiber probe for endoscopic optical coherence tomography

物理学报. 2021, 70(15): 150701 <https://doi.org/10.7498/aps.70.20210151>

#### 基于机器学习的单拍冷原子成像

Single shot imaging for cold atoms based on machine learning

物理学报. 2023, 72(14): 144201 <https://doi.org/10.7498/aps.72.20230449>

#### 机器学习的量子动力学

Quantum dynamics of machine learning

物理学报. 2025, 74(6): 060701 <https://doi.org/10.7498/aps.74.20240999>

#### 基于光学相干血流造影引导的近红外一区视网膜血氧饱和度测量

Near-infrared band I retinal oximetry guided by optical coherence tomography angiography

物理学报. 2025, 74(7): 074201 <https://doi.org/10.7498/aps.74.20241686>

#### 基于机器学习的激光匀光整形方法

Machine learning based laser homogenization method

物理学报. 2024, 73(16): 164205 <https://doi.org/10.7498/aps.73.20240747>

#### 基于波动与扩散物理系统的机器学习

Machine learning based on wave and diffusion physical systems

物理学报. 2021, 70(14): 144204 <https://doi.org/10.7498/aps.70.20210879>