

文章编号: 1004-7220(2024)05-0853-07

数据驱动下合并狭窄左冠状动脉瘤血流动力学参数反演方法

石政加¹, 孙丽芳^{2*}, 赵明轩¹, 纪猛强¹, 史玉龙¹, 桑建兵^{1*}

(1. 河北工业大学机械工程学院, 天津 300401; 2. 河北工业大学医院 内科, 天津 300401)

摘要: **目的** 探究应用机器学习预测合并狭窄左冠状动脉瘤血流动力学参数预测。**方法** 首先根据临床统计的合并狭窄左冠状动脉瘤几何参数范围进行参数化建模和仿真, 将得到的仿真数据作为数据集, 通过搭建两种常见的机器学习模型并训练优化, 对壁面剪切力 (wall shear stress, WSS) 和压力这两个关键的血流动力学参数进行预测反演。通过对比分析这些模型在训练集和测试集上的表现, 评估各个模型的准确性, 验证数据驱动下合并狭窄左冠状动脉瘤血流动力学参数预测的有效性。**结果** 确定了机器学习方法在动脉瘤血流动力学参数反演的有效性。对于 WSS 预测, 训练后深度学习模型和随机森林模型的均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE)、决定系数 R^2 分别达到了 0.052 8、0.032 2、0.988 3 和 0.078 2、0.046 3、0.976 6。对于压力预测, 深度学习模型和随机森林模型预测精度相当, MSE、MAE、 R^2 分别为 4.67×10^{-6} 、 3×10^{-4} 、0.999 7 和 1.07×10^{-5} 、 5×10^{-4} 、0.999 3。**结论** 机器学习方法在预测合并狭窄冠状动脉瘤模型的血流动力学参数方面表现出较高的精度, 在进行机器学习预测时需要综合考虑模型的预测准确性、计算效率以及应用场景的需求, 根据具体情况选择合适的模型。研究解果具有一定的临床意义, 有助于医生更准确地评估患者病情, 为心血管疾病的诊疗提供新思路和方法。

关键词: 动脉瘤; 数值模拟; 机器学习; 深度学习; 随机森林; 血流动力学

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2024.05.009

Data-Driven Inversion of Hemodynamic Parameters for Combined Stenotic Left Coronary Artery Aneurysms

SHI Zhengjia¹, SUN Lifang^{2*}, ZHAO Mingxuan¹, JI Mengqiang¹, SHI Yulong¹, SANG Jianbing^{1*}

(1. School of Mechanical Engineering, Hebei University of Technology, Tianjin 300401, China; 2. Department of Internal Medicine, Hebei University of Technology Hospital, Tianjin 300401, China)

Abstract: **Objective** To investigate the application of machine learning to predict the hemodynamic parameters of combined stenotic left coronary artery (LCA) aneurysms. **Methods** Parameterized modeling and simulation based on the geometric parameter range of combined stenosis LCA aneurysms in clinical statistics were conducted. The obtained simulation data was used as the dataset, and two common machine learning models were constructed and trained for optimization to predict two key hemodynamic parameters: wall shear stress

收稿日期: 2024-03-13; 修回日期: 2024-04-26

基金项目: 河北省自然科学基金项目 (A2020202015, A2021202014), 国家自然科学基金项目 (12102123)

通信作者: 桑建兵, 教授, E-mail: sangjianbing@hebut.edu.cn; 孙丽芳, 副主任医师, E-mail: sunlifang@hebut.edu.cn

* 为共同通信作者

(WSS) and pressure. By comparing and analyzing the performances of these models on the training and testing sets, the accuracy of each model was evaluated, and the effectiveness of the data-driven prediction of hemodynamic parameters for LCA aneurysms with concomitant stenosis was verified. **Results** The effectiveness of machine learning method in inverting the hemodynamic parameters of aneurysms was determined. For WSS prediction, the trained deep learning model and random forest model achieved mean squared error (MSE), mean absolute error (MAE), and determination coefficient R^2 of 0.052 8, 0.032 2, 0.988 3, and 0.078 2, 0.046 3, and 0.976 6, respectively. For pressure prediction, the accuracies of the deep learning models and random forest models were comparable, with MSE, MAE, and R^2 of 4.67×10^{-6} , 3×10^{-4} , 0.999 7, and 1.07×10^{-5} , 5×10^{-4} , and 0.999 3, respectively. **Conclusions** Machine learning methods show high accuracy in predicting the hemodynamic parameters of combined stenotic coronary artery aneurysm models. The predictive accuracy of the model, computational efficiency, and needs of the application scenarios need to be considered in machine learning prediction so that the appropriate model can be selected according to the specific situation. This study has clinical significance, helping doctors to more accurately evaluate a patient's condition and provide new ideas and method for the diagnosis and treatment of cardiovascular diseases.

Key words: aneurysm; numerical simulation; machine learning; deep learning; random forest; hemodynamics

近年来,人工智能在诸多学科领域得到广泛应用^[1-4],机器学习是人工智能的一个子集,是指机器能够独立学习数据中隐藏模式并做出准确预测以提高特定任务性能的算法和统计模型^[5]。人工智能可以代替计算流体力学(computational fluid dynamics, CFD)和流固耦合等传统模拟计算方法,加速疾病预测的过程并减少人工干预,在心血管领域研究和临床应用方面应用前景广泛。Ali等^[6]比较了不同机器学习算法在心血管疾病预测方面的性能和准确性。Farajtabar等^[7]提出了一个神经网络框架来预测存在任何异常(如狭窄)时具有不同性质的冠状动脉网络中的流动行为。Li等^[8]搭建了点云数据集和双采样通道深度学习网络,分析和重现了心血管几何形状和内部血流动力学之间的关系。同样,国内很多学者也将机器学习方法与心血管领域相结合。杨翀等^[9]构建了机器学习算法对动脉瘤性蛛网膜下腔出血预后模型进行预测,证明机器学习模型有较好的预测效果。苑玮琦等^[10]提出了一种基于并联多尺度卷积神经网络的微动脉瘤检测方法,实验结果表明该方法检测效果更好。

本文提出了数据驱动下合并狭窄左冠状动脉瘤血流动力学参数的反演方法。首先,对合并狭窄左冠状动脉瘤进行参数化建模,并对其进行计算流体力学仿真,共生成200个几何模型。搭建了两种机器学习模型,将模型的几何参数和坐标作为机

器学习的输入,将壁面切应力(wall shear stress, WSS)和压力作为机器学习的输出,将机器学习模型预测的WSS和压力与CFD仿真得到的结果进行比较,以评估机器学习模型的预测效果。

1 有限元模型

基于文献[11]重建了理想化的合并狭窄左冠状动脉瘤分叉血管模型,包括左主干(left main, LM)、左前降支(left anterior descent, LAD)和左回旋支(left circumflex, LCX)。根据抽样得出的几何数据对模型进行参数化建模和CFD仿真,首先确定网格参数的设置。本文采用四面体网格划分以实现血管模型内部血流的数值模拟分析,使用无滑移边界条件,共划分5层边界层网格(见图1)。




图1 模型各区域网格结构

Fig. 1 Grid structure of each region in the model

根据 Craiem 等^[12]的统计结果,对合并狭窄动脉瘤模型的参数进行统计(见表1)。共有10个参数需要进行数据抽样,选用拉丁超立方抽样方法,从超参数范围空间中抽取200组数据作为样本点。

表1 相关参数名称和范围

Tab. 1 Related parameter names and ranges

参数	取值范围	参数	取值范围
LM 长度/mm	5.5~13.1	LCX 直径/mm	2.64~4.04
LAD 长度/mm	15.1~20.9	LAD-LCX 夹角/(°)	54.2~87.6
LCX 长度/mm	12.5~19.5	LAD-LM 夹角/(°)	120.5~149.1
LM 直径/mm	3.36~4.80	狭窄率/%	0~70
LAD 直径/mm	3.08~4.36	血管瘤半径/mm	3~8

针对仅存在血管瘤病变、曲率半径为 ∞ 的左冠状动脉血管模型,采用沿血流入口到血流出口的WSS作为判断依据进行网格无关性分析。分别设置最小单元尺寸为0.34、0.26和0.20 mm,以确保网格数量按照两倍数依次扩大。仿真结果显示,在601 284个网格和1 200 762个网格之间,WSS相差仅为1.67%。基于此结果,最终确定了601 284个网格时的最小单元尺寸为0.26 mm,并将该尺寸控制参数应用于其他模型中(见图2)。




图2 网格无关性分析

Fig. 2 Grid independence analysis

在血流动力学模拟中一般主要使用的非牛顿模型有 Carreau、Carreau-Yasuda、Casson、Modified Casson 和 Quemada 黏度模型。Abbasian 等^[12]通过对比15种血液黏度模型得出 Carreau 黏度模型更适合左冠状动脉血流动力学模拟。因此,本文考虑采用 Carreau 模型作为血液模型进行数值模拟,为了便于数据处理,使用稳态仿真,根据临床数据可

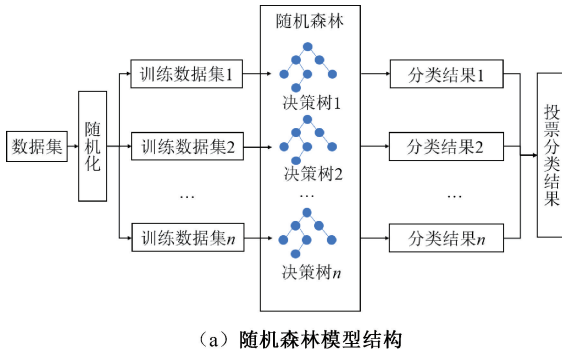
知血流密度为 $1\ 050\ \text{kg/m}^3$,同时根据临床测量结果,计算得到 LM 血流入口处平均速度为 $231.3\ \text{mm/s}$,LAD 和 LCX 的平均压力分别为 $14\ 219.2$ 、 $14\ 016.12\ \text{Pa}$ 。仿真时将血管壁设置为刚性壁面,血液流动由 N-S 方程与连续性方程控制。使用 ANSYS Fluent 2022R1 的有限体积法进行迭代求解流体控制方程,采用二阶迎风离散格式以提高精度和确保快速收敛,重复这一过程直至迭代至残差值小于1%。经过计算所有模型的雷诺数均在层流范围内,故采用层流设置^[13]。时间步长设置为 $0.01\ \text{s}$,用具有 96 核、3.4 GHz 处理器和 256 GB RAM 工作站进行模拟计算。

2 机器学习模型搭建

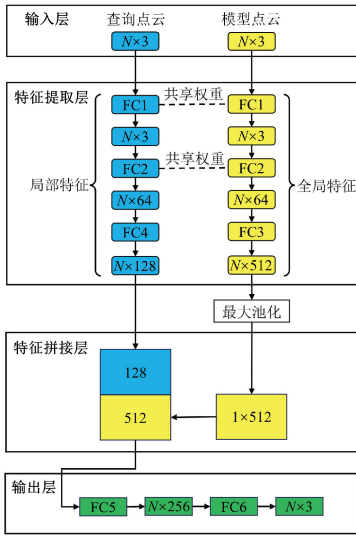
随机森林以多个决策树为基本构建模块,用以提高模型的性能和鲁棒性。本文采用的随机森林模型由46个决策树组成,决策树节点最小样本量为12,决策树叶节点数量为5,预测时通过对数据集进行有放回抽样(bootstrap)来构建每棵树,并对每个节点进行特征的随机选择来增加模型的多样性[见图3(a)]。深度学习由输入层、多个隐藏层和输出层组成。PointNet 是一种创新性的深度学习模型,专门用于处理点云数据,该模型由 Charles 等^[14]提出。本文搭建了基于 PointNet 的深度学习模型,包括两个输入层,分别用于导入合并狭窄的动脉瘤模型的模型点云和查询点云,模型点云包含每个点的坐标,查询点云包含模型的几何参数。特征提取层中两个特征提取模块直接与两个输入层连接。模块1提取动脉瘤的空间坐标作为全局特征,模块2提取查询点云的几何特征作为局部特征。为了增强全局特征和局部特征之间的关系,全连接层1(fully connected layer 1, FC1)和全连接层2(fully connected layer 1, FC2)共享权重,最终输出 WSS 和压力的预测值[见图3(b)]。

3 机器学习模型预测结果

对参数化建模后的200个三维模型进行 CFD 仿真,计算1个心动周期内的血流动力学参数。壁面剪应力(wall shear stress, WSS)和压力(p)的表达式如下:



(a) 随机森林模型结构



(b) 深度学习网络模型

图3 机器学习模型

Fig. 3 Machine learning model (a) Random forest model, (b) Deep learning models

$$WSS = \frac{1}{n-i} \sum_{i=1}^n WSS_i \quad (1)$$

$$P = \frac{1}{n-i} \sum_{i=1}^n P_i \quad (2)$$

式中: n 为心动周期步数, $n = 100$; WSS_i 、 P_i 分别为每个时间步的计算结果。


3.1 WSS 预测结果

最终得到 200 个模型的仿真结果, 其中每个模型约有 3 万个节点数, 每个节点包含 10 个参数, 生成包含 $(4 \sim 6) \times 10^6$ 组数据的数据集。对上述仿真结果进行训练集和测试集的划分, 80% 为训练集, 剩余 20% 为测试集, 并且通过优化好的机器学习模型对其进行训练。散点图中点的分布越接近 1 条直线, 表示机器学习模型预测值与真实值越接近, 预测性能越好。由 WSS 真实值与预测值的散点图可

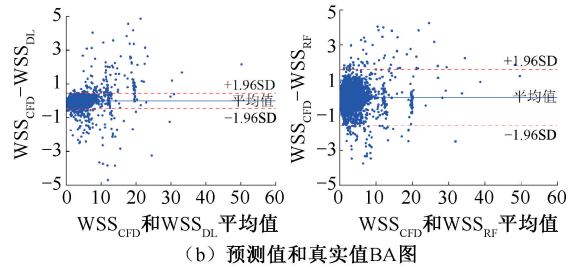
见, 深度学习模型的拟合程度更好, 其散点分布更接近于直线[见图 4(a)]。

Bland-Altman 图又称 BA 图, 图中包括 1 条表示差异的平均线和上下两条限制线。评估两组数据的一致性时, 需要综合观察平均差异线和上下两条限制线之间的距离以确定模型的预测性能。上下两条限制线表示平均差异的 ± 1.96 倍标准差, 通过判断大多数数据点是否在这些限制线内, 以对比两组数据的一致性。由图 4(b) 可见, 两个模型中的大部分点都分布在上下两条限制线之间, 但深度学习模型上下两条限制线之间的距离更短且平均差异线更接近于 0, 证明了机器学习方法预测合并狭窄左冠状动脉的有效性。


为了更直观地比较两个机器学习模型的预测结果, 选择 LM、LAD、LCX 长度分别为 9.64、14.16、



(a) 预测值和真实值散点图



(b) 预测值和真实值BA图



(c) WSS云图

图4 壁面剪应力预测值和模拟值对比

Fig. 4 Comparison between predicted and simulated wall shear stress values (a) Scatter plot of predicted and actual values, (b) BA plots of predicted and true values, (c) WSS contours

注: WSS_{DL} 、 WSS_{RF} 、 WSS_{CFD} 分别表示深度学习模型、随机森林模型计算以及计算流体力学仿真得出的壁面切应力。

16.78 mm, 半径分别为 2.18、1.96、1.67 mm, LAD 与 LCX 夹角为 63.55° , 狭窄率为 64.43%, 血管瘤半径为 5.5 mm 三维模型进行可视化分析。将 CFD、深度学习模型和随机森林模型 3 种方法计算得出的 WSS 进行对比。结果显示, 通过 CFD 方法计算得出的狭窄部位的 WSS 较高, 最大值可达 18.69 Pa。这是因为血液通过狭窄处时流速增加, 导致血管壁面的摩擦力增加。在血管分叉处, 由于血流方向的改变和血管几何形状的改变, 造成血流的分离和重新聚合, 流体在分叉处可能产生流动分离等流体扰动, 导致分叉处壁面附近的流速增加, 从而增加 WSS。并且流入 LCX 的血流速度和方向变化复杂, 导致 LCX 中 WSS 增加。对比可知, 机器学习模型和 CFD 两种方法计算所得的 WSS 分布基本一致。同时, 通过对比分析深度学习和随机森林算法的预测结果, 发现 LCX 靠近血管瘤位置深度学习模型相较于随机森林模型的预测结果较为准确[见图 4(c)]。

3.2 压力预测结果

将上述两个机器学习模型应用于压力预测中, 通过压力预测值和真实值散点图, 可以直观地观察到深度学习模型预测值和真实值之间的相关性相较随机森林模型更好, 大部分点都分布于 $y=x$ 附近[见图 5(a)]。

由图 5(b) 可见, 深度学习模型和随机森林模型的数据点落在 95% 置信区间内, 两模型的平均差异线和上下两条限制线之间的距离接近, 预测性能接近。但随机森林模型的计算耗时比深度学习模型短, 能够在保证预测精度的情况下缩短时间成本, 进一步证明了随机森林模型的优越性。

对比图 5(c) 可见, 动脉瘤血管分叉处和狭窄位置下游所受压力增加, 这是由于血管分叉处血液流速发生变化, 部分动能会转换为静压力, 导致动脉瘤分叉处的压力增加, 并且狭窄位置下游近端会产生再循环区, 增大狭窄处的血管压力。比较 WSS 和压力两个血流动力学参数的结果可知, 同 WSS 相比, 在压力预测任务中, 机器学习模型的性能比预测 WSS 时更为精确, 误差主要集中在血管瘤位置和 LCX 靠近血管瘤处。并且在进行压力预测时, 深度学习模型和随机森林模型均表现出了较高的预测性能, 表明机器学习模型在预测压力方面的表现更为优越。这种差异可能反映了机器学习模型在处

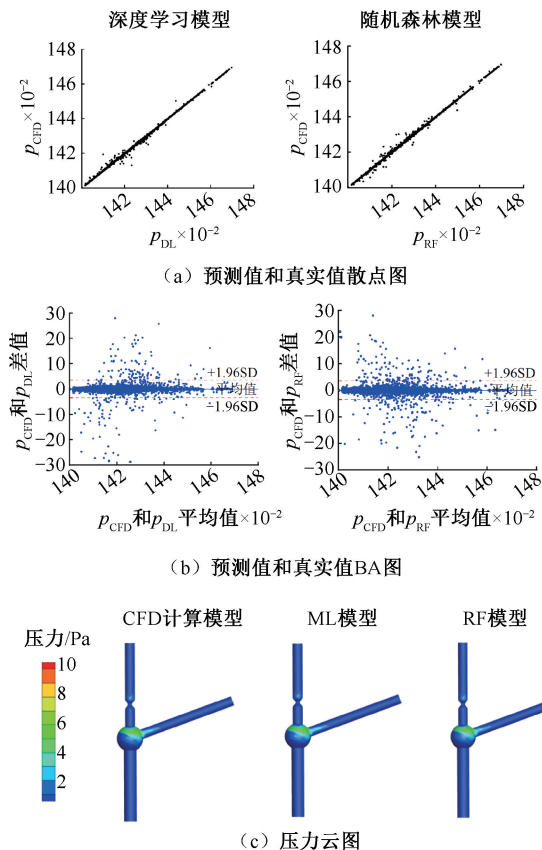


图 5 压力预测值和模拟值对比

Fig. 5 Comparison between predicted and simulated pressure values (a) Scatter plot of predicted and true values, (b) BA plots of predicted and true values, (c) Pressure contours

注: p_{DL} 、 p_{RF} 、 p_{CFD} 分别表示深度学习模型、随机森林模型计算以及计算流体力学仿真得出的压力。

理不同类型数据时的差异性, 以及模型对于不同特征的预测能力的差异。对此可以尝试提高数据质量以及采取适当方法处理数据分布不平衡问题, 从而提高机器学习技术预测 WSS 的准确性。

3.3 预测结果准确性对比

对 LM、LAD、LCX 长度分别为 8.464、18.696、12.78 mm, 半径分别为 1.78、1.956、1.67 mm, LAD 与 LCX 夹角为 63.552° , LAD 与 LM 夹角为 127.94° , 狭窄率为 74.43%, 血管瘤半径为 5.5 mm 的三维模型进行可视化分析。通过计算坐标节点 CFD 模拟值和机器学习模型预测值的绝对误差, 得到绝对误差云图(见图 6)。结果显示, 压力预测结果更为准确, 且在预测 WSS 时误差主要集中在血管瘤部位。这可能是由于血管瘤处的血流模式变化

较大,导致血流动力学参数更加复杂,导致机器学习模型在该区域的预测能力下降。为了提高机器学习方法在实际应用中的准确性,需要更多不同类型和形状的血管瘤样本数据,并对模型进行进一步的调整和验证。

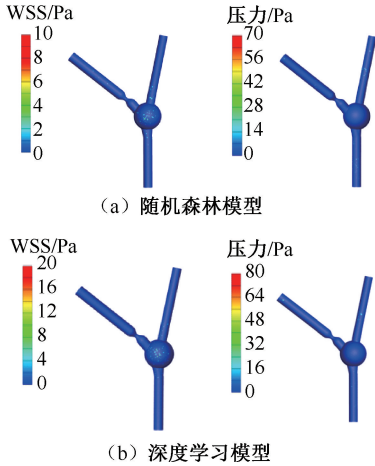


图 6 不同模型预测值和模拟值的绝对误差云图

Fig. 6 Absolute error cloud map of predicted and simulated values for different models (a) Random forest model, (b) Deep learning model

为了更加准确地将深度学习模型和机器学习模型预测结果进行对比分析,本文使用 3 个统计指标对两种机器学习模型进行对比分析,即均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE) 和决定系数 (R^2)。MSE 是一种常用的回归模型评估指标,它衡量了模型预测值与实际观测值之间的平均平方差异;MAE 是用来衡量预测模型在连续型数据上的预测准确度的指标; R^2 是回归模型性能评估的重要指标之一,用于衡量模型对目标变量方差的解释程度。 R^2 的取值范围在 0~1 之间, R^2 越接近 1,表示模型越能解释目标变量的方差;而 R^2 越接近 0,表示模型性能较差。统计指标 MSE、MAE 和 R^2 的表达式如下:

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (3)$$

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{\sum_{i=1}^m (\bar{y}_i - y_i)^2} \quad (5)$$

式中: \hat{y}_i 为预测值; y_i 为真实值; \bar{y}_i 为真实值的平均值。

由表 2 可知,深度学习模型在预测 WSS 和压力时准确性较高,随机森林模型适用于大规模数据集和需要高准确性的预测任务且在计算时间上具有优势。在预测 WSS 时,为了获得更高的准确性,应选用深度学习模型;而在需要考虑计算效率的情况下,预测压力时则更倾向于采用随机森林模型。

表 2 统计指标对比

Tab. 2 Comparison of statistical indicators

指标	WSS		压力	
	深度学习	随机森林	深度学习	随机森林
MSE	0.052 8	0.078 2	4.67×10^{-6}	1.07×10^{-5}
MAE	0.032 2	0.046 3	0.000 3	0.000 5
R^2	0.988 3	0.976 6	0.999 7	0.999 3

4 讨论与结论

本文全面地介绍了机器学习技术在流体力学参数预测中的应用,基于传统数值模拟方法存在计算成本高、时间消耗大等局限性,提出了针对 WSS 和压力预测的两种机器学习模型,并详细讨论了每种模型的原理、优缺点以及在流体力学参数预测中的应用场景,通过散点图、BA 图、绝对误差云图,对比分析了不同模型在测试集上的预测结果。通过对不同机器学习模型的比较分析,深入探讨了这些模型在预测流体力学参数方面的性能,验证了机器学习方法预测反演血流动力学参数的有效性。结果表明,深度学习模型在预测 WSS 方面表现更佳,预测结果与实际仿真结果高度一致,散点图呈现出更接近于一条直线的分布。相比之下,随机森林模型的预测性能略差。对于压力预测,深度学习模型和随机性森林模型在预测值与真实值之间的相关性较好,大部分数据点分布在 $y=x$ 附近,预测精度相当,但深度学习模型的计算耗时大于随机森林模型。在预测压力时,两种模型都表现出了较好的预测性能,然而在预测壁面剪切应力时两模型的预测准确度稍有下降,并且误差主要出现在血管瘤血流动力学变化较为复杂的区域。综上所述,通过不断改进和优化机器学习模型,可以提高对流体力学参数的准确预测能力,为相关领域的研究和应用提供更有效的支持和指导。在实际应用中,可以根据具

体需求和资源限制,灵活选择合适的机器学习模型,以确保结果的准确性和效率。并将机器学习技术应用到临床诊断和治疗中,实现心血管病人的个性化治疗方案的制定和优化。例如,通过准确预测血流动力学参数,医生可以更精确地评估病人的病情,制定更合理的治疗方案,从而提高治疗效果。用于心血管疾病的早期预警和风险评估。此外,通过监测和分析血流动力学参数的变化,还可以及时发现患者潜在的健康问题,采取必要的干预措施,防止疾病的进一步发展。

本研究仍具有一定的局限性:①采用了理想化的合并狭窄左冠状动脉瘤血管模型,通过参数化建模能够快速生成大量三维模型,虽然这些模型在几何形态学上与临床患者个性化冠脉有相似之处,其计算结果有参考价值,但仍然忽略了真实冠脉的特性。②在进行CFD仿真时使用了稳态进行模型的血流动力学参数计算,然而真实环境下血管内的冠脉血流是脉动的,并且CFD仿真将血管壁视作刚性壁,忽略了血管壁对血流的作用。③在仿真时虽然采用了尽可能准确的边界条件,但忽略了临床病人的个体性。因此,在后续的研究中应与临床数据相结合,通过更准确的流固耦合计算方法,设置不同的边界条件,构建更精确的数据集。

利益冲突声明:无。

作者贡献声明:桑建兵和孙丽芳负责设计研究;石政加负责计算并分析数据;所有作者讨论并共同撰写论文。

参考文献:

- [1] MEHTA MC, KATZ IT, JHA AK. Transforming global health with AI [J]. *New Engl J Med*, 2020, 382(9): 791-793.
- [2] 胡凌燕, 周文锦. 基于神经网络的生物组织松弛阶段力学建模[J]. *医用生物力学*, 2021, 36(2): 238-244.
HU LY, ZHOU WJ. Biomechanical modeling of tissues at relaxation stage based on neural network [J]. *J Med Biomech*, 2021, 36(2): 238-244.
- [3] 王冬梅, 郭文霞, 袁书芳, 等. 基于主成分分析和小波神经网络预测跑步中垂直地面反作用力[J]. *医用生物力学*, 2022, 37(4): 706-712.
WANG DM, GUO WX, YUAN SF, et al. Predicting vertical ground reaction force during treadmill running using principal component analysis and wavelet neural network [J]. *J Med Biomech*, 2022, 37(4): 706-712.
- [4] 徐大涛, 全文静, 周辉宇, 等. 基于深度神经网络和逐层相关性传播技术探究“高-低”里程跑者步态模式差异[J]. *医用生物力学*, 2022, 37(6): 1151-1157.
XU DT, QUAN WJ, ZHOU HY, et al. Exploration of gait pattern differences between high-mileage and low-mileage runners based on deep neural network and layer-wise relevance propagation [J]. *J Med Biomech*, 2022, 37(6): 1151-1157.
- [5] JORDAN MI, MITCHELL TM. Machine learning: Trends, perspectives, and prospects [J]. *Science*, 2015, 349(6245): 255-260.
- [6] ALI MM, PAUL BK, AHMED K, et al. Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison [J]. *Comput Biol Med*, 2021(136): 104672.
- [7] FARAJTABAR M, LARIMI MM, BIGLARIAN M, et al. Machine learning identification framework of hemodynamics of blood flow in patient-specific coronary arteries with abnormality [J]. *J Cardiovasc Transl*, 2023, 16(3): 722-737.
- [8] Li G, WANG H, ZHANG M, et al. Prediction of 3D Cardiovascular hemodynamics before and after coronary artery bypass surgery via deep learning [J]. *Commun Biol*, 2021, 4(1): 99-105.
- [9] 杨翀, 李旭东, 吕良福, 等. 基于机器学习预测动脉瘤性蛛网膜下腔出血预后模型的临床研究与应用[J]. *中国医院药学杂志*, 2024, 44(3): 257-262.
- [10] 苑玮琦, 王安. 基于并联多尺度卷积神经网络的微动脉瘤检测方法[J]. *仪器仪表学报*, 2023, 44(11): 224-233.
- [11] JAHROMI R, PAKRAVAN HA, SAIDI MS, et al. Primary stenosis progression versus secondary stenosis formation in the left coronary bifurcation: A mechanical point of view [J]. *Biocybern Biomed Eng*, 2019, 39(1): 188-198.
- [12] ABBASIAN M. Effects of different non-Newtonian models on unsteady blood flow hemodynamics in patient-specific arterial models with *in-vivo* validation [J]. *Comput Meth Prog Bio*, 2020(186): 105185.
- [13] CRAIEM D, CASCIARO ME, GRAF S, et al. Coronary arteries simplified with 3D cylinders to assess true bifurcation angles in atherosclerotic patients [J]. *Cardiovasc Eng Techn*, 2009, 9(4): 127-133.
- [14] QI CR, SU H, MO K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation [C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*. Honolulu: IEEE, 2017: 652-660.