

Fluidodinâmica Computacional (CFD) para Prever Alterações Patológicas na Aorta: Está Pronta para Uso Clínico?

Computational Fluid Dynamics (CFD) For Predicting Pathological Changes In The Aorta: Is It Ready For Clinical Use?

Dominik Obrist¹ e Hendrik von Tengg-Kobligk²

ARTORG Center for Biomedical Engineering Research, University of Bern,¹ Bern – Suíça

Institute for Diagnostic, Interventional and Pediatric Radiology (DIPR), University of Bern,² Bern – Suíça

Minieditorial referente ao artigo: Fluidodinâmica Computacional na Avaliação do Risco Futuro de Aneurismas de Aorta Ascendente

A modelagem computacional de problemas de fluxo complexos se beneficia de uma base já estabelecida de software de Fluidodinâmica Computacional (CFD, do inglês *Computational Fluid Dynamics*) desenvolvido nas últimas décadas. O uso inicial de CFD estava limitado à pesquisa acadêmica. Atualmente, é uma ferramenta totalmente estabelecida em muitas aplicações industriais (por exemplo, automotiva, aeroespacial), embora a CFD continue sendo uma das tarefas computacionais mais exigentes e o estudo de problemas de fluxo complexos seja frequentemente limitado pelo poder computacional disponível. O aumento exponencial contínuo na capacidade computacional e a melhora da acessibilidade à infraestrutura de computação de alto desempenho foi um facilitador para o uso cada vez maior de CFD. À luz desse sucesso, é surpreendente que a CFD dificilmente seja encontrada na prática clínica. Apesar do notável progresso na modelagem do fluxo sanguíneo complexo e na identificação de marcadores quantitativos para padrões de fluxo patológico,¹ a maior parte das aplicações biomédicas da CFD permanece ao nível de pesquisa acadêmica e casos de paciente único. O estudo de Almeida et al.,² é um dos poucos estudos sobre CFD que utiliza dados radiológicos longitudinais de coortes de pacientes. A proposta de previsão de alterações patológicas na aorta com base na CFD ilustra o potencial dessa tecnologia para se tornar uma modalidade diagnóstica estabelecida. Alguns dos desafios abordados com sucesso neste estudo são exemplos que ilustram os motivos pelos quais a CFD ainda não encontrou seu lugar na rotina clínica. Pode-se identificar quatro campos de problemas: a) A dificuldade de gerar modelos eficientes de CFD específicos para o paciente; b) A necessidade de redução da complexidade dos dados para tornar os resultados da CFD acessíveis ao médico; c) A infraestrutura inexistente de TI que integra de maneira eficiente as ferramentas de CFD aos fluxos de trabalho

de dados clínicos existentes; d) A falta de especialistas no ambiente clínico, ou seja, um engenheiro clínico que dê suporte aos médicos que cuidam dos pacientes. A seguir, discutiremos esses problemas e indicaremos possíveis medidas para mitigá-los.

Modelagem específica para o paciente

Modelos específicos para pacientes³ foram implementando com sucesso por muitos pesquisadores. No entanto, a tradução de dados radiológicos de alta resolução em modelos vasculares geométricos para CFD continua sendo uma tarefa demorada, muitas vezes trabalhosa e requer especialistas treinados. Há uma falta de ferramentas automatizadas de segmentação e mesclagem para tarefas biomédicas. Desenvolvimentos recentes baseados em redes neurais profundas podem fornecer soluções aceitáveis para uso clínico.⁴

A definição das condições de contorno (por exemplo, perfis de velocidade no *inflow/outflow*) requer muito cuidado, pois as condições de contorno têm um forte efeito na qualidade dos resultados. Portanto, é útil incluir medidas de fluxo em locais bem definidos (por exemplo, RM de fluxo sanguíneo 2D+time ou 3D+time) em protocolos radiológicos.⁵ Além da escolha adequada da modalidade e localização no corpo, isso requer resolução temporal e espacial adequada dos exames.

Além disso, precisamos de uma melhor compreensão da biomecânica do tecido doente para interpretar corretamente uma aorta remodelada ou dissecada ou a placa na parede de um vaso. Além da pesquisa biomecânica clássica contínua, isso requer estudos com grandes coortes, incluindo voluntários saudáveis, para entender a relevância clínica dos modelos biomecânicos.

Marcadores diagnósticos

A análise dos resultados de CFD é um desafio, mesmo para especialistas em dinâmica de fluidos. Isso se deve em parte à dificuldade em visualizar campos de fluxo tridimensionais dependentes do tempo que apresentam uma riqueza de fenômenos de fluxo que podem ser relevantes para a interpretação clínica dos resultados (por exemplo, vórtices, instabilidades de fluxo, turbulência, separação de fluxo, re-fixação, impacto).

Essa complexidade de dados pode ser reduzida através de modelagem orientada por dados⁶⁻⁸ e por algoritmos de detecção de anomalias (amplamente utilizados na análise de ECG),⁹ que utilizam redes neurais profundas para localizar e destacar valores discrepantes nos dados de fluxo

Palavras-chave

Doenças Cardiovasculares/fisiopatologia; Doenças Cardiovasculares/diagnóstico; Simulação por Computador; Processamento de Imagem Assistida por Computador; Desenho de Próteses; Implantação de Prótese; Engenharia Biomédica.

Correspondência: Dominik Obrist •

Universität Bern - Freiburgrstrasse 3, Bern, 3010 – Suíça
E-mail: dominik.obrist@unibe.ch

DOI: <https://doi.org/10.36660/abc.20220040>

específicos do paciente para orientar o clínico em relação a potenciais anomalias.

Almeida et al.,² abordou os problemas visualizando estruturas coerentes lagrangeanas¹⁰ no campo de fluxo e computando valores escalares únicos que caracterizam aspectos específicos do campo de fluxo (por exemplo, índice de helicidade). Outros propuseram métricas para caracterizar a interação biomecânica entre o fluxo sanguíneo e as paredes arteriais^{11,12} ou o efeito do fluxo de cisalhamento no trauma sanguíneo e na trombogenicidade.^{13,14} É de suma importância estabelecer o valor clínico de tais métricas e estabelecê-las como marcadores diagnósticos ou escores clínicos. Somente com tal abordagem possibilitaremos uma interpretação eficiente e padronizada dos dados de CFD na rotina clínica.

Infraestrutura de TI integrada

A integração total da CFD no fluxo de trabalho clínico requer interfaces de transferência de dados fáceis de usar entre bancos de dados de pacientes clínicos, sistemas de imagem e plataformas computacionais para realizar a CFD. Em casos complexos, com maior demanda por poder computacional, os dados de imagem podem necessitar ser transferidos para

infraestruturas computacionais centralizadas, que podem estar fora do perímetro de TI do hospital. Isso levanta questões sobre privacidade e segurança de dados, que devem ser abordadas estabelecendo tecnologia de criptografia apropriada e conexões dedicadas. Os serviços externos também devem considerar os aspectos regulatórios da transferência de dados de pacientes pela internet. Vale a pena procurar soluções utilizadas em aplicativos computacionais estabelecidos anteriormente (por exemplo, FFR_{CT}).¹⁵

Engenheiro Clínico

O sucesso no enfrentamento desses problemas requer o estabelecimento do papel de um engenheiro clínico que faz parte da equipe de radiologia clínica e está totalmente integrado ao fluxo de trabalho. Só assim, a CFD tem potencial para encontrar seu lugar como um recurso diagnóstico sustentável na rotina clínica.

Com essas medidas propostas, a CFD acabará se tornando apenas mais uma modalidade dentro de um ecossistema radiológico multimodal integrado, fornecendo dados adicionais para o especialista clínico obter melhor diagnóstico e previsão, incluindo a estratificação de risco adaptada individualmente.

Referências

- Morris P D, Narracott A H, von Tengg-Kobligh D A, Silva Soto S, Hsiao A, Lungu Pet al. Computational fluid dynamics modelling in cardiovascular medicine. *Heart*.2016;102(1):18-28. doi: 10.1136/heartjnl-2015-308044.
- Almeida G. Computational Fluid Dynamics to Assess the Future Risk of Ascending Aortic Aneurysms. *Arq Bras Cardiol*. 2022; 118(2):448-460.
- Gray RA, Pathmanathan P. Patient-Specific Cardiovascular Computational Modeling: Diversity of Personalization and Challenges. *J Cardiovasc Transl Res*. 2018;11:80-8. doi: 10.1007/s12265-018-9792-2. Epub 2018 Mar 6.
- Chaitanya K, Karani N Baumgartner CF, Becker A, Donati O, Konukoglu E. Semi-supervised and task-driven data augmentation. *Med Imag Anal*.2021; 68:101934. doi: 10.1016/j.media.2020.101934.
- Bonfanti M, Franzetti G, Maritati G, Homer-Vanniasinkam S, Balabani S, Díaz-Zuccarini V. Patient-specific haemodynamic simulations of complex aortic dissections informed by commonly available clinical datasets. *Med Eng Phys*. 2019;71:45-55 DOI: 10.1016/j.medengphy.2019.06.012
- Arzani A, Dawson STM. Data-driven cardiovascular flow modelling: examples and opportunities. *JR Soc Interface*.2021;18:20200802. doi: 10.1098/rsif.2020.0802. Epub 2021 Feb 10.
- Habibi M, D'Souza, S, Dawson M, Arzani A. Integrating multi-fidelity blood flow data with reduced-order data assimilation. *Comput Biol Med*.2021;135:104566 doi: 10.1016/j.combiomed.2021.104566
- Liang L, Mao W, Sun W. A feasibility study of deep learning for predicting hemodynamics of human thoracic aorta. *J Biomech*.2020;99:109544.
- Li H, Boulanger P. A survey of heart anomaly detection using ambulatory Electrocardiogram (ECG). *Sensors(Basel)*.2020;20(5):1461. doi: 10.1016/j.combiomed.2021.104566
- Darwish A, Norouzi S, Di Labbio G, Kadem L. Extracting Lagrangian coherent structures in cardiovascular flows using Lagrangian descriptors. *Phys Fluids* .2021;33:111707.
- Arzani, A, Shadden SC. Wall shear stress fixed points in cardiovascular fluid mechanics. *J Biomech*.2018;73:145-52. doi: 10.1016/j.jbiomech.2018.03.034.
- Morbiducci U, Mazzi V, Domanin M, De Nisco G, Vergara C, Steinman DA, et al., Wall shear stress topological skeleton independently predicts long-term restenosis after carotid bifurcation endarterectomy. *Ann Biomed Eng*.2020;48(12):2936-49. doi: 10.1007/s10439-020-02607-9.
- Taylor J O, Meyer RS, Deutsch S, Manning KB. Development of a computational model for macroscopic predictions of device-induced thrombosis. *Biomech Model Mechanobiol*.2016;15(6):1713-31. doi: 10.1007/s10237-016-0793-2. Epub 2016 May 12.
- Yazdani A, Zhang P, Sheriff J, Slepian MJ, Deng Y, Bluestein D. Multiscale modeling of blood flow-mediated platelet thrombosis. *Handb Mater Model Appl Curr Emerg Mater*.2020;2667-98.
- Min J K, Taylor CA, Stephan A, Kwon KB, Jonathon L, Bernard DB. Noninvasive Fractional Flow Reserve Derived From Coronary CT Angiography. *JACC Cardiovasc Imaging*.2015;8(10):1209-22. doi: 10.1016/j.jcmg.2015.08.006.



Este é um artigo de acesso aberto distribuído sob os termos da licença de atribuição pelo Creative Commons