



**UNIVERSIDADE FEDERAL DO OESTE DO PARÁ – UFOPA
INSTITUTO DE ENGENHARIA E GEOCIÊNCIAS – IEG
BACHARELADO INTERDISCIPLINAR EM CIÊNCIA E TECNOLOGIA**

CARLOS HENRIQUE PINTO DA SILVEIRA

**ESTUDOS E APLICAÇÕES DAS TÉCNICAS DE MACHINE LEARNING NA
RESOLUÇÃO DE PROBLEMAS DA MECÂNICA DOS FLUIDOS**

SANTARÉM

2024

CARLOS HENRIQUE PINTO DA SILVEIRA

**ESTUDOS E APLICAÇÕES DAS TÉCNICAS DE MACHINE LEARNING NA
RESOLUÇÃO DE PROBLEMAS DA MECÂNICA DOS FLUIDOS**

Trabalho de Conclusão de Curso apresentado ao Bacharelado Interdisciplinar em Ciência e Tecnologia para obtenção do grau de Bacharel em Ciência e Tecnologia na Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências.

Orientador: Josecley Fialho Góes

SANTARÉM

2024

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema Integrado de Bibliotecas – SIBI/UFOPA

S587e Silveira, Carlos Henrique Pinto da
Estudos e aplicações das técnicas de machine learning na resolução de problemas da mecânica dos fluidos / Carlos Henrique Pinto da Silveira. – Santarém, 2024.
11 p.
Inclui bibliografias.

Orientação: Josecley Fialho Góes.

Trabalho de Conclusão de Curso – Relatório Técnico (Graduação) – Universidade Federal do Oeste do Pará, Instituto de Engenharia e Geociências, Bacharelado Interdisciplinar em Ciência e Tecnologia.

1. Mecânica do fluidos. 2. Machine learning. 3. Python (Linguagem de programação). I. Góes, Josecley Fialho, *orient.* II. Título.

CDD: 23 ed. 620.106

Bibliotecário-Documentalista: Mayco Chaves – CRB 2/1357

RESUMO

Nos problemas de engenharia, os estudos sobre fluidos fazem parte de diversas áreas como: o escoamento em tubulações, movimento de rios, entre outras aplicações. As equações que regem o comportamento de fluidos no sistema são conhecidas como as equações de Navier-Stokes, resolvendo-as é possível obter campo de velocidade e pressão no escoamento. Essas equações diferenciais parciais possuem limitadas soluções analíticas, devido sua complexidade, fazendo-se necessário o uso de análise numérica, conhecida como Dinâmica dos Fluidos Computacional (CFD do inglês, Computational Fluid Dynamics). A abordagem em CFD em comparação à abordagem experimental é consideravelmente barata, mas ainda possui custo computacional considerável. Com o avanço da inteligência computacional, foi possível utilizar modelos de Aprendizado de Máquina (ML do inglês, Machine learning) em conjunto com métodos CFD para reduzir o custo computacional. Neste sentido, o estudo e aplicação de técnicas que conectem o CFD e ML é desejável para diminuir o custo computacional e, por consequência, proporcionar estudos mais viáveis na área de simulação de fluidos computacionais. Nesse sentido, o presente projeto utilizou um modelo de aprendizado de máquina, por meio da linguagem Python, para resolver o problema Lid Driven Cavity, obtendo êxito na resolução do problema escolhido.

Palavras-chave: Mecânica dos fluidos; Python; Machine learning; Modulus sym.



Universidade Federal do Oeste do Pará
Pró-reitoria de Pesquisa, Pós-graduação e Inovação Tecnológica
Diretoria de Pesquisa

RELATÓRIO TÉCNICO-CIENTÍFICO

Programa Institucional de bolsas de Iniciação Científica – PIBIC
Programa Institucional de bolsas de Inovação Tecnológica – PIBITI
Programa Institucional de voluntários em Iniciação Científica - PIVIC

1. IDENTIFICAÇÃO

Discente: Carlos Henrique Pinto da Silveira

E-mail: carlos.silveira@discente.ufopa.edu.br

Orientador(a): Josecley Fialho Góes

Vínculo: (X) Bolsista () Voluntário

Vigência executada do vínculo como bolsista ou voluntário: De 06/12/2022 A 30/11/2023

Grande área do conhecimento (CNPq): Ciências Exatas e da Terra

Sub-área do conhecimento (CNPq): Matemática Aplicada

Título do Plano de Trabalho: Estudos e aplicações das técnicas de Machine Learning na resolução de problemas da Mecânica dos Fluidos

Título do Projeto ao qual está vinculado o plano de trabalho: Estudos e aplicações das técnicas de programação paralela e Machine Learning na resolução de problemas da Dinâmica dos Fluidos Computacional

2. RESUMO

Nos problemas de engenharia, os estudos sobre fluidos fazem parte de diversas áreas como: o escoamento em tubulações, movimento de rios, entre outras aplicações. As equações que regem o comportamento de fluidos no sistema são conhecidas como as equações de Navier-Stokes, resolvendo-as é possível obter campo de velocidade e pressão no escoamento. Essas equações diferenciais parciais possuem limitadas soluções analíticas, devido sua complexidade, fazendo-se necessário o uso de análise numérica, conhecida como Dinâmica dos Fluidos Computacional (CFD do inglês, Computational Fluid Dynamics). A abordagem em CFD em comparação à abordagem experimental é consideravelmente barata, mas ainda possui custo computacional considerável. Com o avanço da inteligência computacional, foi possível utilizar modelos de Aprendizado de Máquina (ML do inglês, Machine learning) em conjunto com métodos CFD para reduzir o custo computacional. Neste sentido, o estudo e aplicação de técnicas que conectem o CFD e ML é desejável para diminuir o custo computacional e, por consequência, proporcionar estudos mais viáveis na área de simulação de fluidos computacionais. Nesse sentido, o presente projeto utilizou um modelo de aprendizado de máquina, por meio da linguagem Python, para resolver o problema Lid Driven Cavity, obtendo êxito na resolução do problema escolhido.

Palavras-Chaves: Mecânica dos fluidos; Python; Machine learning; Modulus sym.

3. INTRODUÇÃO

Segundo Çengel e Cimbala (2015, p. 2): “Mecânica dos fluidos é definida como a ciência que trata do comportamento dos fluidos em repouso (estática dos fluidos) ou em movimento (dinâmica dos fluidos) e da interação entre fluidos e sólidos ou outros fluidos nas fronteiras”. Essa área do conhecimento, tem aplicações em diversos campos da ciência e da engenharia, como a meteorologia, a hidráulica, a aerodinâmica, a difusão de poluentes, geração de energia, dissipação de calor e a medicina.

O fluido é uma substância no estado líquido ou gasoso, a qual quando submetida a uma tensão de cisalhamento, tende a se deformar continuamente, ainda que essa força de cisalhamento seja pequena (ÇENGEL e CIMBALA, 2015).

A história da mecânica dos fluidos remonta à antiguidade, quando os primeiros princípios sobre o comportamento dos fluidos foram estabelecidos por Arquimedes, no Século III A.C, como a formulação e aplicação do princípio do empuxo. Desde então, diversos cientistas contribuíram para o avanço dessa área do conhecimento, desde os fundamentos clássicos até as abordagens modernas (ÇENGEL e CIMBALA, 2015).

Um dos marcos teóricos mais importantes da mecânica dos fluidos é o conjunto de equações de Navier-Stokes, que descrevem o movimento de um fluido viscoso e incompressível, levando em conta as forças de pressão, gravidade e atrito. Essas equações foram formuladas no Século XIX por Claude-Louis Navier e George Gabriel Stokes a partir das leis de conservação de massa, momento e energia. As equações de Navier-Stokes são capazes de modelar uma grande variedade de fenômenos fluidodinâmicos, como o escoamento laminar, escoamento turbulento, a formação de ondas, a convecção térmica, aerodinâmica de corpos e movimentos dos rios.

No entanto, as equações de Navier-Stokes são altamente não lineares e complexas, o que dificulta a obtenção de soluções analíticas para a maioria das aplicações práticas. Por isso, a partir do Século XX, surgiram os métodos numéricos para resolver as equações de Navier-Stokes de forma aproximada, usando computadores. Essa área de pesquisa é conhecida como Dinâmica dos Fluidos Computacional (CFD do inglês, Computational Fluid Dynamics), a qual permite simular o comportamento dos fluidos com maior acurácia e eficiência, (RAMPONI e BLOCKEN, 2012). A CFD tem sido grandemente utilizada para projetar e otimizar sistemas que envolvem fluidos, como turbinas, foguetes, aviões, carros, navios, pontes, edifícios, dutos, válvulas, bombas, filtros, e escoamento de rios.

Uma das soluções para otimizar as simulações de fluidos é o uso de modelos de Aprendizado de Máquina (ML do inglês, Machine learning) para realizarem as simulações de escoamento de fluidos, entre os modelos destacam-se: Aprendizado de Máquinas Puro, com o objetivo de substituir toda as equações de Navier-Stokes por aproximações baseadas em Redes Neurais Profundas (DNN, do inglês, Deep Neural Network); ML Híbridos, o qual une os benefícios da CFD tradicional com os benefícios do Aprendizado de Máquina Puro (KOCHKOV et al., 2021); e ainda as Redes Neurais Informadas pela Física (PINNs do inglês, Physics-Informed Neural Networks), as quais utilizam as equações físicas governantes no treinamento de redes neurais (SHARMA et al., 2023).

4. OBJETIVOS

O objetivo inicial do projeto consistia em compreender e empregar as técnicas de aprendizagem de máquinas para resolver problemas da mecânica dos fluidos. Para isso foram realizados levantamentos bibliográficos para compreender a física dos fluidos e as técnicas de machine learning utilizadas para resolução de problemas na mecânica dos fluidos, para posteriormente aplicá-las na resolução de problemas da mecânica dos fluidos. Contudo, durante a execução do projeto, surgiram diversas dificuldades para aplicar as diferentes técnicas de machine learning na resolução dos problemas, sendo necessário escolher somente uma para concentrar os estudos.

A partir dessa mudança de foco, novos objetivos específicos foram visados, que foram:

- Escolher uma técnica de machine learning para concentrar os estudos;
- Escolher os problemas de mecânica dos fluidos;
- Comparar os resultados obtidos com a solução CFD para obter a acurácia e precisão.

5. METODOLOGIA

A Figura 01 contém o fluxograma das etapas realizadas durante a execução do presente projeto.

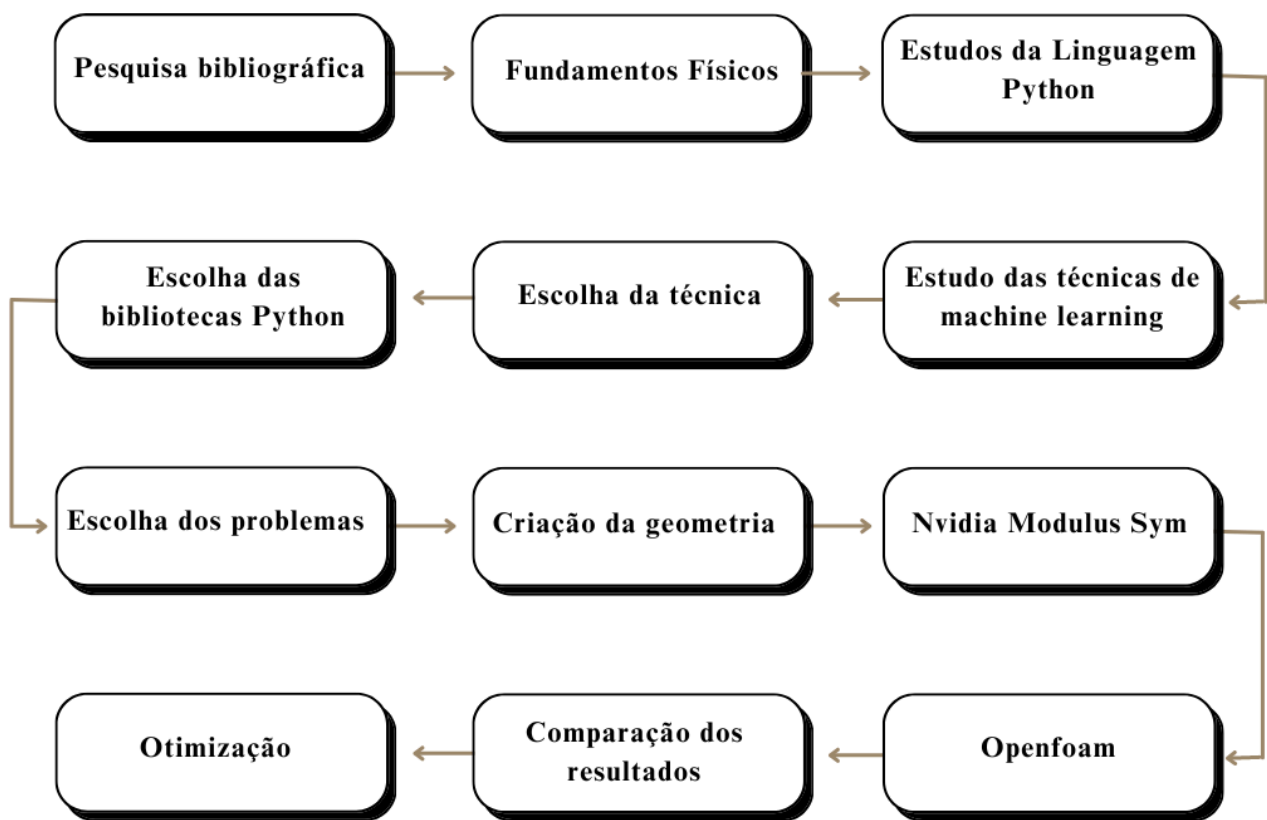


Figura 01: Fluxograma da execução do projeto.

O modelo de aprendizado de máquina escolhido foi o Modulus Sym. Ele é um modelo criado pela NVIDIA, o qual é baseado em PINNs, ou seja, utiliza as equações de Navier-Stokes para treinar as redes neurais para gerar os dados para as simulações dos fluidos. O Modulus Sym é um framework de aprendizado profundo (DL, do inglês, Deep Learning) produzido na linguagem de programação Python, que une a física, as equações diferenciais parciais (EDPs) e a inteligência artificial para criar modelos robustos para resolução de problemas da mecânica dos fluidos. Ele é capaz de gerar e importar geometrias, configurar os parâmetros físicos do problema, configurar os parâmetros de treinamento e processar os dados da simulação CFD. Além disso, é possível acompanhar o processo de treinamento durante a simulação, por meio de uma interface gráfica

presente no Modulus Sym, a qual apresenta as estatísticas de treinamento. Como resultado, o Modulus Sym apresenta os resultados das simulações, podendo ainda comparar os resultados obtidos com o resultado de outras simulações CFD nas mesmas condições físicas que foram geradas a partir de outro simulador CFD.

Abaixo estão apresentadas a equação da continuidade bidimensional e as equações de Navier-Stokes para um fluido incompressível, bidimensional e em regime permanente.

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} = 0$$

$$u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} = -\frac{1}{\rho} \frac{\partial p}{\partial x} + \nu \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right)$$

$$u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} = -\frac{1}{\rho} \frac{\partial p}{\partial y} + \nu \left(\frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} \right)$$

O computador utilizado foi um HP com processador Intel Core i7, com 16GB de memória RAM e placa de vídeo NVIDIA GeForce GT 730. Posteriormente, o bolsista utilizou um workstation Dell com o processador Intel Xeon com 32GB de memória RAM e placa de vídeo NVIDIA GeForce Titan Xp com 12GB de memória. As ferramentas utilizadas para implementação da rede neural foram Python na versão 3.9.12, a ferramenta de ciência de dados Anaconda 3 e a biblioteca da NVIDIA Modulus Sym na versão 0.2.0, com suas respectivas bibliotecas internas.

6. RESULTADOS OBTIDOS

O problema de mecânica dos fluidos escolhido foi o Lid Driven Cavity (LDC), o qual a configuração consiste em uma cavidade quadrada preenchida com um fluido, onde a tampa superior da cavidade é movida a uma velocidade constante, enquanto as outras três paredes permanecem fixas, conforme mostrado na Figura 02. Essa condição cria um campo de fluxo complexo dentro da cavidade, oferecendo padrões de fluxo, transições turbulentas e fenômenos relacionados à mecânica dos fluidos.




Figura 02: Representação do lid driven cavity.

Nesse problema, a cavidade quadrada possui arestas de 0.1m, as paredes laterais e inferior estão

fixas, a parede superior se move em uma velocidade de 1m/s na direção x, conforme a Figura 02. As condições da equação de Navier-Stokes foram: densidade igual a 1, viscosidade cinemática igual a 0.01, regime permanente e problema bidimensional.

Abaixo estão as equações de Navier-Stokes utilizadas neste problema.

$$u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} = -\frac{1}{\rho} \frac{\partial p}{\partial x} + \nu \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right)$$

$$u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} = -\frac{1}{\rho} \frac{\partial p}{\partial y} + \nu \left(\frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} \right)$$

O código em linguagem de programação Python para o problema foi executado, gerando a simulação utilizando o Modulus Sym e em seguida fez a validação da simulação do Modulus Sym com dados de uma simulação do mesmo problema, com as mesmas métricas e condições, que foi realizada de forma quantitativa, com outro código numérico, robusto e acurado, conhecido como Openfoam. O OpenFOAM (Open Field Operation and Manipulation) é uma biblioteca de código aberto para simulação numérica, especialmente voltada para dinâmica dos fluidos computacional (CFD). Ele oferece um conjunto abrangente de ferramentas para modelagem e simulação de problemas envolvendo o comportamento de fluidos, como aerodinâmica, transferência de calor e fenômenos multifásicos. As Figuras 03 e 04 contém a validação da simulação.

A Figura 03 contém a simulação através Modulus Sym, simulação CFD por meio do Openfoam e comparação de ambos em relação ao campo da velocidade, respectivamente.




Figura 03: Comparação dos resultados do campo de velocidade obtidos pelo openfoam e Modulus Sym.

A Figura 04 contém a simulação através Modulus Sym, simulação CFD por meio do Openfoam e comparação de ambos em relação a pressão, respectivamente.




Figura 04: Comparação dos resultados da pressão obtidos pelo openfoam e Modulus Sym.

Analisando a diferença da simulação do Modulus Sym e Openfoam nas Figuras 03 e 04, pode-se observar que o erro das simulações do Modulus Sym foram baixos, evidenciado pela coloração escura e escala decimal do gráfico de erro, ou seja, o Modulus Sym foi capaz de gerar uma simulação confiável para o problema proposto da mecânica dos fluidos.

No final do projeto, o mesmo caso, com os mesmo parâmetros, foi refeito utilizando o Modulus Sym na plataforma de programação Python online chamada Google Colab, por meio da TPU T4, disponibilizada de forma gratuita na plataforma, foram obtidos os mesmo resultados mostrados acima, porém com menor tempo de processamento. Portanto, a utilização de plataformas de processamento online como o Google Colab, que possuem grande poder computacional, principalmente se utilizados nas versões pagas, onde disponibilizam GPUs e TPUs de alto desempenho, mostrou-se muito promissor para pesquisas nesse segmento científico de simulações CFD. Porém, é necessário ressaltar a importância de computadores físicos com poder computacional considerável nos laboratórios, para criação das geometrias, visualização de grandes dados, arquivos em três dimensões e nas simulações iniciais dos estudos.

7. PUBLICAÇÕES TÉCNICO-CIENTÍFICAS.

“Estudos e aplicações das técnicas de machine learning na resolução de problemas da mecânica dos fluidos”, Carlos Henrique Pinto da Silveira, XI Jornada Acadêmica da UFOPA.

“Estudos e aplicações das técnicas de machine learning na resolução de problemas da mecânica dos fluidos”, Carlos Henrique Pinto da Silveira, I amazon Expo Science.

8. PRINCIPAIS PROBLEMAS E DIFICULDADES PARA A REALIZAÇÃO DAS ATIVIDADES

Os principais problemas e dificuldades encontrados durante a realização do projeto foram: Incompatibilidade do sistema operacional com algumas bibliotecas Python; Incompatibilidade da GPU GeForce GT 730 com algumas bibliotecas da NVIDIA; A reduzida quantidade de informações a respeito da geração das simulações CFD para alguns modelos de aprendizado de máquina voltados para a simulação de problemas da mecânica dos fluidos; A memória insuficiente da placa de vídeo NVIDIA GeForce Titan Xp para rodar casos mais complexos e com aplicações mais realistas da mecânica dos fluidos, como em casos em três dimensões.

9. REFERÊNCIAS

CENGEL, Yunus A.; CIMBALA, John M. Mecânica dos fluidos-3. Amgh Editora, 2015.

KOCHKOV, Dmitrii et al. Machine learning–accelerated computational fluid dynamics. Proceedings of the National Academy of Sciences, v. 118, n. 21, p. e2101784118, 2021.

RAMPONI, Rubina; BLOCKEN, Bert. CFD simulation of cross-ventilation for a generic isolated building: Impact of computational parameters. Building and environment, v. 53, p. 34-48, 2012.


SHARMA, Prakhar et al. Stiff-PDEs and Physics-Informed Neural Networks. Archives of Computational Methods in Engineering, p. 1-30, 2023.

10. PARECER DO ORIENTADOR

Gostaria de expressar meu parecer positivo em relação às atividades desenvolvidas pelo bolsista

no âmbito do plano de trabalho intitulado "Estudos e Aplicações das Técnicas de Machine Learning na Resolução de Problemas da Mecânica dos Fluidos". Durante o período de acompanhamento, observei o seu empenho, dedicação e progresso significativo nas tarefas propostas. Destaco seu comprometimento notável com as metas estabelecidas no plano de trabalho. Sua dedicação em entender os conceitos teóricos relacionados à Mecânica dos Fluidos e integrá-los eficientemente com técnicas de Machine Learning é evidente. Sua capacidade analítica para identificar desafios específicos na área de estudo e propor soluções fundamentadas demonstra um entendimento profundo dos conceitos envolvidos. Destaco também sua capacidade de colaborar efetivamente com colegas e pesquisadores. Sua participação em discussões e contribuições para a equipe evidenciam um trabalho em conjunto harmonioso. Como sugestão, recomendo continuar aprofundando seus conhecimentos teóricos na Mecânica dos Fluidos, consolidando a base conceitual que sustenta suas implementações práticas. Portanto, aprovo o relatório submetido, certo de que seu desempenho e dedicação resultarão em contribuições significativas para o avanço do conhecimento na interseção entre Machine Learning e Mecânica dos Fluidos.

Santarém, 14 de janeiro de 2024.

Documento assinado digitalmente
 JOSECLEY FIALHO GOES
Data: 07/05/2024 11:45:46-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do orientador

Carlos Henrique Pinto da Silveira

Assinatura do bolsista