

一种基于残差多尺度注意力生成对抗网络的 颅内动脉瘤血流动力学预测方法

李中凯¹ 李晓琴¹ 高斌¹ 卢旺盛² 杨光明² 印胤²

摘要 目的 颅内动脉瘤是一种严重威胁患者生命安全的疾病,其速度、压力和涡量的血流动力学预测对于诊断和治疗具有重要的临床意义。计算流体力学(computational fluid dynamics, CFD)能够有效地模拟血流动力学特征,但其计算成本较高。为此本文建立一种新型的深度学习架构,用于快速预测颅内动脉瘤的血流动力学。**方法** 基于210例颅内动脉瘤患者的形状数据进行计算流体力学模拟,并根据计算结果构建压力、速度和涡量数据库。设计了一种结合了残差-挤压激励-模块(Res-SE-Block)和多尺度注意块(multi-scale attention block, MAB)的残差多尺度注意力生成对抗网络(residual multi-scale attention generative adversarial network, RMAGAN),基于动脉瘤的形状信息来进行压力、速度和涡量的血流动力学预测。生成器采用了残差多尺度U-Net架构,用以提高网络的性能和预测能力,判别器采用了马尔可夫判别器,来提高网络的运行速度,损失函数结合了CGAN的损失函数与Smooth损失函数。最后使用均方根误差(root mean square error, RMSE)、归一化平均绝对误差(normalized mean absolute error, NMAE)和皮尔逊相关系数(r)指标对本文的深度学习模型进行评估,同时与多层感知机和卷积神经网络进行了比较。**结果** 深度学习模型的预测结果与计算流体力学模拟的速度、压力和涡量非常吻合,两种方法的相似度和准确性达到 $RMSE < 0.2804$, $NMAE < 12.5096\%$, $r > 0.8153$,同时减少了1500倍的计算成本。**结论** 本文的深度学习模型能够进行血流动力学的快速预测,并且大幅降低计算成本,为血流动力学模拟提供了一种全新的解决思路,在颅内动脉瘤的临床诊断和治疗研究中具有潜力。

关键词 颅内动脉瘤;计算流体力学;血流动力学;深度学习;生成对抗网络

DOI: 10.3969/j.issn.1002-3208.2026.04.005.

中图分类号 R318.01 **文献标志码** A **文章编号** 1002-3208(2026)04-0363-08

本文著录格式 李中凯,李晓琴,高斌,等.一种基于残差多尺度注意力生成对抗网络的颅内动脉瘤血流动力学预测方法[J].北京生物医学工程,2026,45(4):363-370. LI Zhongkai, LI Xiaoqin, GAO Bin, et al. A hemodynamic prediction method for intracranial aneurysms based on residual multi-scale attention generative adversarial network[J]. Beijing Biomedical Engineering, 2026, 45(4): 363-370.

A hemodynamic prediction method for intracranial aneurysms based on residual multi-scale attention generative adversarial network

LI Zhongkai¹, LI Xiaoqin¹, GAO Bin¹, LU Wangsheng², YANG Guangming², YIN Yin²

¹ College of Chemistry and Life Science, Beijing University of Technology, Beijing 100124;

² Union Strong (Beijing) Technology Co. Ltd., Beijing 100176

Corresponding author: GAO Bin (E-mail: gaobin@bjut.edu.cn)

[Abstract] Objective Intracranial aneurysm is a disease that seriously threatens the life and safety of

patients, and the hemodynamic prediction of velocity, pressure, and vorticity holds clinical significance for their diagnosis and treatment. Computational fluid dynamics (CFD) effectively models hemodynamic characteristics, it incurs high computational costs. The study proposes a novel deep learning architecture for the rapid prediction of intracranial aneurysm hemodynamics. **Methods** The CFD simulations were conducted based on the shape data of 210 intracranial aneurysm cases, and a database of pressure, velocity, and vorticity was established according to the simulation results. A residual multi-scale attention generative adversarial network (RMAGAN) combining residual squeeze-and-excitation blocks (Res-SE-Block) and multi-scale attention block (MAB) was designed to perform hemodynamic prediction of pressure, velocity and vorticity based on the shape information of aneurysms. The generator employed a residual multi-scale U-Net architecture to enhance network performance and predictive capability, while the discriminator utilized a Markov discriminator to improve computational efficiency. The loss function integrates the CGAN loss function with a Smooth loss function to optimize training stability and prediction accuracy. The performance of our deep learning model was evaluated by using root mean square error (RMSE), normalized mean absolute error (NMAE), and Pearson correlation coefficient (r), and was compared with that of multi-layer perceptron (MLP) and convolutional neural network (CNN). **Results** The predicted results of the deep learning model closely matched the velocity, pressure, and vorticity from the CFD simulations. The similarity and accuracy between the two methods achieved $RMSE < 0.2804$, $NMAE < 12.5096\%$, and $r > 0.8153$, while reducing the computational cost by a factor of 1500. **Conclusions** Our deep learning model enables rapid prediction of hemodynamics and significantly reduces computational costs, providing a novel solution for hemodynamic simulations. It holds potential for clinical diagnosis and treatment of intracranial aneurysms.

【Keywords】 intracranial aneurysm; computational fluid dynamics; hemodynamics; deep learning; generative adversarial network

0 引言

颅内动脉瘤 (intracranial aneurysm, IA) 是指发生在大脑动脉血管的局部扩张或突出, 一旦破裂, 就会对人体造成严重的伤害^[1]。在诊断和治疗的过程中, 速度、压力和涡量等血流动力学指标对于评估颅内动脉瘤是有意义的^[2]。计算流体力学是一种应用广泛且能够准确预测血流动力学的方法^[3], 但由于其庞大的计算时间和大量的内存需求影响了其临床适用性^[4]。

随着人工智能 (artificial intelligence, AI) 的发展, 深度学习在医疗领域得到了广泛应用^[5], 并且在血流动力学中表现出了比传统的计算流体力学方法更加出色的预测性能, 显著降低了计算成本^[6]。Itu 等^[7]采用全连接网络预测冠状动脉计算机断层

扫描的分流储备计算。Charlegchi 等^[8]利用卷积神经网络预测冠状动脉分叉处的瞬态壁面剪应力。Su 等^[9]将多层感知器网络和卷积神经网络相结合用于预测冠状动脉壁剪应力。Lv 等^[10]利用点云网络预测升主动脉的时间平均壁剪应力参数。Wang 等^[11]将点云网络应用于颈动脉狭窄血流动力学预测。Morales Ferez 等^[12]利用全连接网络、卷积神经网络预测左心耳血栓风险指数。Liang 等^[13]利用深度神经网络预测人胸主动脉血流动力学。然而, 这些方法仍然存在一定局限性。全连接网络难以捕捉空间特征, 卷积神经网络需要对输入数据进行裁剪处理, 而点云网络计算成本较高, 并且大多数方法需要对计算流体力学计算结果进行预处理, 无法充分利用计算结果的信息。

近年来, 生成对抗网络 (generative adversarial network, GAN)^[14] 广泛应用到了医学影像领域^[15], 其中 Pix2pixGAN^[16], 在医学图像生成和翻译^[17]方面取得了显著的成功, 帮助医疗人员进行疾病诊断和评估。然而, 目前很少有使用生成对抗网络预测血

基金项目: 国家重点研发计划 (2022YFC2704804) 资助

作者单位: 1 北京工业大学化学与生命科学学院 (北京 100124)

2 强联智创 (北京) 科技有限公司 (北京 100176)

通信作者: 高斌。E-mail: gaobin@bjut.edu.cn

流动力学参数的实例。本文将生成对抗网络与计算流体力学结合,设计了一种新颖、快速、高精度的生成对抗网络架构,基于动脉瘤形状信息进行压力、速度和涡量的血流动力学预测,而且能够直接利用计算流体力学的结果,不受限于二维动脉瘤模型大小。

1 研究方法

本研究符合医学伦理要求,伦理审查获得了首都医科大学宣武医院伦理委员会的批准。所有医学研究数据均已获得签署的知情同意书。

1.1 数据库制作

首都医科大学宣武医院,基于原始影像数据重建210个颅内动脉瘤三维模型。为验证所提方法的可行性,采用二维数据进行实验。首先,将三维模型沿动脉瘤最大直径所在平面切片,获取动脉瘤二维截面。载瘤动脉被简化为长20 mm、直径2 mm的直管,并沿直径所在平面切片,与脉瘤二维截面拼接后形成二维动脉瘤模型。

利用Ansys 2020 R2软件对得到的210例二维动脉瘤模型进行计算流体力学模拟,计算域采用0.005 mm的三角形网格,血液被视为密度为

$1\ 050\ \text{kg/m}^3$,粘度为 $0.003\ 5\ \text{Pa}\cdot\text{s}$ 的湍流牛顿流体^[18]。动脉壁被视为刚性边界,并施加无滑移条件。将载瘤动脉左侧设置为入口,右侧设置为出口。入口速度设为 $0.8\ \text{m/s}$,出口压力设置为 $0\ \text{Pa}$ 。最大迭代次数设置为1 000,保证数值收敛,残差小于 10^{-4} 。

使用Ansys-Ensign来提取速度、压力和涡量的计算结果。首先视图设置为-Z,图形窗口尺寸设置为 512×512 ,后续保持不变。取消所有参数渲染,输出图像得到动脉瘤的形状信息。使用入口速度对速度进行归一化处理,得到无量纲的归一化速度,将其应用到动脉瘤区域实现动脉瘤的归一化速度着色,设置调色板的范围为 $0\sim 0.2$ 和21个颜色等级,输出图像得到动脉瘤的速度信息。将压力应用到动脉瘤区域实现动脉瘤的压力着色,设置调色板的颜色范围为 $0\sim 150\ \text{Pa}$ 和21个颜色等级,输出图像得到动脉瘤压力的信息。将涡量应用到动脉瘤区域实现动脉瘤的涡量着色,设置调色板范围为 $0\sim 500\ \text{s}^{-1}$ 和21个颜色等级,输出图像得到动脉瘤的涡量信息。最终获得了210套二维动脉瘤数据,包含动脉瘤的形状信息,以及速度、压力和涡量信息,部分结果如图1所示。




图1 数据库部分实例

Figure 1 Partial instances of the database

1.2 深度学习模型

本文提出的残差多尺度注意力生成对抗网络(residual multi-scale attention generative adversarial network, RMAGAN)由一个生成器和判别器组成,如图2所示,网络设计参考了Pix2pixGAN,共享二维颅内动脉瘤的形状信息。

生成器将动脉瘤的形状信息作为输入,来生成动脉瘤速度、压力和涡量的血流动力学信息。生成器基于Pix2pixGAN的U-Net结构^[19]进行了改进,采用了引入Res-SE-Block和MAB的残差多尺度注意力U-Net(RMAU-Net)^[20]来提高整体的预测性能。生成器的网络架构由一个编码器和一个解码器组成,各由5层组成,每层使用一个Res-SE-Block模块。编码器中的每一层通过2×2的最大池化层连接,解码器的每一层通过上采样模块连接。上采样模块的结构由3×3的上卷积层、批归一化层和LeakyReLU激活层组成。编码器和解码器的每层之间通过跳跃连接融合高维和低维特征。通过一个MAB模块来连接解码器和编码器的底端,并在解码

器的最后连接一个MAB模块和一个3×3上采样层来输出最终的生成结果。生成器的输入尺寸为4×512×512,输出尺寸为4×512×512,其中前4个通道、中间4个通道和最后4个通道分别用于生成速度、压力和涡量。


判别器的任务是对传入的速度、压力和涡量进行真假判别。为了提高计算效率,RMAGAN的判别器采用了马尔可夫判别器(PatchGAN)。该判别器对尺寸更小的、具有更少参数的Patch进行真假判别,有助于加快判别器的处理速度。判别器由4个层组成,每个层的结构如图2所示。判别器的输入尺寸为16×512×512,对最终大小为1×128×128的Patch进行真假判别。

损失函数由两部分组成,第一部分采用CGAN的损失函数:

$$\mathcal{L}_{\text{cGAN}}(G, D) = E_{x,y} [\ln D(x, y)] + E_{x,z} [\ln (1 - D(x, G(x, z)))] \quad (1)$$

式中: G 最小化此损失;而 D 最大化此损失。

第二部分采用了SmoothL1损失函数^[21]。



生成器学习从动脉瘤形状到速度、压力和涡量的映射;判别器对输入数据进行真假判别

图2 RMAGAN深度学习网络

Figure 2 The RMAGAN deep learning network

SmoothL1 损失结合了 L1 损失和 L2 损失的优点,在训练的早期阶段能够快速收敛,在训练的后期阶段收敛更加稳定,因此 SmoothL1 损失更具鲁棒性,使得生成的结果尽可能接近真实结果。第二部分的损失函数如下:

$$\text{SmoothL1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (2)$$

将两部分损失相结合,并在 SmoothL1 之前施加一个可调节的超参数 λ 。总损失函数为:

$$G^* = \arg \min_G \max_D \mathcal{L}_{\text{cGAN}}(G, D) + \lambda \text{SmoothL1}(G) \quad (3)$$

1.3 实验设置

本研究首先设置五折交叉验证实验。首先将数据库中的 200 套均分为 5 组,每组 40 套数据。选取 4 组训练,在训练结束时保存生成器权重。在测试阶段使用剩下的一组,调用保存的权重生成血流动力学结果,并与计算流体力学结果对比,以最小误差选取最优权重,该过程重复 5 次。完成交叉验证后,使用数据库的剩下 10 套进行预测,采用 5 组最优权重独立预测,并对结果取平均融合,以提升模型的泛化能力,获得更稳定、平滑的预测结果。

实验在 Windows 10 服务器系统上进行,使用的软件为 Python 3.9.13 和 PyTorch 1.13.1+cu117,使用两个 NVIDIA GeForce RTX 3090 GPU 上进行并行计算,每个 GPU 的内存容量为 24 GB。训练过程的超参数如下:选用 Adam 优化器, Beta1 为 0.5, Beta2 为 0.999,学习率 (learning rate) 为 0.001,批次大小 (batch size) 为 32,轮次数 (epochs) 为 1 000, λ 为 15。

采用均方根误差 (root mean square error, RMSE) 和归一化平均绝对误差 (normalized mean absolute error, NMAE) 来评估深度学习模型的预测结果与计算流体力学模拟结果之间的准确性。利用皮尔逊相关系数 (r) 来评估深度学习模型的预测结果与计算流体力学模拟结果的一致性。3 个评价指标的计算公式如下。

$$\text{RMSE} = \sqrt{\frac{1}{N} \times \sum_{n=1}^N (y_n - x_n)^2} \quad (4)$$

$$\text{NMAE} = \frac{1}{N} \times \frac{\sum_{n=1}^N |y_n - x_n|}{\max |x_n| - \min |x_n|} \times 100\% \quad (5)$$

$$r = \frac{\sum_{n=1}^N (x_n - \bar{x})(y_n - \bar{y})}{\sqrt{\sum_{n=1}^N (x_n - \bar{x})^2} \sqrt{\sum_{n=1}^N (y_n - \bar{y})^2}} \quad (6)$$

式中: y_n 为深度学习模型预测的血流动力学图像中的动脉瘤区域的像素值; $\bar{y}$ 为 y 的均值; x_n 为计算流体力学模拟得到的血流动力学图像中的动脉瘤区域的像素值; $\bar{x}$ 为 x 的均值; N 为图像中动脉瘤区域的像素总数。

2 结果

对五折交叉验证的实验结果进行了统计和记录,实验结果为:速度的 RMSE 为 0.0756 ± 0.0038 , NMAE 为 $2.6527\% \pm 0.1752\%$,压力的 RMSE 为 0.0367 ± 0.0036 , NMAE 为 $1.7473\% \pm 0.1667\%$,涡量的 RMSE 为 0.0651 ± 0.0016 , NMAE 为 $2.4217\% \pm 0.0769\%$ 。五折交叉验证的结果表明深度学习模型在预测速度、压力和涡量方面表现出准确性、稳定性和泛化性。

表1 深度学习模型最终预测结果的评价指标

Table 1 Evaluation indicators of the final prediction results of deep learning models

变量	RMSE	NMAE	r
速度	0.0874 ± 0.0337	$2.9328\% \pm 1.2408\%$	0.9795 ± 0.0157
压力	0.0555 ± 0.0240	$2.2862\% \pm 0.9613\%$	0.9909 ± 0.0061
涡量	0.1853 ± 0.0951	$7.9354\% \pm 4.5742\%$	0.8942 ± 0.0789

表1展示了深度学习模型最终预测结果的评价指标,实验结果表明深度学习模型具有良好的精度 ($\text{RMSE} < 0.2804$, $\text{NMAE} < 12.5096\%$),并且预测结果与计算流体力学模拟结果之间存在较强的一致性 ($r > 0.8153$)。经过测试,深度学习方法的预测时间为 0.8667 s ,而计算流体力学消耗的时间为 1.306 s ,因此本文方法降低了1 500倍的计算成本。

图3展示了速度、压力和涡量的可视化预测结果。与计算流体力学结果相比,深度学习模型成功地预测了动脉瘤内部的流场,能够展示动脉瘤内部的流动轨迹。计算流体力学结果显示存在一个红色的高速度、高压力和高涡量区域(图中箭头所指),即血液流入动脉瘤的区域。深度学习模型也成功地预测了这个区域,同时还预测出了动脉瘤内的中心低压区域和动脉瘤内部血流漩涡的形状和大小。




图3 计算流体力学模拟与深度学习模型预测的速度、压力和涡量的结果对比

Figure 3 Comparison of velocity, pressure, vorticity results between CFD simulations and deep learning model predictions

3 讨论

在这项研究中,参照Pix2pixGAN的思想,提出了一种融合了Res-SE-Block和MAB模块的残差多尺度注意力生成对抗网络架构用于颅内动脉瘤的速度、压力和涡量的血流动力学预测。Res-SE-Block将挤压激励模块与残差模块相结合,有助于缓解梯度消失和梯度爆炸的问题并能够提高生成结果的质量。MAB模块引入了多尺度特征信息和注意力机制,能够更好地捕捉通道和空间之间的关系。

根据图3的实验结果,深度学习模型对于速度、压力和涡量的血流动力学的预测结果和计算流体力学的结果十分接近,颅内动脉瘤内的高速血流区与低速血流区对比明显。然而,高速血流的轨迹相对较短,说明深度学习模型虽然能够预测高速度、高压、高涡量区域,但是预测能力有一定的限制。五折交叉验证结果表明深度学习模型具有良好的稳定性和泛化性。根据表1的实验结果,最终预测结果也具有较高精度(RMSE<0.280 4, NMAE<12.509 6%, $r>0.815$ 3),其中速度最大误差小于

4.18%,压力最大误差小于3.25%,涡量最大误差小于12.51%。对比以往的研究,Lv等^[10]的最大误差小于12.6%,Wang等^[11]的最大误差小于12.5%,Liang等^[13]的最大误差小于10.4%,可见本文的深度学习模型和计算流体力学模拟结果是比较接近的。此外,Wang等^[11]和Liang等^[13]的实验结果表明,压力的误差小于速度的误差,这与本文的实验结果也是一致的。根据本实验结果,涡量的误差最大,压力的误差最小,原因可能是涡量的分布比压力的分布更为复杂。综合所有实验结果,本文的深度学习模型能够实现对速度、压力和涡量的血流动力学的快速预测,同时显著降低了计算成本,这表明深度学习模型对于血流动力学的预测具有一定的潜力。

Itu等^[7]、Su等^[9]和Morales等^[12]采用基于多层感知机的方法进行血流动力学预测,但是模型难以捕捉复杂的细节和全局信息。Gharleghi等^[8]、Su等^[9]和Morales等^[12]采用卷积神经网络进行血流动力学预测,但是需要对原始数据进行拉平和裁剪,容易导致图像失真。Lv等^[7]和Wang等^[11]利用点云网络进行血流动力学预测,但受限于数据规模和训练时间。Liang等^[13]采用深度神经网络进行血流动力学

预测,但要求使用固定数量的网格,限制了模拟的灵活性和准确性。现有的深度学习方法通常需要对计算流体力学结果进行标准化的预处理操作,这导致深度学习模型无法充分利用流体的信息。本文提出的基于生成对抗网络的血流动力学预测方法具有显著优势。该方法可直接利用计算流体力学模拟结果进行训练和预测,无需数据预处理,从而最大程度保留流体信息,避免数据修改和丢失,确保生成结果的真实性和可靠性。此外,提取的计算流体力学结果的尺寸大小固定,因此不受二维动脉瘤模型大小的影响,显著加快了训练过程。

尽管本文方法已取得良好效果,但仍面临诸多挑战。首先,由于颅内动脉瘤数据库规模有限,并采用了简化模型,其对更真实动脉瘤形状的预测性能尚不确定。然而,本研究的主要目标是验证方法的可行性,目前结果已展现出较高的准确性。未来,课题组计划通过扩充数据库,使用更丰富、更真实的动脉瘤形状,以进一步提升模型性能。此外,尝试了三维颅内动脉瘤血流动力学预测,但由于计算资源限制,训练时间和内存需求显著增加,现有硬件难以支持。后续工作将优化深度学习模型架构,并结合更强计算资源,以实现高效、精准的三维血流动力学预测。

4 结论

本文建立了一个高质量的二维颅内动脉瘤数据库,并设计了残差多尺度注意力生成对抗网络架构,实现了颅内动脉瘤速度、压力、涡量的血流动力学的快速预测。实验结果表明,该方法在保持较高预测准确性的同时,将计算成本降低了1 500倍,与计算流体力学模拟结果具有较强一致性。

参考文献

- [1] Xu Z, Rui YN, Hagan JP, et al. Intracranial aneurysms: pathology, genetics, and molecular mechanisms [J]. *Neuromolecular Medicine*, 2019, 21(4): 325–343.
- [2] Liang F, Oshima M, Huang H, et al. Numerical study of cerebroarterial hemodynamic changes following carotid artery operation: a comparison between multiscale modeling and stand-alone three-dimensional modeling [J]. *Journal of Biomechanical Engineering*, 2015, 137(10): 101011.
- [3] Fu W, Gu Z, Meng X, et al. Numerical simulation of hemodynamics in stented internal carotid aneurysm based on patient-specific model [J]. *Journal of Biomechanics*, 2010, 43(7): 1337–1342.
- [4] Liang L, Liu M, Martin C, et al. A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis [J]. *Journal of the Royal Society, Interface*, 2018, 15(138): 20170844.
- [5] Noorbakhsh-Sabet N, Zand R, Zhang Y, et al. Artificial intelligence transforms the future of health care [J]. *The American Journal of Medicine*, 2019, 132(7): 795–801.
- [6] Li G, Wang H, Zhang M, et al. Prediction of 3D cardiovascular hemodynamics before and after coronary artery bypass surgery via deep learning [J]. *Communications Biology*, 2021, 4(1): 99.
- [7] Itu L, Rapaka S, Passerini T, et al. A machine-learning approach for computation of fractional flow reserve from coronary computed tomography [J]. *Journal of Applied Physiology* (1985), 2016, 121(1): 42–52.
- [8] Gharleghi R, Sowmya A, Beier S. Transient wall shear stress estimation in coronary bifurcations using convolutional neural networks [J]. *Computer Methods and Programs in Biomedicine*, 2022, 225: 107013.
- [9] Su B, Zhang JM, Zou H, et al. Generating wall shear stress for coronary artery in real-time using neural networks: feasibility and initial results based on idealized models [J]. *Computers in Biology and Medicine*, 2020, 126: 104038.
- [10] Lv L, Li H, Wu Z, et al. An artificial intelligence-based platform for automatically estimating time-averaged wall shear stress in the ascending aorta [J]. *European Heart Journal-Digital Health*, 2022, 3(4): 525–534.
- [11] Wang S, Wu D, Li G, et al. Deep learning-based hemodynamic prediction of carotid artery stenosis before and after surgical treatments [J]. *Frontiers in Physiology*, 2023, 13: 1094743.
- [12] Morales Ferez X, Mill J, Juhl KA, et al. Deep learning framework for real-time estimation of in-silico thrombotic risk indices in the left atrial appendage [J]. *Frontiers in Physiology*, 2021, 12: 694945.
- [13] Liang L, Mao W, Sun W. A feasibility study of deep learning for predicting hemodynamics of human thoracic aorta [J]. *Journal of Biomechanics*, 2020, 99: 109544.
- [14] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C]// 28th International Conference on Neural Information Processing Systems. Montreal: NIPS, 2014, 2: 2672–2680.
- [15] P J, B K SK, Jayaraman S. Automatic foot ulcer segmentation

- using conditional generative adversarial network (AFSegGAN): a wound management system[J]. PLOS Digital Health, 2023, 2(11): e0000344.
- [16] Isola P, Zhu J, Zhou T, et al. Image-to-image translation with conditional adversarial networks[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: CVPR, 2017: 5967–5976.
- [17] van der Schot A, Sikkil E, Niekolaas M, et al. Placental vessel segmentation using pix2pix compared to U-Net[J]. Journal of Imaging, 2023, 9(10): 226.
- [18] Gharahi H, Zambrano BA, Zhu DC, et al. Computational fluid dynamic simulation of human carotid artery bifurcation based on anatomy and volumetric blood flow rate measured with magnetic resonance imaging[J]. International Journal of Advances in Engineering Sciences and Applied Mathematics, 2016, 8(1): 40–60.
- [19] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation [C]// MICCAI 2015. Munich, Germany: Cham: Springer International Publishing, 2015: 234–241.
- [20] Jiang L, Ou J, Liu R, et al. RMAU-Net: residual multi-scale attention U-Net for liver and tumor segmentation in CT images [J]. Computers in Biology and Medicine, 2023, 158: 106838.
- [21] Girshick BR. Fast R-CNN [C]// 2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: ICCV, 2015: 1440–1448.
- (2024–12–19 收稿, 2025–03–06 修回)

(上接第 347 页)

- [23] Cheng ST. Cognitive reserve and the prevention of dementia: the role of physical and cognitive activities [J]. Current Psychiatry Reports, 2016, 18(9): 85.
- [24] Nguyen L, Murphy K, Andrews G. Cognitive and neural plasticity in old age: a systematic review of evidence from executive functions cognitive training [J]. Ageing Research Reviews, 2019, 53: 100912.
- [25] Cui XY, Gui WJ, Miao JW, et al. A combined intervention of aerobic exercise and video game in older adults: the efficacy and neural basis on improving mnemonic discrimination [J]. Journals of Gerontology Series A-Biological Sciences and Medical Sciences, 2023, 78(8): 1436–1444.
- [26] Strenziok M, Parasuraman R, Clarke E, et al. Neurocognitive enhancement in older adults: comparison of three cognitive training tasks to test a hypothesis of training transfer in brain connectivity[J]. NeuroImage, 2014, 85(Pt 3): 1027–1039.
- (2025–04–24 收稿, 2025–08–11 修回)