

GIOVANNI SIMÕES COTRIM

**ESTUDO DE MODELO FENOMENOLÓGICO PARA INTERAÇÃO
FLUIDO-ESTRUTURA E SOLUÇÃO USANDO APRENDIZADO POR
REFORÇO**

**Trabalho de Conclusão de Curso
apresentado à Escola Politécnica da
Universidade de São Paulo para obtenção
do diploma de Engenharia de Petróleo.**

SÃO PAULO

2024

GIOVANNI SIMÕES COTRIM

**ESTUDO DE MODELO FENOMENOLÓGICO PARA INTERAÇÃO
FLUIDO-ESTRUTURA E SOLUÇÃO USANDO APRENDIZADO POR
REFORÇO**

**Trabalho de Conclusão de Curso
apresentado à Escola Politécnica da
Universidade de São Paulo para obtenção
do diploma de Engenharia de Petróleo.**

**Área de concentração: Mecânica de
fluidos; aprendizado de máquina;
engenharia *offshore*.**

**Orientador: Prof. Dr. Rafael dos Santos
Gioria**

SÃO PAULO

2024

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

FICHA CATALOGRÁFICA

Cotrim, Giovanni Simões

Estudo de modelo fenomenológico para interação fluido-estrutura e solução usando Aprendizado por Reforço / G. S. Cotrim -- São Paulo, 2024.
86 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e de Petróleo.

1.Mecânica de fluidos 2.Aprendizado de máquina 3.Engenharia offshore
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Minas e de Petróleo II.t.

AGRADECIMENTOS

Chegando ao final do curso de Engenharia, devo agradecer, antes de tudo, às pessoas que mais investiram em mim: minha mãe, Denise, e meu pai, Carlos Henrique. O amor, tempo, energia e dinheiro que dedicaram escapam a qualquer tentativa de descrição e permanecem apenas como uma vaga ideia - ainda que intensa - do quanto devo a ambos. Após 25 anos de investimento, dedico o desfecho aos dois.

Não poderia deixar de mencionar meu irmão, Guilherme, que me apresentou à Engenharia e à Escola Politécnica, tornando-as meus objetivos quando mais novo; minha irmã, Bianca, a pessoa que mais me ofereceu acolhimento e compreensão, sempre me lembrando de minha capacidade nos momentos de maior dificuldade; e meu cunhado, Tiago, que, muitas vezes, passou madrugadas em claro me apoiando com os trabalhos acadêmicos e sobretudo me apresentou a carreira que escolhi seguir.

Deixo um agradecimento geral, mas caloroso e sincero, às pessoas que passaram por minha vida durante a graduação, tornando-a algo que sempre rememorarei com muito carinho.

RESUMO

Este trabalho apresenta uma análise e ajuste do modelo fenomenológico de interação fluido-estrutura. O modelo busca representar a dinâmica de vibrações induzidas por vórtices (VIV) e prever seus comportamentos – que podem acarretar falhas estruturais críticas. Buscou-se realizar esse ajuste através da utilização de Aprendizado por Reforço (AR), focando no algoritmo Q-Learning para ajustar os parâmetros do sistema de equações diferenciais que visam modelar as VIV em cilindros imersos em escoamento de fluido. O objetivo final é validar tanto o modelo proposto quanto o ganho de utilizar-se AR em pesquisas no contexto da indústria petrolífera offshore especialmente porque a técnica de aprendizado Q-learning não necessita de conhecimento do modelo sobre o qual atua. A escolha de usar em um modelo conhecido para VIV tem intuito de demonstrar a capacidade da técnica. Os dados utilizados no treinamento do modelo de aprendizado de máquina foram gerados de forma sintética, com simulações tanto em condições de ruído quanto sem ruído, a fim de avaliar a robustez dele em condições mais próximas à realidade. A análise de desempenho evidenciou que é capaz de encontrar parâmetros que aplicados à modelagem de VIV rendem simulações muito próximas aos sinais de entrada. Além disso, verificou-se que apesar de em geral o aumento de episódios no treinamento melhorar a precisão dos resultados, isso não ocorre indefinidamente e os ganhos marginais são progressivamente menores. Os achados levam à conclusão de que o modelo de acoplamento fluido-estrutura pode ser uma boa maneira analítica de se analisar VIV e que o aprendizado por reforço tem extenso potencial de aplicação em pesquisas na área.

ABSTRACT

This paper presents an analysis and adjustment of the phenomenological fluid-structure interaction model. The model aims to represent the dynamics of vortex-induced vibrations (VIV) and predict their behaviors, which can lead to critical structural failures. This adjustment was achieved through the use of Reinforcement Learning (RL), focusing on the Q-Learning algorithm to tune the parameters of the differential equation system intended to model VIV in cylinders immersed in fluid flow. The ultimate goal is to validate both the proposed model and the benefits of using RL in offshore oil industry research, especially because the Q-learning technique does not require prior knowledge of the model it operates on. The choice to use a known model for VIV is intended to demonstrate the technique's capability. The data used in training the machine learning model were synthetically generated, with simulations conducted under both noisy and noise-free conditions, to assess its robustness in scenarios closer to reality. The performance analysis showed that it is capable of finding parameters that, when applied to VIV modeling, yield simulations very close to the input signals. Furthermore, it was observed that while, in general, increasing the training episodes improves result accuracy, this does not continue indefinitely, and the marginal gains become progressively smaller. The findings lead to the conclusion that the fluid-structure coupling model can be an effective analytical approach for analyzing VIV and that reinforcement learning has extensive application potential in research within this area.

LISTA DE FIGURAS

Figura 1: Evolução da produção <i>onshore</i> e <i>offshore</i> – Pré-sal x Pós-sal. Fonte: Brasil (2024).....	11
Figura 2: Esquema e visualização do escoamento ao redor de um corpo afilado e um corpo rombudo. Fonte: Ássi (2005, p. 9).....	17
Figura 3: Regiões de escoamento perturbado pela presença do corpo rombudo Fonte: Ássi (2005, p. 10).....	18
Figura 4: Escoamento ao redor de cilindro sem separação. Fonte: Van Dyke (1988, p.8).....	20
Figura 5: Escoamento ao redor de um cilindro, $Re = 26$. Fonte: Van Dyke (1988, p.28).....	20
Figura 6: Representações dos três estados de escoamentos completamente laminares. Fonte: Ássi (2005, p. 12).....	21
Figura 7: Transições em cada região perturbadora. Fonte: Zdravkovich (1988, p. 96).	21
Figura 8: Relação entre o número de Strouhal e o número de Reynolds. Fonte:Norberg (2001, p. 461).....	23
Figura 9: Comportamento dos coeficientes de pressão comparados com os regimes de escoamento e em relação. Fonte: Ássi (2005, p.16).....	25
Figura 10: Modelo de oscilação harmônico em cilindro elástico. Fonte: Ássi (2009, p. 26).....	26
Figura 11: Variação do campo de pressão na parede para aproximadamente um terço do ciclo de emissão de vórtices. Fonte: Ássi (2005, p. 50).....	27
Figura 12: Resposta típica de VIV (amplitude e frequência) de um cilindro. Fonte: Adaptada de Govardhan & Williamson (2000, p. 122).....	30

Figura 13: Resposta típica da amplitude de oscilação de um cilindro livre para oscilar transversalmente ao fluxo. Fonte: Ássi (2009, p. 85).....	31
Figura 14: Modelo de estrutura acoplada e osciladores de esteira para vibrações 2-D induzidas por vórtices. Fonte: Facchinetti, de Langre e Biolley (2004, p. 124).....	32
Figura 15: Interação entre agente e ambiente. Fonte: Garnier et al. (2021, p. 2).....	38
Figura 16: Mapa dos caminhos percorridos pelo agente durante seu aprendizado. .	42
Figura 17: Mapa dos caminhos percorridos pelo agente durante seu aprendizado – ampliado.....	43
Figura 18: Relações de chamadas e dependência entre os componentes do modelo de <i>Q-Learning</i>	44
Figura 19: Tempo de Processamento por Número de Episódios - Treinamento sem ruído.....	50
Figura 20: Tempo de Processamento por Número de Episódios - Treinamento com ruído.....	50
Figura 21: Oscilação simulada versus oscilação alvo - 500 episódios - sem ruído...	51
Figura 22: Evolução das recompensas durante o treinamento - 500 episódios - sem ruído.....	51
Figura 23: Oscilação simulada versus oscilação alvo - 1000 episódios - sem ruído.	52
Figura 24: Evolução das recompensas durante o treinamento - 1000 episódios - sem ruído.....	52
Figura 25: Oscilação simulada versus oscilação alvo - 2000 episódios - sem ruído.	53
Figura 26: Evolução das recompensas durante o treinamento - 2000 episódios - sem ruído.....	53
Figura 27: Oscilação simulada versus oscilação alvo - 3500 episódios - sem ruído.	54

Figura 28: Evolução das recompensas durante o treinamento - 3500 episódios - sem ruído.....	54
Figura 29: Oscilação simulada versus oscilação alvo - 5000 episódios - sem ruído. 55	
Figura 30: Evolução das recompensas durante o treinamento - 5000 episódios - sem ruído.....	55
Figura 31: Oscilação simulada versus oscilação alvo - 500 episódios - com ruído...56	
Figura 32: Evolução das recompensas durante o treinamento - 500 episódios - com ruído.....	56
Figura 33: Oscilação simulada versus oscilação alvo - 1000 episódios - com ruído. 57	
Figura 34: Evolução das recompensas durante o treinamento - 1000 episódios - com ruído.....	57
Figura 35: Oscilação simulada versus oscilação alvo - 2000 episódios - com ruído. 58	
Figura 36: Evolução das recompensas durante o treinamento - 2000 episódios - com ruído.....	58
Figura 37: Oscilação simulada versus oscilação alvo - 3500 episódios - com ruído. 59	
Figura 38: Evolução das recompensas durante o treinamento - 3500 episódios - com ruído.....	59
Figura 39: Oscilação simulada versus oscilação alvo - 5000 episódios - com ruído. 60	
Figura 40: Evolução das recompensas durante o treinamento - 5000 episódios - com ruído.....	60

LISTA DE TABELAS

Tabela 1: Os 30 poços com maior produção de petróleo no Brasil (bbl/d). Fonte: Brasil (2024).....	13
Tabela 2: Resultados experimentais e numéricos para St e Re. Fonte: Ássi (2005, p. 15); Meneghini et al. (2010, p. 20).....	24
Tabela 3: tabela-Q contendo as recompensas associadas a cada ação em cada estado.....	42
Tabela 4: Ação / Estado afetado.....	46
Tabela 5: Valores utilizados na geração de sinal de entrada para o modelo de aprendizado de máquina.....	47
Tabela 6: Valores de parâmetros encontrados na literatura.....	49
Tabela 7: Comparação dos parâmetros obtidos pelo modelo em relação à literatura.	50
Tabela 8: Parâmetros - 500 episódios - sem ruído.....	52
Tabela 9: Parâmetros - 1000 episódios - sem ruído.....	53
Tabela 10: Parâmetros - 2000 episódios - sem ruído.....	54
Tabela 11: Parâmetros - 3500 episódios - sem ruído.....	55
Tabela 12: Parâmetros - 5000 episódios - sem ruído.....	56
Tabela 13: Parâmetros - 500 episódios - com ruído.....	57
Tabela 14: Parâmetros - 1000 episódios - com ruído.....	58
Tabela 15: Parâmetros - 2000 episódios - com ruído.....	59
Tabela 16: Parâmetros - 3500 episódios - com ruído.....	60
Tabela 17: Parâmetros - 5000 episódios - com ruído.....	61

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	Contextualização.....	11
1.2	Objetivo.....	14
1.3	Justificativa.....	14
1.4	Escopo.....	15
1.5	Organização do trabalho.....	15
2	REVISÃO BIBLIOGRÁFICA.....	16
2.1	Escoamentos ao redor de corpos de geometria arbitrária.....	16
2.2	Escoamento em corpos cilíndricos.....	16
2.3	Número de Reynolds e o escoamento em torno de cilindros circulares 18	
2.3.1	Escoamentos completamente laminares.....	19
2.3.2	Regiões de transição.....	21
2.4	Número de Strouhal.....	22
2.5	Forças fluidodinâmicas.....	24
2.6	Vibrações induzidas por vórtices (VIV).....	25
2.7	Resposta típica e <i>lock-in</i>	28
2.8	Modelagem do fenômeno VIV.....	32
2.8.1	Oscilador estrutural.....	32
2.8.2	Oscilador da esteira.....	34
2.8.3	Acoplamento fluido-estrutura.....	35
2.9	Aprendizado por Reforço.....	36
2.9.1	Q-Learning.....	38
2.9.2	Exemplo de aplicação.....	40
3	MÉTODO.....	44

3.1	Aplicação de <i>Q-Learning</i> à equação de acoplamento.....	44
3.1.1	Dados utilizados no treinamento do modelo.....	46
3.1.2	Ferramentas e tecnologias.....	46
3.1.3	Aplicações.....	47
4	RESULTADOS.....	48
4.1	Modelo de acoplamento fluido-estrutura sem ruídos no sinal de entrada.....	51
4.1.1	500 episódios.....	51
4.1.2	1000 episódios.....	52
4.1.3	2000 episódios.....	53
4.1.4	3500 episódios.....	54
4.1.5	5000 episódios.....	55
4.2	Modelo de acoplamento fluido-estrutura.....	56
4.2.1	500 episódios.....	56
4.2.2	1000 episódios.....	57
4.2.3	2000 episódios.....	58
4.2.4	3500 episódios.....	59
4.2.5	5000 episódios.....	60
5	CONCLUSÃO.....	61
5.1	Contribuições do trabalho.....	61
	REFERÊNCIAS.....	62

1 INTRODUÇÃO

1.1 Contextualização

Do início dos anos 1950 aos anos 1960, a produção de petróleo no Brasil ocorreu exclusivamente *onshore*. O foco da indústria de petróleo no Brasil deslocou-se para a exploração *offshore* somente na década de 1960, sendo a primeira perfuração submarina realizada em 1968, na Bacia de Campos, RJ (ORTIZ NETO; DALLA COSTA, 2007, p.100).

Entre as décadas de 1970 e 1980, a produção *offshore* da *commodity* superou a produção em terra (MORAIS, 2013, p. 383). No ano de 2008 o país iniciou a produção de petróleo no Pré Sal, atingindo valores diários de aproximadamente 4,262 milhões de barris de óleo equivalente (MMboe/d) em março de 2024 (BRASIL, 2024).




Figura 1: Evolução da produção *onshore* e *offshore* – Pré-sal x Pós-sal. Fonte: Brasil (2024)

De acordo com o Boletim da Produção de Petróleo e Gás Natural, de março de 2024, produzido pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), os 30 poços com maior produção de petróleo, em barris de petróleo por dia (bbl/d), no Brasil são *offshore* (BRASIL, 2024).

Poço	Campo	Bacia	Localização	Petróleo (bbl/d)
7-ATP-6-RJS	Atapu / Atapu_Eco / Anc_Norte_Atapu / Oeste De Atapu	Santos	Mar	52.843
7-BUZ-S0D-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	50.061
3-BRSA-1322-RJS	Anc_Mero / Mero	Santos	Mar	49.547
7-BUZ-33-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	49.379
7-BUZ-45DA-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	48.893
9-ITP-1-RJS	Itapu / Itapu_Eco	Santos	Mar	48.484
7-MRO-6DB-RJS	Anc_Mero / Mero	Santos	Mar	46.697
9-ATP-1-RJS	Atapu / Atapu_Eco / Anc_Norte_Atapu / Oeste De Atapu	Santos	Mar	45.045
7-BUZ-10-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	44.354
7-BUZ-12-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	43.957
7-BUZ-18-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	43.858
7-ITP-5D-RJS	Itapu / Itapu_Eco	Santos	Mar	43.386
7-BUZ-25-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	42.467
7-MRO-10B-RJS	Anc_Mero / Mero	Santos	Mar	41.670
7-BUZ-23-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	41.030
7-BUZ-30-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	39.910
3-BRSA-1255-RJS	Anc_Mero / Mero	Santos	Mar	38.630
9-BUZ-4-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	37.566
7-BUZ-31D-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	35.367
9-BRSA-1254-RJS	Sépia / Sépia Leste / Sépia_Eco	Santos	Mar	34.761
7-ITP-3A-RJS	Itapu / Itapu_Eco	Santos	Mar	33.318
7-TUP-121DA-RJS	Tupi	Santos	Mar	30.555
3-BRSA-1201-RJS	Sépia / Sépia Leste / Sépia_Eco	Santos	Mar	30.432
7-MRO-3-RJS	Anc_Mero / Mero	Santos	Mar	30.277
7-LL-27-RJS	Tupi	Santos	Mar	29.167
9-BUZ-1-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	26.856
9-LL-12D-RJS	Anc_Tupi / Sul De Tupi / Tupi	Santos	Mar	26.805
7-SPH-22-SPS	Nordeste De Sapinhoá / Noroeste De Sapinhoá / Sapinhoá / Sudoeste De Sapinhoá	Santos	Mar	26.410
3-BRSA-1064-RJS	Búzios / Búzios_Eco / Tambuatá	Santos	Mar	26.235
9-LL-20D-RJS	Tupi	Santos	Mar	25.607

Tabela 1: Os 30 poços com maior produção de petróleo no Brasil (bbl/d). Fonte: Brasil (2024)

Considerando os dados expostos acima, verifica-se que entre os 30 poços com maior produção diária não há poços em terra (*onshore*) e que a produção de petróleo no mar (*offshore*) é bastante superior. Os dados de 2024 corroboram a ideia apresentada por Sucena, Marcondes e Couto (2020), de que é imprescindível pesquisar e estudar as condições a que plataformas de petróleo *offshore* estão sujeitas, para que, de forma proativa, seja possível evitar a paralisação parcial ou total de operações de unidades produtivas e minimizar prejuízos estruturais e econômicos.

Estruturas mal projetadas exigem manutenções frequentes e reparos emergenciais. Em profundidades de até 290 metros, conforme Barata (2003), ainda é viável a intervenção humana de mergulhadores para manutenção, reparo e inspeção de instalações marinhas. Para profundidades superiores, o uso de dispositivos apropriados é indispensável, tornando essas operações extremamente custosas. As condições a que equipamentos submersos são expostos podem afetar a vida útil deles e elevar os custos de intervenção em projetos *offshore* (MORAIS, 2013, p. 167). Os custos operacionais após a fase de exploração e perfuração de poços são elevados, no caso brasileiro da ordem de US\$ 5,00 por barril, conforme descrito em CBIE (2019).

Outro aspecto crítico é o impacto ambiental. Falhas estruturais podem provocar vazamentos de óleo ou gás, com graves consequências para o ecossistema marinho. A poluição resultante de acidentes dessa natureza pode ter efeitos duradouros sobre os ecossistemas marinhos, resultando na degradação de habitats, mortalidade de espécies e impactos econômicos nas comunidades costeiras. Além disso, a reputação das empresas envolvidas é frequentemente comprometida, resultando em consequências financeiras significativas e perda de confiança pública (JERNELÖV, 2010).

Por fim, falhas que causam acidentes ou danos ambientais podem acarretar multas pesadas e sanções regulatórias impostas por agências governamentais, a exemplo da Lei nº 9.605/1998 (Lei de Crimes Ambientais), o que impacta diretamente a viabilidade financeira do projeto.

Torna-se clara, portanto, a necessidade de se projetar instalações que sejam resistentes e que exijam manutenções ou reparos mínimos. Dentre os diversos tipos de instalações submersas, vale ressaltar a extensa aplicação de cabos, *risers* e dutos, os quais estão sujeitos a esforços produzidos pela correnteza e à interação fluido-estrutura (MORAIS, 2013; CICOLIN, 2015; TERREIRO, 2019). Esses esforços estão relacionados ao fenômeno de Vibrações Induzidas por Fluxo (VIF), mais especificamente, Vibrações Induzidas por Vórtices (VIV). Essas vibrações facilitam falhas por fadiga, causando danos estruturais e redução da vida útil do equipamento (CICOLIN, 2015; TERREIRO, 2019).

1.2 Objetivo

Este trabalho tem como foco ajustar o modelo fenomenológico proposto por Facchinetti, de Langre e Biolley (2004) por meio de uma metodologia diferente da utilizada pelos autores – aprendizado por reforço, mais especificamente, o algoritmo *Q-Learning* – usando apenas informação da oscilação temporal da estrutura.

A proposta é encontrar os melhores parâmetros para o modelo de acoplamento fluido-estrutura, que visa descrever de maneira analítica as vibrações induzidas por vórtices, às quais um cilindro imerso em escoamento de fluido está sujeito. Com esses parâmetros, pode-se verificar se chega-se à mesma conclusão do trabalho original e se o modelo descreve adequadamente o fenômeno de VIV.

Além disso, buscamos validar os benefícios oferecidos pelo método de aprendizado de máquina, no que tange precisão na obtenção dos parâmetros e técnicas que não dependem de modelagem do processo.

1.3 Justificativa

Ressaltou-se anteriormente a importância da presença da indústria petrolífera brasileira em regiões *offshore*. Concluiu-se que existe a necessidade de se projetar instalações que sejam resistentes e que exijam manutenções ou reparos mínimos.

Portanto, a aplicação de uma nova metodologia baseada em aprendizado por reforço, mais especificamente o algoritmo *Q-Learning*, para otimizar os parâmetros do modelo de acoplamento fluido-estrutura proposto por Facchinetti, de Langre e Biolley (2004), justifica-se pela possibilidade de encontrar-se uma solução que permita validar e possivelmente melhorar a modelagem fenomenológica de VIV.

1.4 Escopo

Esta pesquisa busca avaliar se a aplicação de aprendizado por reforço nas análises do comportamento de estruturas submetidas ao escoamento de fluidos corresponde aos mesmos resultados obtidos por Facchinetti, de Langre e Biolley (2004) e se alcança valores diferentes daqueles presentes na literatura para os parâmetros do modelo de acoplamento fluido-estrutura.

1.5 Organização do trabalho

O trabalho está estruturado da seguinte forma em sequência à introdução apresentada no capítulo 1: no capítulo dois é revisada a literatura sobre a qual o estudo está estruturado, abordando temas fundamentais de mecânica dos fluidos e de aprendizado por reforço pertinentes ao trabalho; a metodologia é tratada no capítulo três, focando na implementação do algoritmo de *Q-Learning* com o modelo de acoplamento, sendo o alicerce deste estudo; A análise de resultados e considerações finais são abordadas, respectivamente, nos capítulos quatro e cinco.

2 REVISÃO BIBLIOGRÁFICA

2.1 Escoamentos ao redor de corpos de geometria arbitrária

O entendimento sobre escoamentos é fundamental por estarem associados às áreas de desenvolvimento que passam pelas indústrias petrolífera, automobilística, de aviação, espacial, naval, construção civil, entre outras. Essa relevância advém da importância da análise de escoamentos em torno de corpos rombudos (corpos de geometria mais arredondada e com maior espessura em relação ao seu comprimento) e afilados em busca de alto desempenho. O interesse para a engenharia decorre do fato de que, geralmente, os corpos estão expostos a correntes de fluidos que os associam a escoamentos relacionados às questões de interação fluido-estrutura e a transição para turbulência. (BIMBATO, 2012, p. 1; RIBEIRO, 2002, p.2; SILVA, 2013, p. 1; FONSECA, 2013, p.13).

Um exemplo didático extraído de Bimbato (2012, p.1), é o da asa de um avião:

A asa de um avião, por exemplo, possui uma razão espessura-largura pequena e trabalha, em voo de cruzeiro, com ângulos de ataque pequenos; a fuselagem apresenta dimensões transversais pequenas quando comparadas com o seu comprimento. Todas essas características são próprias de um corpo esbelto. Entretanto, as aeronaves trabalham, nos momentos mais críticos (procedimentos de pouso e de decolagem) com suas asas submetidas a elevados ângulos de ataque. Nestas condições, uma asa, mesmo que fina, pode apresentar uma extensa zona descolada no seu extradorso e uma esteira viscosa significativa, o que constituem as características marcantes do escoamento ao redor de um corpo rombudo.

Bimbato (2012, p.2) apresenta ainda outro exemplo, agora relacionado aos efeitos de Vibrações Induzidas por Vórtices, VIV, nos *risers* da indústria petrolífera *offshore*:

Os *risers* são tubos cilíndricos longos, que possuem a função de transportar o petróleo do fundo do mar para a plataforma. Os esforços cíclicos a que estão submetidos, decorrentes de vibrações, são capazes de degradar a estrutura mecânica dos *risers* por um processo de fadiga.

2.2 Escoamento em corpos cilíndricos

A classificação de um corpo como afilado ou como rombudo está intimamente relacionada ao seu comportamento sob influência de um escoamento. Ao ser

submetido a um fluxo de fluidos, se for gerado escoamento separado sobre uma porção substancial de sua superfície, esse corpo pode ser classificado como rombudo. Para valores baixos de Re (número de Reynolds) o escoamento ao redor de um corpo rombudo permanece estável, no entanto essa estabilidade se esvai quando o número de Reynolds ultrapassa certo valor crítico. (BEARMAN, 1984, p. 1).

Na Figura 2 é possível visualizar a esteira atrás do corpo rombudo, com destaque para a superfície exposta ao escoamento separado (em vermelho).

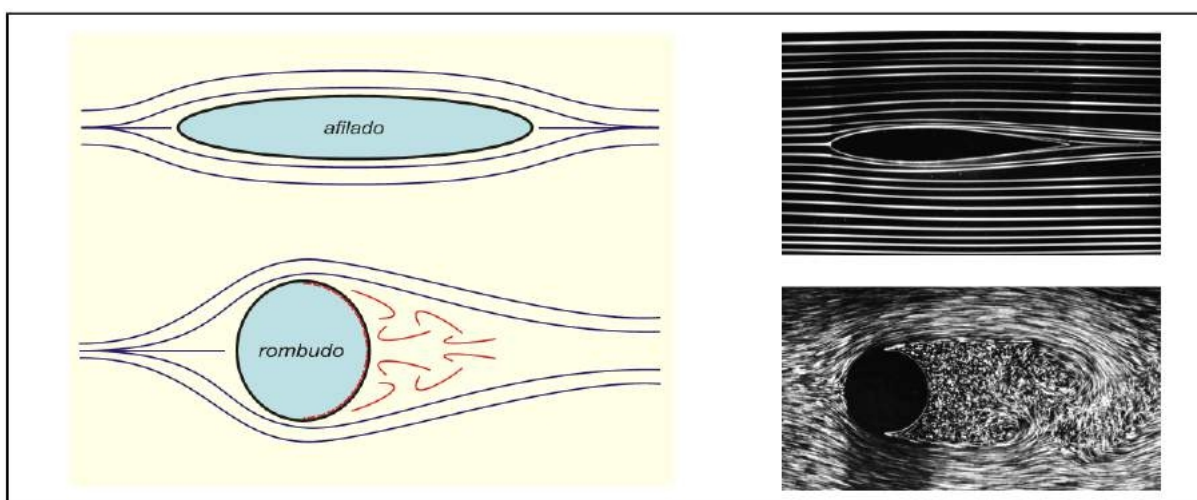


Figura 2: Esquema e visualização do escoamento ao redor de um corpo afilado e um corpo rombudo.

Fonte: Ássi (2005, p. 9)

Conforme explicado por Ássi (2005, p. 8):

A separação pode ocorrer devido à geometria do corpo e às condições da camada limite (quando a superfície exposta for contínua). Se a forma do corpo não for suavemente afilada, mas terminar abruptamente, o escoamento que segue uma linha de corrente próxima à superfície sofrerá um impedimento devido a um aumento no campo de pressão. Este impedimento se dá por causa de um gradiente desfavorável de pressão no sentido do escoamento (ou gradiente adverso de pressão), forçando o escoamento próximo à desaceleração e consequente separação. Os efeitos de turbulência na camada limite também influenciam no fenômeno de separação. À medida que a camada limite se torna turbulenta, o ponto de separação se move para a parte posterior (à jusante) do corpo.

A Figura 3 apresenta o escoamento ao redor de corpos rombudos em regiões de escoamento perturbado pela presença do corpo, conforme segue:

Região 1 - faixa de escoamento retardado consequentes do ponto de estagnação frontal no corpo;

Região 2 - camada limite aderida à superfície do corpo. Quando o gradiente de pressão passa a ser desfavorável para a aderência das camadas limites elas se separam e formam as camadas cisalhantes livres que delimitam a esteira próxima;

Região 3 - escoamento deslocado e acelerado pela presença do corpo, na qual a velocidade média do escoamento é maior que a do escoamento incidente;

Região 4 - esteira é a parte do escoamento perturbado, que apresenta escoamento totalmente separado e com velocidade média menor que a incidente;

Na esteira próxima (região da esteira junto ao corpo) têm origem os principais fenômenos responsáveis pelas vibrações induzidas pelo escoamento.




Figura 3: Regiões de escoamento perturbado pela presença do corpo rombudo Fonte: Ássi (2005, p. 10).

2.3 Número de Reynolds e o escoamento em torno de cilindros circulares

O fenômeno de separação, mencionado no tópico anterior, é governado pelo número de Reynolds (Re). Essa grandeza adimensional relaciona a magnitude das

forças inerciais e viscosas no escoamento (ÁSSI, 2005, p. 10; CICOLIN, 2015, p. 7), de acordo com a equação (2.1):

$$Re = \frac{\rho U_{\infty} D}{\mu} = \frac{U_{\infty} D}{\nu} \quad (2.1)$$

onde ρ representa a massa específica do fluido; U_{∞} , a velocidade do escoamento incidente; D , uma dimensão característica do escoamento; μ a viscosidade dinâmica (absoluta) do fluido; e ν a viscosidade cinemática do fluido. Dado que o presente estudo enfoca em escoamentos ao redor de corpos rombudos com geometria cilíndrica e que apresentam seções transversais circulares, deste ponto em diante D representará o diâmetro externo do cilindro e U_{∞} , a velocidade do escoamento incidente ao longe.

2.3.1 Escoamentos completamente laminares

Tratando-se de escoamentos ao redor de cilindros circulares, é interessante pensar sobre escoamentos completamente laminares. Segundo Carmo (2005), esse tipo de escoamento pode ser dividido em três estados:

L1: escoamento altamente viscoso sem separação (*creeping flow*): $0 < Re < 4$ a 5;

L2: separação com recirculação estacionária: 4 a $5 < Re < 30$ a 48 ;

L3: regime laminar periódico: 30 a $48 < Re < 180$ a 200 ;

Em L1 as camadas limite não se separam da superfície do cilindro em nenhum ponto, vide Figura 4. O regime é estacionário e não há a formação de uma esteira visível.




Figura 4: Escoamento ao redor de cilindro sem separação. Fonte: Van Dyke (1988, p.8).

A separação - L2 - se inicia em $Re = 4$ a 5 , quando bolhas de recirculação estacionárias e simétricas são formadas. As camadas cisalhantes livres se encontram à jusante dessas bolhas, no chamado ponto de confluência. Ambos os fenômenos mencionados se fazem visíveis na Figura 5.




Figura 5: Escoamento ao redor de um cilindro, $Re = 26$.

Fonte: Van Dyke (1988, p.28).

Com o aumento de Re as bolhas de recirculação acabam por se alongar e a esteira fica instável para $Re = 30$ a 48 . Nesse ponto já se trata de um regime laminar periódico - L3 -. Elevando Re ainda mais, observa-se uma oscilação harmônica ao longe, com amplitude que aumenta com Re . Para valores entre 45 e 65 as camadas cisalhantes se enrolam formando cristas e vales. Para valores de Re superiores a esses, uma carreira de vórtices laminares, conhecida por esteira de von Kármán, pode ser observada (ÁSSI, 2005, p. 12).




Figura 6: Representações dos três estados de escoamentos completamente laminares. Fonte: Ássi (2005, p. 12).

2.3.2 Regiões de transição

À medida que o número de Reynolds aumenta, o escoamento passa por transições sucessivas, assumindo regimes diferentes para cada região perturbada ao redor do corpo. Carmo (2005, p. 27) afirma que “cada transição é sensível a pequenas perturbações de várias espécies. Estas perturbações podem fazer com que as transições se iniciem em um Re menor e muitas vezes podem modificar significativamente as estruturas resultantes.”

Zdravkovich (1988, p. 93) afirma que “é esperado que o número de Reynolds seja o único parâmetro governante apenas para o escoamento livre de perturbações.”. Na Figura 7 são mostradas esquematicamente as transições que ocorrem em três regiões: TrW (*transition on wake* ou transição na esteira), $TrSL$ (*transition on shear layers* ou transição nas camadas cisalhantes) e $TrBL$ (*transition on boundary layers* ou transição nas camadas limite).




Figura 7: Transições em cada região perturbadora. Fonte: Zdravkovich (1988, p. 96).

A transição para o regime turbulento na esteira - TrW -, esboçada na Figura 7 (a), ocorre para $Re \approx 2 \times 10^2$. “A turbulência gradualmente se desenvolve na região próxima ao cilindro e se espalha ao longo da esteira, mas as camadas cisalhantes, que limitam a região de esteira próxima, permanecem laminares.” (CARMO, 2005, p. 27).

Aumentando-se o número de Reynolds, a transição turbulenta antecipa-se em direção ao ponto de separação e acontece nas camadas cisalhantes - TrSL -, representada na Figura 7 (b), afetando o comprimento e a largura da esteira próxima. (CARMO, 2005, p. 27).

Quando o escoamento atinge $Re \approx 10^5$, a transição para regime turbulento alcança a camada limite no ponto de separação - TrSL -, representada pela Figura 7 (c), causando uma redução súbita no arrasto, chamada de crise do arrasto. (CARMO, 2005, p. 27).

Para valores ainda mais altos de Re , a transição turbulenta se move em direção ao ponto de estagnação, gerando uma camada limite completamente turbulenta na região de separação, como representado na Figura 7 (d). (CARMO, 2005, p. 28).

2.4 Número de Strouhal

A emissão de vórtices ocorre de forma alternada, periódica, de frequência f_s . O adimensional dessa frequência é o número de Strouhal (St). “Esta frequência de emissão é inversamente proporcional à razão entre o diâmetro do cilindro e a velocidade do escoamento, decorrendo daí a definição do número de Strouhal, St ” (GONÇALVES, 2013, p.38), representado por:

$$St = \frac{f_s D}{U_\infty} \quad (2.2)$$

Na figura 8 e tabela 2 são apresentados dados experimentais e numéricos para a variação do número de Strouhal em relação ao número de Reynolds para uma faixa ampla de até 10^6 . Esse parâmetro é utilizado para relacionar a frequência de emissão de vórtices com as características geométricas e do escoamento. Verifica-

se que, para uma vasta faixa de Reynolds, o número de Strouhal para um cilindro é da ordem de $St \approx 0,2$. (NORBERG, 2001, p.461; ÁSSI, 2005, p.14; ÁSSI, 2009, p.154; VIOLETTE; DE LANGRE; SZYDLOWSKI, 2007, p. 1136; SILVA, 2013, p.19; CICOLIN, 2015, p.9).




Figura 8: Relação entre o número de Strouhal e o número de Reynolds. Fonte:Norberg (2001, p. 461).

Re	Autor	St
100	Braza et al. (1986) numérico	0,16
100	Sa & Chang (1991) numérico	0,155
100	Meneghini (1993) numérico	0,162
100	Williamson (1991) experimental	0,164
200	Braza et al. (1986) numérico	0,20
200	Borthwick (1986) numérico	0,188
200	Sa & Chang (1991) numérico	0,186
200	Meneghini (1993) numérico	0,195
200	Williamson (1991) experimental	0,196
10000	Ribner & Etkin (1958) apud Roshko (1961) experimental	0,20

Tabela 2: Resultados experimentais e numéricos para St e Re. Fonte: Ássi (2005, p. 15); Meneghini et al. (2010, p. 20).

2.5 Forças fluidodinâmicas

“O campo de velocidades do escoamento ao redor de um cilindro gera uma distribuição de pressão ao redor da parede. O efeito desse campo de pressões é a resultante das forças fluidodinâmicas aplicadas no cilindro.” (ÁSSI, 2005, p.15). “O desprendimento de vórtices ao redor do cilindro altera o campo de pressão em seu entorno, produzindo uma força fluidodinâmica cíclica no corpo.” (CICOLIN, 2015, p.9).

O campo de pressões ao redor da parede é representado em termos dos coeficientes de pressão, adimensionalizados em termos da pressão dinâmica ($\frac{1}{2}\rho U_{\infty}^2$), e da área projetada do corpo (ÁSSI, 2005, p. 15).

Cicolin (2015) afirma que “essa força pode ser dividida em uma componente paralela ao escoamento F_D - força de arrasto (ou *drag*) - e outra perpendicular ao escoamento, F_L - força de sustentação (ou *lift*)”. Tais forças podem ser representadas em sua forma adimensionalizada do cilindro:

$$C_D = \frac{F_D}{\frac{1}{2}\rho U_{\infty}^2 D} \quad (2.3)$$

$$C_L = \frac{F_L}{\frac{1}{2}\rho U_{\infty}^2 D} \quad (2.4)$$

e tem-se o coeficiente de arrasto (C_D) e o coeficiente de sustentação (C_L).

Conforme Ássi (2005, p. 15), “o escoamento ao redor de um cilindro apresenta um campo de velocidades cíclico, variável no tempo, quando surge a instabilidade e formação da esteira de vórtices”. Dessa forma, o campo de pressões também será variável e os coeficientes de pressão podem ser escritos em termos de um valor médio \bar{C} e uma parcela flutuante C' , de acordo com as equações:

$$C = \bar{C} + C' \quad (2.5)$$

$$C = \overline{C_D} + C'_D \quad (2.6)$$

Na Figura 9 pode-se observar os valores dos coeficientes para diferentes valores de Re . O coeficiente de sustentação médio $\overline{C_L}$ é nulo em decorrência da simetria do escoamento, enquanto C'_L se torna significativo a partir do início do desprendimento de vórtices no regime laminar (CICOLIN, 2015, p. 11).

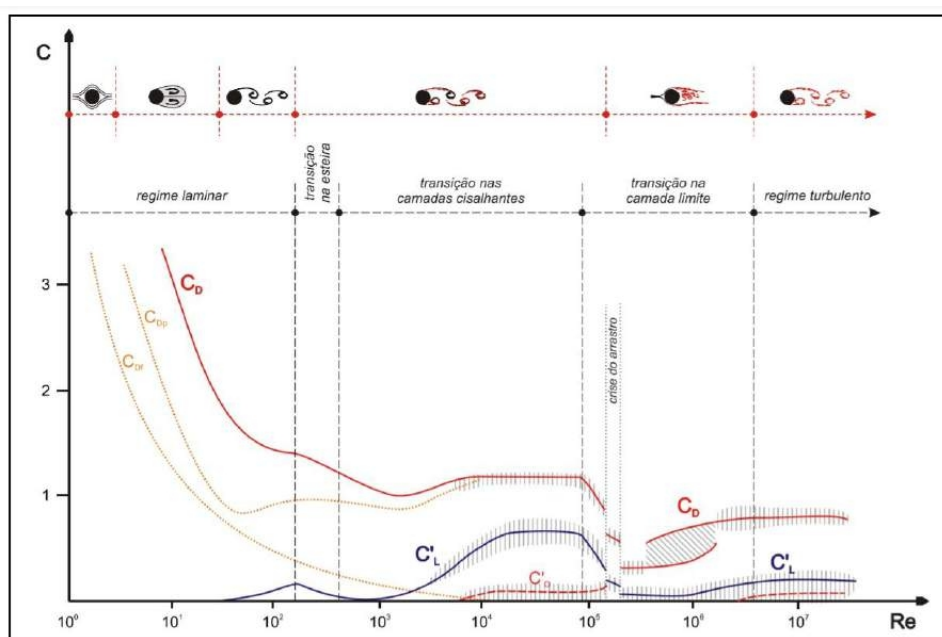


Figura 9: Comportamento dos coeficientes de pressão comparados com os regimes de escoamento e em relação. Fonte: Ássi (2005, p.16).

2.6 Vibrações induzidas por vórtices (VIV)

“As vibrações induzidas pela emissão de vórtices – VIV – são um dos tipos de vibrações induzidas pelo escoamento em corpos rombudos.” (ÁSSI, 2005, p. 50). Trata-se de uma “vibração da estrutura causada pela interação entre a dinâmica do corpo e a excitação periódica das forças fluidas geradas na modificação do campo de pressões, consequência da emissão de vórtices na esteira próxima.” (ÁSSI, 2005, p. 43). Portanto, “a fonte dos efeitos de VIV está na interação entre o cilindro e os

campos de pressões modificados pela emissão dos vórtices na esteira.” (ÁSSI, 2005, p. 51).

Conforme Ássi (2005, p. 51), as vibrações podem ocorrer em duas direções: transversal e longitudinal ao escoamento. Ele afirma que:

[...] a flutuação das forças na direção transversal é maior que na direção longitudinal,

uma vez que a força de arrasto não muda de direção enquanto a força de sustentação varia sua magnitude e direção. Logo, a excitação na direção transversal tem maior intensidade que na direção longitudinal, resultando em um movimento de oscilação mais amplo na primeira direção. Por outro lado, a amplitude de oscilação na direção do arrasto é menor e tem o dobro da frequência. (Ássi, 2005, p. 51).

Considerando que as vibrações transversais ao escoamento tem maior intensidade em relação às vibrações longitudinais, as primeiras são o foco deste trabalho.

Na Figura 10 pode-se perceber que as vibrações transversais estão associadas a um campo de pressão assimétrico, atrelado à emissão de vórtices, que leva à uma força de sustentação fluidodinâmica na mesma direção dessas vibrações.




Figura 10: Modelo de oscilação harmônica em cilindro elástico. Fonte: Ássi (2009, p. 26).

Vale reiterar que existe uma alternância na emissão de vórtices, o que leva a “uma flutuação periódica na força transversal de sustentação proporcional à frequência de

emissão desses vórtices na esteira” (Ássi, 2005, p. 50). Com isso, é possível representar essa força em um modelo de oscilação harmônica. Na Figura 11 observa-se esse caráter oscilatório do campo de pressão e, conseqüentemente, da força transversal de sustentação.




Figura 11: Variação do campo de pressão na parede para aproximadamente um terço do ciclo de emissão de vórtices. Fonte: Ássi (2005, p. 50).

Ressalta-se que as amplitudes de vibração “podem atingir valores significativos, da ordem do diâmetro do cilindro, principalmente quando a frequência de emissão de vórtices se aproxima de uma das frequências naturais do sistema.” (CICOLIN, 2015, p. 12). Quando isso acontece, ou seja, quando tais frequências são muito próximas ou idênticas, acontece o fenômeno de Ressonância (ÁSSI, 2005, p. 52; SILVA, 2013, p. 34).

Essas vibrações, a que vários tipos de estruturas estão sujeitas, como por exemplo, cabos suspensos para pontes, linhas de transmissão de energia no ar, tubos, *risers*,

entre outros, podem causar danos a estruturas, como falha por fadiga. (KHALAK; WILLIAMSON, 1999, p. 814; FACCHINETTI; DE LANGRE; BIOLLEY, 2004, p. 123; SILVA, 2013, p. 34; CICOLIN, 2015, p. 2 e 12).

2.7 Resposta típica e *lock-in*

Na resposta típica são considerados os seguintes parâmetros do VIV em forma adimensional, conforme descrito por Ássi (2005, p. 46) e por Cicolin (2015, p. 14). A adimensionalização desses parâmetros os torna padronizados, facilitando a análise dos dados disponíveis.

- **Velocidade reduzida (U_r):** razão entre a velocidade do escoamento ao longe (U_∞) e o produto entre a frequência natural do sistema em água (f_w) e o diâmetro do cilindro (D): $U_r = U_\infty / f_w D$.
- **Parâmetro de massa (m^*):** razão entre a massa do sistema (m) e a massa do fluido deslocada (m_v): $m^* = m / m_v$.
- **Amplitude reduzida (A^*):** razão entre a amplitude de vibração do sistema (\hat{y}) e o diâmetro do cilindro (D): $A^* = \hat{y} / D$.
- **Frequência reduzida (f^*):** razão entre a frequência de oscilação do cilindro (f_s) e a frequência natural do sistema no vácuo (f_{0N}): $f^* = f_s / f_{0N}$.
- **Parâmetro de amortecimento (ζ):** razão entre o amortecimento estrutural (c) e o amortecimento crítico ($c_{cr} = 2\sqrt{km}$): $\zeta = c / c_{cr}$.

Como mencionado anteriormente, um sistema de oscilação pode vir a sofrer o fenômeno de ressonância quando a frequência da excitação externa f_s se aproximar da frequência natural de oscilação da estrutura f_0 . Considerando o acoplamento fluido estrutura analisado neste estudo, a formação de vórtices representa essa excitação externa, que tem como frequência característica aquela de emissão de vórtices.

Com a assunção de que $f_s \approx St \approx 0.2$ em boa parte do escoamento, é possível calcular uma aproximação para a velocidade de sincronização U^* :

$$U^* \approx U_r = \frac{U_\infty}{f_w D} \approx \frac{1}{St} \approx 5 \quad (2.7)$$

No VIV, a sincronização de frequências ocorre de uma forma distinta dos casos tradicionais de ressonância, pois nesse fenômeno existe uma faixa de sincronização, não somente um ponto, como ocorre para a ressonância clássica.

Segundo Ássi (2005, p.52), o fenômeno de sincronização (*lock-in*) é definido como “o regime em que a frequência de emissão de vórtices f_s é capturada pela frequência f . Assim, ocorre sincronização quando $f_s / f \approx 1$.”

Silva (2013, p. 34) descreve esse fenômeno conforme abaixo:

Um oscilador harmônico comum responde à entrada do sistema com a mesma frequência em que é excitado. Porém, em sistemas sujeitos a VIV a figura muda um pouco, pois o sistema de excitação (desprendimento de vórtices) está intimamente ligado ao sistema excitado (cilindro) de forma que a movimentação do corpo altera o padrão de emissão de vórtices e desta forma altera o seu próprio carregamento. Dado um oscilador formado por um cilindro sujeito a um escoamento, pode-se aumentar a velocidade da corrente de forma que se consiga atingir a ressonância. Porém ao passar por este ponto haverá uma região em que o cilindro ainda responderá com grandes amplitudes, pois o sistema se retroalimenta de forma que a frequência de emissão de vórtices é capturada pela frequência de vibração do cilindro, permanecendo sincronizadas até que esta faixa acabe. Este fenômeno é chamado de “*lock-in*” ou sincronização.

Essa faixa de sincronização pode ser observada na Figura 12. Os gráficos de resposta em frequência mostram “a representação da relação linear entre a frequência de emissão f_s e a velocidade reduzida, deixando claro o coeficiente angular ditado pelo número de Strouhal, $St = 0,20$ ”, ilustrando o processo de sincronização. (PEREIRA, 2014, p. 17).

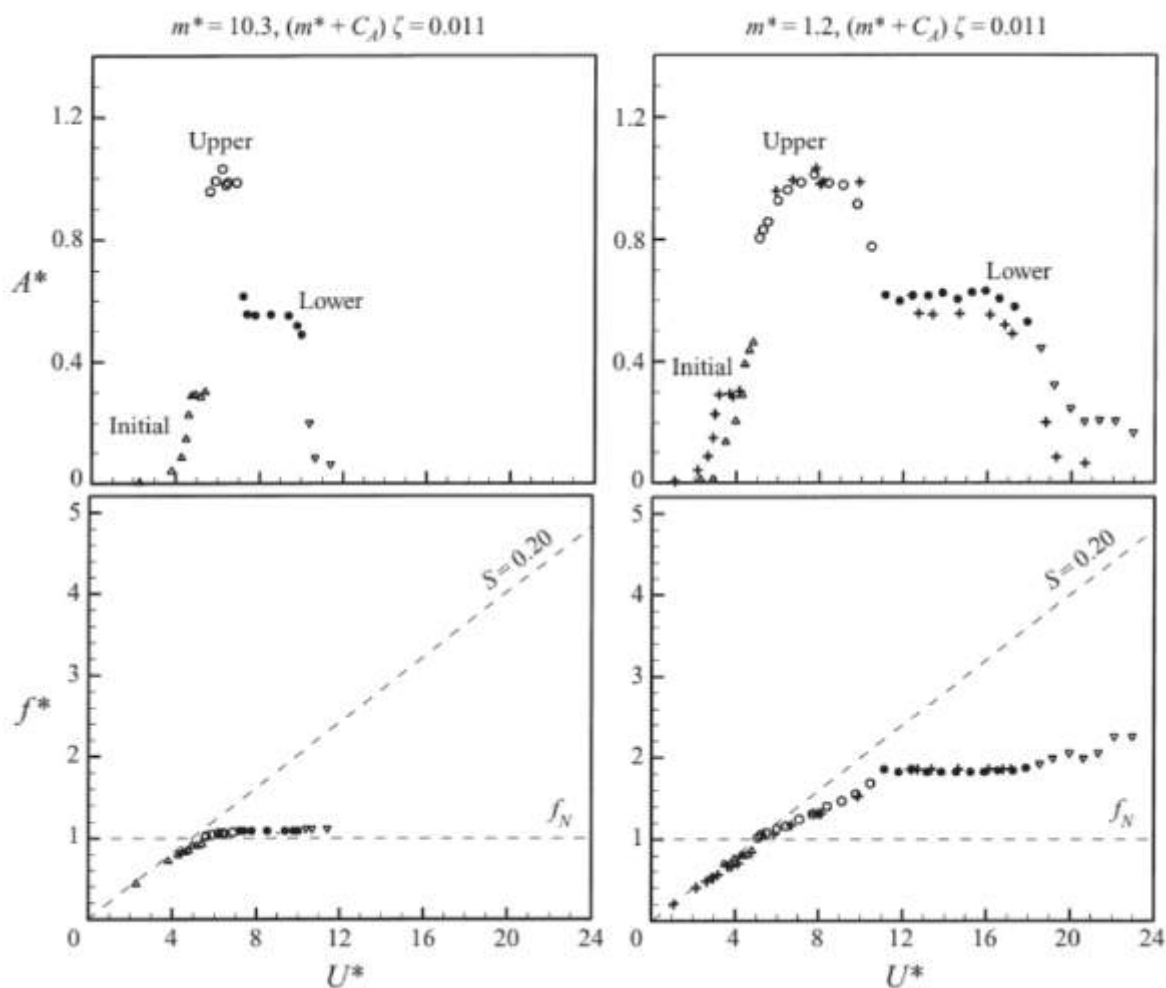


Figura 12: Resposta típica de VIV (amplitude e frequência) de um cilindro. Fonte: Adaptada de Govardhan & Williamson (2000, p. 122).

Adicionalmente, buscando uma maior compreensão da resposta típica da amplitude de oscilação do cilindro, na figura 13 está apresentada a reação da amplitude reduzida ao aumento do Re e da velocidade de escoamento reduzida.




Figura 13: Resposta típica da amplitude de oscilação de um cilindro livre para oscilar transversalmente ao fluxo. Fonte: Ássi (2009, p. 85).

Conforme Pereira (2014, p. 15), considerando-se as amplitudes máximas transversais, pode-se observar que há:

- 1) Um ramo inicial (*Initial Excitation*), em que a frequência de emissão de vórtices é ligeiramente menor que a frequência natural do sistema e, portanto, onde se tem menores valores de amplitude de VIV;
- 2) Um ramo superior (*Upper branch*), em que há grandes amplitudes de resposta de VIV em função da sincronização da frequência de emissão de vórtices com a frequência natural do cilindro, ou ;
- 3) Um ramo inferior (*Lower branch*), em que a sincronização é mais evidente porém com respostas em valores menores que as do *Upper branch*, em um prenúncio da interrupção do quadro ressonante.

2.8 Modelagem do fenômeno VIV

O presente estudo teve como base o modelo proposto por Facchinetti, de Langre e Biotley (2004) para análise computacional simplificada do fenômeno de VIV. Eles discorrem sobre três possíveis métodos de modelagem da fenomenologia de vibrações induzidas por vórtices, os quais são por acoplamento via deslocamento, velocidade ou aceleração do cilindro (ibid.). Ao final de seu estudo, averiguou-se que o modelo de acoplamento por aceleração obteve resultados notavelmente melhores que as outras opções (FACCHINETTI; DE LANGRE; BIOLLEY, 2004, p. 138), sendo, portanto, o modelo empregado neste trabalho.

2.8.1 Oscilador estrutural

O modelo proposto por Facchinetti, de Langre e Biotley (2004) considera um cilindro circular rígido de diâmetro D , conectado a um suporte elástico, com um grau de liberdade - 1 dof. Tal cilindro oscila somente na direção transversal a um escoamento laminar e uniforme, de velocidade U .




Figura 14: Modelo de estrutura acoplada e osciladores de esteira para vibrações 2-D induzidas por vórtices. Fonte: Facchinetti, de Langre e Biotley (2004, p.

equação (3.1), na qual Y representa o deslocamento dimensional transversal à correnteza, descreve um oscilador linear:

$$m\ddot{Y} + r\dot{Y} + hY = S \quad (3.1)$$

onde (\cdot) representa a derivada em relação ao dimensional de tempo T .

A massa m engloba, simultaneamente, a massa da estrutura m_s e a massa adicional m_f , atrelada ao fluido. De forma semelhante, o amortecimento r é resultado da combinação do amortecimento estrutural r_s com o amortecimento hidrodinâmico r_f . Os termos tratados acima respeitam as seguintes relações (FACCHINETTI; DE LANGRE; BIOLLEY, 2004, p. 125):

$$m = m_s + m_f \quad m_f = C_M \rho D^2 \frac{\pi}{4} \quad \mu = \frac{m_s + m_f}{\rho D^2} \quad (3.2)$$

$$r = r_s + r_f \quad r_f = \gamma \Omega \rho D^2 \quad (3.3)$$

onde ρ é a densidade do fluido, μ é um adimensional de razão de massa, C_M é o coeficiente de massa adicionado, γ é um coeficiente de amortecimento do fluido (SKOP; BALASUBRAMANIAN, 1997; SKOP; LUO, 2001) e Ω uma frequência angular de referência. Ainda em relação à equação (3.1), tem-se a rigidez h , associada somente a efeitos externos.

Como tratado por Facchinetti, de Langre e Biolley (2004), em fluido parado, Ω é a frequência angular do movimento da estrutura e γ , função da amplitude de oscilação, relacionado ao coeficiente de arrasto C_D . Entretanto, no caso em questão, apesar de γ ainda estar relacionada a C_D , Ω passa a ser a frequência angular do derramamento de vórtices, $\Omega = \Omega_f = 2\pi StU/D$, onde St é o número de Strouhal.

Definindo a frequência angular estrutural $\Omega_s = \sqrt{h/m}$ e o coeficiente de amortecimento estrutural $\xi = r_s / (2m\Omega_s)$, pode-se reescrever a equação (3.1) da seguinte forma:

$$\ddot{Y} + (2\xi\Omega_s + \frac{\gamma}{\mu}\Omega_f)\dot{Y} + \Omega_s Y = \frac{S}{m} \quad (3.4)$$

2.8.2 Oscilador da esteira

De acordo com Nayfeh (1993), a natureza flutuante da esteira de vórtices é modelada por um oscilador não linear que satisfaz a equação de van der Pol.

$$\ddot{q} + \xi\Omega_f(q^2 - 1)\dot{q} + \Omega_f q = F \quad (3.5)$$

Esse oscilador não linear será tratado como o oscilador de esteira.

Facchinetti, de Langre e Biolley (2004) citam possíveis explicações para o sentido físico da variável de esteira adimensional $q(t)$. Afirma-se que poderia estar associada ao coeficiente de sustentação da estrutura C_L (HARTLEN; CURRIE, 1970); alternativamente poderia ser considerado como uma variável de um modelo reduzido para o escoamento relacionado à média ponderada da componente transversal do escoamento (BLEVINS, 2001); também já foi atribuída uma proporcionalidade com a velocidade transversal de uma massa de fluido representativa na região da esteira próxima ao cilindro (KRENK; NIELSEN, 1999); e associado com o deslocamento transversal médio da camada de fluido da região da esteira em relação ao eixo de coordenadas apontando ao longo do escoamento livre (NOACK; OHLE; ECKELMANN, 1991).

A variável F , presente no lado direito da igualdade (3.5), modela os efeitos do movimento do cilindro na região da esteira, próxima a ele. Quando $F = 0$ e $0 < \varepsilon \ll 1$, o oscilador de esteira (3.5) fornece uma oscilação estável, quase-harmônica, de amplitude finita $q_0 = 2$, tendo frequência angular Ω_f (NAYFEH, 1993).

2.8.3 Acoplamento fluido-estrutura

Seguindo a ideia de Facchinetti, de Langre e Biolley (2004), introduzindo o adimensional de tempo $t = T\Omega_f$ e a coordenada espacial $y = Y/D$, as equações (3.4) e (3.5) levam ao sistema dinâmico do acoplamento fluido-estrutura:

$$\ddot{y} + (2\xi\delta + \frac{\gamma}{\mu})\dot{y} + \delta^2 y = s \quad \ddot{q} + \epsilon(q^2 - 1)\dot{q} + q = f \quad (3.6)$$

onde $\delta = \Omega_s/\Omega_f$ é a frequência angular reduzida da estrutura, também relacionada à velocidade reduzida U_r .

Os termos adimensionais do acoplamento são:

$$s = \frac{S}{D\Omega_f^2 m} = S \cdot \frac{D}{4\pi^2 St^2 U^2 m} \quad f = \frac{F}{D\Omega_f^2} = F \cdot \frac{D}{4\pi^2 St^2 U^2} \quad (3.7)$$

Agora, o símbolo “ \cdot ”, presente na equação (3.6), representa a derivada em relação ao adimensional de tempo t . O sistema (3.6) é a forma básica de modelos fenomenológicos de VIV usando osciladores de van der Pol. Com a proposta de deixar o modelo o mais simples possível, Facchinetti, de Langre e Biolley (2004) determinaram que os termos de acoplamento fluido-estrutura no lado direito das igualdades sejam limitados a serem funções lineares de q e y , e de suas derivadas temporais.

A ação s do fluido na região da esteira, próxima ao cilindro, na estrutura geralmente é considerada como uma força de sustentação flutuante (HARTLEN; CURRIE, 1970). Em variáveis dimensionais, podemos definir a variável como:

$$S = \frac{1}{2} \rho U^2 D C_L \quad (3.8)$$

Facchinetti, de Langre e Biolley (2004) chamam atenção para o fato de que C_L , na expressão acima, não corresponde ao coeficiente de sustentação instantânea total

na estrutura devido a S representar a força causada apenas pela vorticidade da esteira. Para contornar o problema, Facchinetti, de Langre e Biolley (2004) seguiram a ideia apresentada por Govardhan e Williamson (2000) e definiu C_L como o coeficiente de sustentação da esteira e C_L^{tot} como o coeficiente de sustentação total. Nesse caso, a variável q é interpretada como coeficiente de sustentação reduzido do vórtice $q = 2C_L/C_{L0}$, onde o coeficiente de sustentação de referência (C_{L0}) é aquele observado numa estrutura fixa sujeita a desprendimento de vórtices. A razão $K = q/2 = C_L/C_{L0}$ descreve, portanto, a ampliação da sustentação do vórtice referente à uma estrutura fixa sujeita a desprendimento de vórtices. Em sua forma adimensional, (3.8) é escrita da seguinte forma:

$$s = Mq \quad M = \frac{1}{2} C_{L0} \cdot \frac{1}{8\pi^2 St^2 \mu} \quad (3.9)$$

Como μ é uma razão de massa, vide (3.2), M é, essencialmente, um número de massa, e escala o efeito da esteira na estrutura.

Como mencionado no tópico 3.1, diversas escolhas podem ser consideradas para a ação de f no oscilador de esteira. Seria possível seguir com o modelo de acoplamento baseado em deslocamento $f = Ay$, com o atrelado à velocidade $\dot{f} = A\dot{y}$, ou com o associado à aceleração $\ddot{f} = A\ddot{y}$. No presente estudo, será utilizado o acoplamento por aceleração.

2.9 Aprendizado por Reforço

Aprendizado por reforço (AR) é uma área de aprendizado de máquina onde um agente aprende a tomar decisões realizando certas ações dentro de um ambiente, buscando maximizar uma recompensa cumulativa. Ao contrário do aprendizado supervisionado, onde o modelo é treinado em um conjunto de dados com pares de entrada-saída, AR foca em aprender através de tentativa e erro (SUTTON; BARTO, 2018).

AR é composto por diversos algoritmos, divididos entre *model-free* – sem modelo – e *model-based* – baseado em modelo. Algoritmos do primeiro tipo aprendem diretamente da interação com o ambiente, ajustando suas ações com base nas recompensas recebidas, sem um modelo explícito dele. Já os algoritmos baseados em modelo utilizam um esquema pré definido para prever as consequências das ações, permitindo planejar melhor as decisões.

Ainda assim, todos têm em comum as seguintes características, descritas de acordo com (SUTTON; BARTO, 2018):

- Agente e Ambiente: O agente é a entidade que aprende e toma decisões, enquanto o ambiente é tudo o que não é o agente.
- Ação: Uma ação é uma escolha feita pelo agente que afeta o ambiente.
- Estado: O estado é uma representação da situação atual no ambiente e contém todas as informações relevantes que o agente precisa para tomar uma decisão.
- Recompensa: A recompensa é um sinal numérico que o agente recebe imediatamente após a execução de uma ação em um estado específico. Ela indica o sucesso ou fracasso da ação em relação ao objetivo geral, orientando o agente a maximizar o retorno acumulado ao longo do tempo.
- Política: Uma política define o comportamento do agente em cada estado, mapeando estados a ações.

Dentro de um modelo de AR, o agente interage continuamente com o ambiente. Ele observa o estado em que se encontra, seleciona uma ação, recebe uma recompensa do ambiente e transita para um novo estado. O objetivo é desenvolver uma política que maximize a recompensa total ao longo do tempo (KAELBLING; LITTMAN; MOORE, 1996).




Figura 15: Interação entre agente e ambiente. Fonte: Garnier et al. (2021, p. 2)

Como mencionado anteriormente, existem diversos algoritmos de AR. Neste trabalho optou-se por utilizar o *Q-Learning*, um algoritmo sem modelo, ou seja, que não requer um modelo do ambiente para aprender políticas otimizadas. Esse tipo de algoritmo baseia-se exclusivamente nas experiências coletadas pelo agente ao interagir com o ambiente para aprender como tomar decisões.

2.9.1 *Q-Learning*

Resumidamente, *Q-Learning* é um algoritmo que visa encontrar a política de seleção de ações mais otimizada para qualquer Processo de Decisão de Markov (MDP) dado (WATKINS; DAYAN, 1992). Por sua vez, um MDP é uma estrutura matemática que modela problemas de decisão sequenciais em ambientes estocásticos, permitindo que um agente escolha ações de maneira a maximizar a soma de recompensas esperadas ao longo do tempo (SUTTON; BARTO, 2018).

Um algoritmo de *Q-Learning* revolve em torno de valores de qualidade (Valores *Q*), que representam a qualidade de uma ação em um determinado estado, ou seja, o valor esperado da recompensa futura ao tomar uma determinada ação a partir de um estado específico; da política (π), uma estratégia que define o comportamento do

agente em cada estado do ambiente; a taxa de aprendizado (α), um hiperparâmetro que controla o quanto novos dados substituem os dados antigos durante o processo de aprendizado; e do fator de desconto (γ) que determina a importância das recompensas futuras em comparação com as recompensas imediatas. Ele assume um valor entre 0 e 1 ($0 \leq \gamma \leq 1$) e influencia como o agente avalia as recompensas que receberá ao longo do tempo (SUTTON; BARTO, 2018).

2.9.1.1 Equação de Bellman

A equação de Bellman é de extrema importância dentro do contexto de *Q-Learning*, sendo utilizada para atualizar os valores Q com base nas recompensas recebidas e nas estimativas futuras de valores Q.

$$Q(s, a) \leftarrow Q(s, a) + \alpha [r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (3.10)$$

onde

- **s** é o estado atual
- **a** é a ação tomada
- **r** é a recompensa imediata recebida após a ação a
- **s'** é o próximo estado alcançado
- **α** é a taxa de aprendizado
- **γ** é o fator de desconto
- **$\max_{a'} Q(s', a')$** é o valor Q máximo esperado para o próximo estado s'.

A equação de Bellman descreve todos os comportamentos comentados anteriormente. A atualização dos valores Q levando em consideração a recompensa esperada futura, ponderada pelo fator de desconto γ , junto à recompensa imediata r.

O processo de aprendizado em Q-Learning envolve repetidas interações entre o agente e o ambiente. Em cada interação, o agente observa o estado s, escolhe uma ação “a” com base em uma política, executa a ação e observa a recompensa r e o próximo estado s'. Com essas informações, o valor Q do par (s,a) é atualizado conforme a equação de Bellman, de modo que o agente maximize a recompensa cumulativa ao longo do tempo (SUTTON; BARTO, 2018).

2.9.1.2 Algoritmo

A implementação do Q-Learning envolve a inicialização de uma tabela Q, onde cada entrada representa um par estado-ação (s, a) e armazena o valor Q associado. Inicialmente, todos os valores Q são definidos como zero ou atribuídos aleatoriamente. Além disso, definem-se os hiperparâmetros α (taxa de aprendizado) e γ (fator de desconto).

Durante o loop de interação com o ambiente, o agente interage com o ambiente em uma série de episódios. Cada episódio começa em um estado inicial e continua até atingir um estado terminal ou um número máximo de etapas. Em cada estado s, a ação a é selecionada usando uma política de exploração.

A ação “a” é executada, resultando em uma recompensa r e na transição para o novo estado s'. Os valores Q são então atualizados utilizando a equação de Bellman. Essa atualização considera a recompensa imediata r e a estimativa das recompensas futuras $\max_a Q(s', a')$.

O estado s' torna-se o novo estado atual e o processo é repetido até o final do episódio. Durante esse processo busca-se que o agente aprenda a política ótima π^* .

$$\pi^*(s) = \arg \max_a Q(s, a) \quad (3.11)$$

Para ser possível visualizar esse processo melhor, sem barreiras de sintaxe, um pseudocódigo representando o algoritmo descrito está presente no apêndice I.

2.9.2 Exemplo de aplicação

Para ilustrar o funcionamento do algoritmo, foi utilizado um ambiente simples: uma grade quadrada 4x4, composta por 16 estados numerados de 0 a 15 - a grade é enumerada sequencialmente por linhas de baixo para cima. O agente é posicionado aleatoriamente dentro da grade, e seu objetivo é alcançar o estado 13, a coordenada alvo. O código associado está apresentado no apêndice J.

O agente pode escolher uma dentre quatro possíveis ações em cada estado: "para cima", "para baixo", "para esquerda", ou "para direita". Cada ação move o agente de uma posição na grade e uma recompensa é atribuída para avaliar se a ação foi vantajosa. Ela pode assumir valor igual a 1, caso o próximo estado seja o alvo final, ou zero, em qualquer outra situação.

A tabela-Q possui dimensões de (16, 4), onde cada linha representa um estado, e cada coluna corresponde a uma das quatro ações possíveis. O valor armazenado em cada célula da tabela-Q indica o valor-Q, ou seja, a qualidade da ação naquele estado. Quanto maior o valor, mais eficaz é a ação naquele estado, em termos de alcançar o objetivo.

A tabela-Q é inicializada com zeros em todas as posições e os valores são atualizados a cada iteração, sendo isso que representa o aprendizado do modelo. Após 200 iterações do agente no ambiente, temos a tabela-Q final, representada pela Tabela 3.

Estado	Cima	Baixo	Esquerda	Direita
0	0,857375	0,950000	0,685058	0,912000
1	0,902500	1,000000	0,721954	0,472099
2	0,658464	0,758784	0,000000	0,857314
3	0,814506	0,902500	0,791459	0,892455
4	0,902493	0,902493	0,814502	0,902500
5	0,950000	0,950000	0,857375	0,857344
6	0,763031	0,566944	0,902500	0,812246
7	0,847077	0,853712	0,000000	0,857375
8	0,912000	0,857280	0,823009	0,950000
9	1,000000	0,902500	0,902500	0,902500
10	0,900271	0,829308	0,950000	0,685900
11	0,902500	0,807990	0,000000	0,895279
12	0,892417	0,902442	0,902211	1,000000
13	0,000000	0,000000	0,000000	0,000000
14	0,760002	0,890559	1,000000	0,866400
15	0,857068	0,855649	0,942400	0,950000

Tabela 3: tabela-Q contendo as recompensas associadas a cada ação em cada estado.

Os maiores valores nas células da tabela indicam que essas ações foram identificadas como as melhores para maximizar a recompensa. A tabela-Q permite que, independentemente do estado inicial do agente, ele encontre o caminho ideal até o objetivo (estado 13). Ao final do treinamento, o agente consegue navegar com sucesso pela grade, encontrando a solução ótima com base no aprendizado acumulado. Portanto, a melhor política para o cenário apresentado foi encontrada.

A figura 16 é um mapa dos caminhos percorridos pelo agente durante seu aprendizado. O caminho descrito em azul é a primeira tentativa e fica claro que, com a evolução do aprendizado, os trajetos vão ficando menores.

Vale ressaltar que os estados são os pares ordenados representados por inteiros, começando no estado 0 em (0, 0) e aumentando com passo 1, sempre da esquerda para a direita, de baixo para cima.




Figura 16: Mapa dos caminhos percorridos pelo agente durante seu aprendizado

É interessante observar o alcance desse algoritmo, aplicando exatamente ao mesmo contexto, mas a uma grade mais extensa - 103 lados, 10.609 possíveis estados, e objetivo sendo o 497.




Figura 17: Mapa dos caminhos percorridos pelo agente durante seu aprendizado – ampliado

3 MÉTODO

3.1 Aplicação de *Q-Learning* à equação de acoplamento

O projeto – disponível em <https://github.com/GSCotrim/Q-Learning-VIV> e nos apêndices – foi desenhado seguindo a arquitetura padrão de um modelo de aprendizado por reforço, como definido por Sutton e Barto (2018), dividido em ambiente e agente.

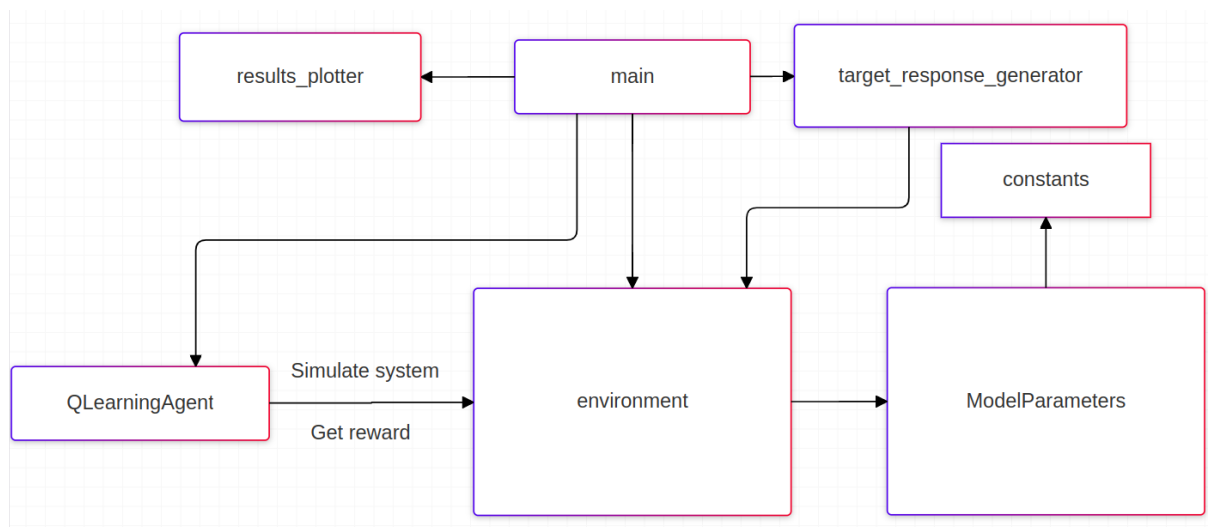


Figura 18: Relações de chamadas e dependência entre os componentes do modelo de *Q-Learning*.

O arquivo *main.py* (apêndice B) age como orquestrador, definindo a resposta esperada do modelo e iniciando o agente, definido por *QlearningAgent.py* (apêndice D).

O ambiente, definido por *environment.py* (apêndice C), segue o modelo de acoplamento fluido-estrutura proposto por Facchinetti, de Langre e Biolley (2004), descrito pelo sistema de equações diferenciais (3.6) resolvidas utilizando o “*Livermore Solver for Ordinary Differential Equations with Automatic method switching*” (LSODA), parte da biblioteca ODEPACK (HINDMARSH, 1983; PETZOLD, 1983). Com diferentes parâmetros, diferentes $y(t)$ e $q(t)$ são gerados. O agente fornece combinações de parâmetros (A , ϵ , ξ , γ , μ , δ , M - todos mapeados as suas respectivas variáveis no código, no apêndice A), o ambiente simula como o modelo

se comportaria e retorna uma recompensa, sendo esta o oposto do erro quadrático médio entre o comportamento simulado e o comportamento alvo.

O agente trabalha com estados e ações associadas. Cada estado é uma lista com os índices do vetor que contém os valores de cada um dos sete parâmetros a serem definidos. As ações representam uma mudança em um dos valores do estado, somando ou subtraindo um. A ação pode assumir qualquer valor inteiro entre 0 e 13 (inclusos), e é esse valor que determina qual posição do vetor de estado será afetada, assim como a forma em que será alterada.

Abstraindo a lógica do código neste momento, a maneira como o estado será afetado pela ação segue a regra abaixo.

Ação	Estado afetado
0	Estado[0] + 1
1	Estado[0] - 1
2	Estado[1] + 1
3	Estado[1] - 1
4	Estado[2] + 1
5	Estado[2] - 1
6	Estado[3] + 1
7	Estado[3] - 1
8	Estado[4] + 1
9	Estado[4] - 1
10	Estado[5] + 1
11	Estado[5] - 1
12	Estado[6] + 1
13	Estado[6] - 1

Tabela 4: Ação / Estado afetado

Tendo um estado definido como [5, 4, 3, 13, 2, 12, 8] e uma ação igual a 5, teríamos o próximo estado como [5, 4, 2, 13, 2, 12, 8]. Se esse fosse o estado ótimo, significaria que os melhores valores encontrados para os parâmetros estariam nos índices [5, 4, 2, 13, 2, 12, 8] do vetor responsável por guardar os valores dos parâmetros. Para maiores detalhes sobre a lógica por trás desse funcionamento, remeter ao apêndice D.

A lógica de recompensa do modelo utiliza o erro quadrático médio entre a saída esperada e aquela gerada. Atribui-se um valor negativo a esse erro, sendo que quanto maior o erro absoluto, maior a penalização sofrida pelo modelo. No cenário proposto, a recompensa máxima é zero.

$$Recompensa = -\frac{1}{n} \sum_{i=1}^n \left(y_{simulation}(t_i) - y_{target}(t_i) \right)^2 \quad (3.12)$$

Quanto aos componentes restantes, temos *ModelParameters.py* como uma classe de estrutura de dados com o propósito de facilitar o trânsito de dados (apêndice E). O arquivo *constants.py* contém valores de parâmetros retirados da literatura (apêndice F). Em *results_plotter.py* fica concentrada a lógica de geração de gráficos (apêndice H) e *target_response_generator.py* é responsável por gerar os dados utilizados para o treinamento do modelo (apêndice G).

3.1.1 Dados utilizados no treinamento do modelo

Como mencionado no item anterior, os dados utilizados para o treinamento do modelo foram gerados computacionalmente devido à falta de dados experimentais. Foi gerado um sinal sintético, adicionado de ruído branco, baseado em dados da literatura.

Os parâmetros utilizados para gerar o sinal através do sistema de equações (3.1) seguem abaixo:

Parâmetro	Valor
Coeficiente de van der Pol (ϵ)	0.4
Coeficiente de acoplamento (A)	10.0
Coeficiente de amortecimento estrutural (ξ)	0.07e-2
Coeficiente de amortecimento fluido (γ)	0.47746
Relação de massa adimensional (μ)	2.8274
Frequência angular reduzida (δ)	0.9381
Número de massa (M)	0.0168

Tabela 5: Valores utilizados na geração de sinal de entrada para o modelo de aprendizado de máquina.

3.1.2 Ferramentas e tecnologias

A implementação do modelo foi realizada em Python devido à vasta aplicabilidade da linguagem no campo de aprendizado de máquina. A biblioteca NumPy foi utilizada para manipulação de matrizes, SciPy para resolver o sistema de equações diferenciais, tqdm para acompanhamento visual do progresso do treinamento e Matplotlib para visualização de dados.

3.1.3 Aplicações

Para validar o modelo serão feitas duas aplicações: ambas abordando oscilações mais próximas daquilo observado experimentalmente, com efeitos não-lineares, mas uma levará em consideração ruídos no sinal de entrada e outra não, buscando analisar quão bem o modelo se adapta aos ruídos naturais às situações práticas.

Para cada uma das aplicações rodou-se três vezes, com diferentes números de episódios – 500, 1000, 2000, 3500 e 5000. Serão apresentados os melhores resultados dentre aqueles rodados.

4 RESULTADOS

Neste capítulo serão apresentados os resultados obtidos a partir da modelagem descrita neste estudo, atrelada à proposta de Facchinetti, de Langre e Biolley (2004). No tópico 4.1 é demonstrada uma aplicação ao oscilador sem ruídos no sinal de entrada. No tópico 4.2 serão apresentados os resultados da aplicação ao oscilador com ruídos.

Em ambos os cenários, independente do número de episódios rodados, observou-se que o agente encontrou parâmetros que, aplicados ao modelo de Facchinetti, de Langre e Biolley (2004), geraram simulações com comportamento muito próximo ao do alvo, no entanto, os valores dos parâmetros em si não mostraram-se tão próximos daqueles presentes na literatura – como apresentado na tabela 7.

Parâmetro	Valor	Referência
Coefficiente de acoplamento (A_num)	12.0	Facchinetti, de Langre e Biolley (2004)
Coefficiente de van der Pol (epsilon_num)	0.3	Facchinetti, de Langre e Biolley (2004)
Coefficiente de amortecimento estrutural (xi_num)	0.0007	Ássi (2010)
Frequência estrutural (fs)	0.3	Ássi (2010)
Diâmetro do cilindro (D)	0.05	Ássi (2010)
Densidade do fluido (rho)	1000.0	Ássi (2010)
Relação de massa adimensional (mstar)	2.6	Ássi (2010)
Número de Strouhal (St)	0.2	Discutido no tópico 2.4 deste trabalho.
Coefficiente de massa adicionada (Cm)	1.0	Faltinsen (1993)
Coefficiente de lift (CLO)	0.3	Violette, de Langre e Szydlowski (2007)
Coefficiente de arrasto oscilatório (CDosc)	1.2	Violette, de Langre e Szydlowski (2007)
Frequência angular estrutural (Omegas)	1.8849	Facchinetti, de Langre e Biolley (2004)
Velocidade do fluxo (Uinf)	0.0799	Facchinetti, de Langre e Biolley (2004)
Frequência angular do fluxo (Omegaf)	2.0094	Facchinetti, de Langre e Biolley (2004)
Frequência angular reduzida (delta_num)	0.9381	Facchinetti, de Langre e Biolley (2004)
Coefficiente de amortecimento fluido (gamma_num)	0.4775	Facchinetti, de Langre e Biolley (2004)
Massa do fluido (mf)	1.9635	Facchinetti, de Langre e Biolley (2004)
Massa estrutural (ms)	5.1051	Facchinetti, de Langre e Biolley (2004)
Relação de massa adimensional (mu_num)	2.8274	Facchinetti, de Langre e Biolley (2004)
Número de massa (M_num)	0.0168	Facchinetti, de Langre e Biolley (2004)

Tabela 6: Valores de parâmetros encontrados na literatura

Simulação	Erro Médio	Desvio Padrão
500 - sem ruído	21,43%	87,47%
1000 - sem ruído	55,13%	119,39%
2000 - sem ruído	43,62%	119,08%
3500 - sem ruído	79,49%	138,79%
5000 - sem ruído	67,31%	128,37%
500 - com ruído	43,14%	63,61%
1000 - com ruído	32,90%	116,48%
2000 - com ruído	77,14%	82,29%
3500 - com ruído	43,14%	65,18%
5000 - com ruído	83,13%	77,13%

Tabela 7: Comparação dos parâmetros obtidos pelo modelo em relação à literatura.

Os gráficos de recompensa comportam-se como esperado, apresentando valores maiores com o passar dos episódios. Em geral há uma concentração de picos negativos durante os episódios iniciais, indicando a maior predisposição do agente à exploração de novas ações. O aumento nas recompensas indica um conhecimento maior sobre o ambiente por parte do agente e mais foco na exploração de ações já conhecidas e bem avaliadas.

O aumento no número de episódios parece ter influência na qualidade dos resultados, com o modelo alcançando a simulação mais fiel ao alvo ao ser treinado com 2000 e 3500 episódios em ambos os casos. Contudo, o ganho marginal diminui à medida que o número de episódios aumenta, o que é esperado, além de observar-se um crescimento acentuado no tempo de processamento, embora de forma irregular, devido às variações no hardware utilizado na simulação.

Calculou-se o aumento percentual no tempo de execução entre cada par consecutivo de experimentos considerando a diferença entre eles e dividindo pelo tempo de execução do inicial.

Para o caso sem ruído identificou-se um aumento percentual médio de 79,63% entre experimentos, sendo o maior entre o de 2000 episódios e 3500 (127,8%) e o menor entre 3500 e 5000 (8,0%).




Figura 19: Tempo de Processamento por Número de Episódios - Treinamento sem ruído

Para o caso sem ruído identificou-se um aumento percentual médio de 61,0% entre experimentos, sendo o maior entre o de 2000 episódios e 3500 (127,7%) e o menor entre 500 e 1000 (8,1%).




Figura 20: Tempo de Processamento por Número de Episódios - Treinamento com ruído

4.1 Modelo de acoplamento fluido-estrutura sem ruídos no sinal de entrada.

4.1.1 500 episódios




Figura 21: Oscilação simulada versus oscilação alvo - 500 episódios - sem ruído




Figura 22: Evolução das recompensas durante o treinamento - 500 episódios - sem ruído

Parâmetro	Valor
Coeficiente de van der Pol (ϵ)	0.34231
Coeficiente de acoplamento (A)	1.0
Coeficiente de amortecimento estrutural (ξ)	0.00085
Coeficiente de amortecimento fluido (γ)	0.85385
Relação de massa adimensional (μ)	2.73846
Frequência angular reduzida (δ)	0.84615
Número de massa (M)	0.06192

Tabela 8: Parâmetros - 500 episódios - sem ruído

4.1.2 1000 episódios




Figura 23: Oscilação simulada versus oscilação alvo - 1000 episódios - sem ruído




Figura 24: Evolução das recompensas durante o treinamento - 1000 episódios - sem ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.92692
Coefficiente de acoplamento (A)	5.38462
Coefficiente de amortecimento estrutural (ξ)	0.00100
Coefficiente de amortecimento fluido (γ)	0.63462
Relação de massa adimensional (μ)	1.23077
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.07715

Tabela 9: Parâmetros - 1000 episódios - sem ruído

4.1.3 2000 episódios




Figura 25: Oscilação simulada versus oscilação alvo - 2000 episódios - sem ruído




Figura 26: Evolução das recompensas durante o treinamento - 2000 episódios - sem ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.92692
Coefficiente de acoplamento (A)	6.84615
Coefficiente de amortecimento estrutural (ξ)	0.00092
Coefficiente de amortecimento fluido (γ)	0.26923
Relação de massa adimensional (μ)	0.47692
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.07715

Tabela 10: Parâmetros - 2000 episódios - sem ruído

4.1.4 3500 episódios

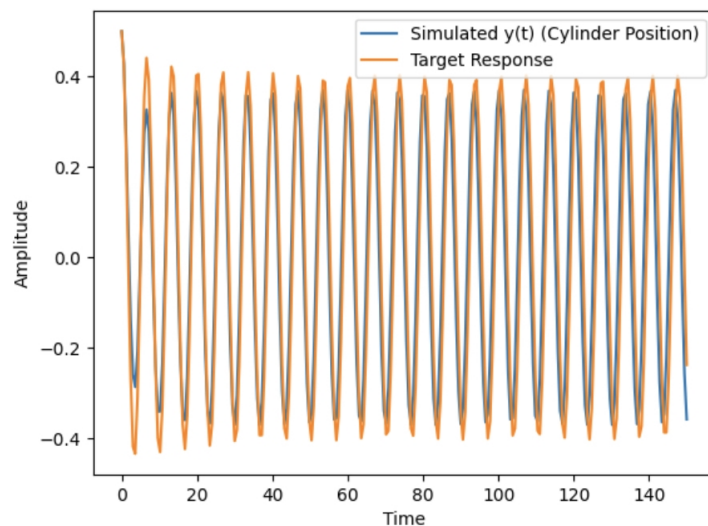


Figura 27: Oscilação simulada versus oscilação alvo - 3500 episódios - sem ruído




Figura 28: Evolução das recompensas durante o treinamento - 3500 episódios
- sem ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.85385
Coefficiente de acoplamento (A)	2.46154
Coefficiente de amortecimento estrutural (ξ)	0.00001
Coefficiente de amortecimento fluido (γ)	0.78077
Relação de massa adimensional (μ)	1.23077
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.09238

Tabela 11: Parâmetros - 3500 episódios - sem ruído

4.1.5 5000 episódios




Figura 29: Oscilação simulada versus oscilação alvo - 5000 episódios - sem ruído




Figura 30: Evolução das recompensas durante o treinamento - 5000 episódios - sem ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.85385
Coefficiente de acoplamento (A)	3.92308
Coefficiente de amortecimento estrutural (ξ)	0.00047
Coefficiente de amortecimento fluido (γ)	1.0
Relação de massa adimensional (μ)	1.60769
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.08477

Tabela 12: Parâmetros - 5000 episódios - sem ruído

4.2 Modelo de acoplamento fluido-estrutura

4.2.1 500 episódios

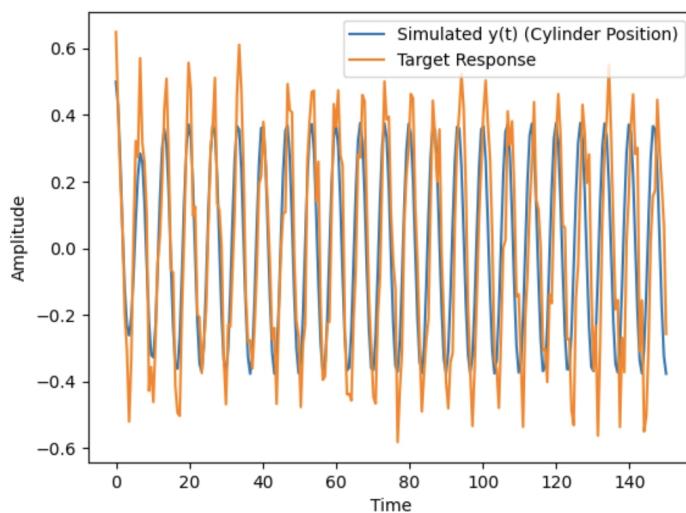


Figura 31: Oscilação simulada versus oscilação alvo - 500 episódios - com ruído




Figura 32: Evolução das recompensas durante o treinamento - 500 episódios - com ruído

Parâmetro	Valor
Coeficiente de van der Pol (ϵ)	0.92692
Coeficiente de acoplamento (A)	20.00000
Coeficiente de amortecimento estrutural (ξ)	0.00100
Coeficiente de amortecimento fluido (γ)	0.56154
Relação de massa adimensional (μ)	1.60769
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.03146

Tabela 13: Parâmetros - 500 episódios - com ruído

4.2.2 1000 episódios




Figura 33: Oscilação simulada versus oscilação alvo - 1000 episódios - com ruído




Figura 34: Evolução das recompensas durante o treinamento - 1000 episódios - com ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.56154
Coefficiente de acoplamento (A)	11.23077
Coefficiente de amortecimento estrutural (ξ)	0.00054
Coefficiente de amortecimento fluido (γ)	0.63462
Relação de massa adimensional (μ)	0.85385
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.07715

Tabela 14: Parâmetros - 1000 episódios - com ruído

4.2.3 2000 episódios




Figura 35: Oscilação simulada versus oscilação alvo - 2000 episódios - com ruído.




Figura 36: Evolução das recompensas durante o treinamento - 2000 episódios - com ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.56154
Coefficiente de acoplamento (A)	14.15385
Coefficiente de amortecimento estrutural (ξ)	0.00016
Coefficiente de amortecimento fluido (γ)	1.00000
Relação de massa adimensional (μ)	1.60769
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.06192

Tabela 15: Parâmetros - 2000 episódios - com ruído

4.2.4 3500 episódios




Figura 37: Oscilação simulada versus oscilação alvo - 3500 episódios - com ruído




Figura 38: Evolução das recompensas durante o treinamento - 3500 episódios - com ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.78077
Coefficiente de acoplamento (A)	17.07692
Coefficiente de amortecimento estrutural (ξ)	0.00062
Coefficiente de amortecimento fluido (γ)	0.70769
Relação de massa adimensional (μ)	1.60769
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.04669

Tabela 16: Parâmetros - 3500 episódios - com ruído

4.2.5 5000 episódios




Figura 39: Oscilação simulada versus oscilação alvo - 5000 episódios - com ruído




Figura 40: Evolução das recompensas durante o treinamento - 5000 episódios - com ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.19615
Coefficiente de acoplamento (A)	1.00000
Coefficiente de amortecimento estrutural (ξ)	0.00009
Coefficiente de amortecimento fluido (γ)	0.12308
Relação de massa adimensional (μ)	0.47692
Frequência angular reduzida (δ)	0.84615
Número de massa (M)	0.06192

Tabela 17: Parâmetros - 5000 episódios - com ruído

5 CONCLUSÃO

Concluimos a validade da utilização de aprendizado de máquina – neste caso aprendizado por reforço – na análise da questão, chegando em bons resultados, sem a necessidade de passar extensivamente por literaturas e cálculos para obter-se os parâmetros da equação. Tendo uma ideia dos intervalos fisicamente lógicos de cada parâmetro, foi possível obter bons valores, de maneira rápida e direta. Ademais, validou-se certa flexibilidade do modelo de aprendizado por reforço, capaz de produzir comportamentos próximos dos sinais de entrada, sejam sinais com ou sem ruídos.

5.1 Contribuições do trabalho

O presente estudo reforça o modelo de acoplamento fluido estrutura de Facchinetti, de Langre e Biolley (2004), utilizando acoplamento por aceleração.

Além disso, reforça que aprendizado de máquina pode e deve ser utilizado em estudos acadêmicos, dado que reduz o esforço e encontra bons resultados em análises variadas.

REFERÊNCIAS

ÁSSI, Gustavo R. S. **Estudo experimental do efeito de interferência no escoamento ao redor de cilindros alinhados**. 2005. Dissertação (Mestrado em Engenharia Mecânica de Energia de Fluidos) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2005. doi:10.11606/D.3.2005.tde-11012006-154457. Disponível em: <<https://teses.usp.br/teses/disponiveis/3/3150/tde-11012006-154457/pt-br.php>> Acesso em: 06 abr. 2024.

_____. **Mechanisms for flow-induced vibration of interfering bluff bodies**. Orientador: Professor Peter Bearman. 2009. 228 p. Thesis (Doctor of Philosophy (PhD) of Engineering) - Imperial College London (University of London), London, England, 2009. ISBN:0000 00042681 6745. Disponível em: <https://www.academia.edu/4848205/Mechanisms_for_flow_induced_vibration_of_interfering_bluff_bodies_PhD_Thesis_2009> . Acesso em: 28 abr. 2024.

ÁSSI, Gustavo R. S.; BEARMAN, P. W.; MENEHINI, J. R. (2010). On the wake-induced vibration of tandem circular cylinders: the vortex interaction excitation mechanism. **Journal of Fluid Mechanics**, 661, pp 365401 doi:10.1017/S0022112010003095. Disponível em: <<https://repositorio.usp.br/item/002133372>>. Acesso em 06 nov. 2024.

BARATA, Germana. Pesquisa avalia rotina de mergulhadores em águas profundas. **Cienc. Cult.**, São Paulo , v. 55, n. 2, p. 06, Apr. 2003 . Disponível em: <http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252003000200006&lng=en&nrm=iso> . Acesso em: 10 mar. 2024.

BEARMAN, P. W. Vortex shedding from oscillating bluff bodies. **Annual Review of Fluid Mechanics** , California / USA, v. Vol. 16, ed. (Volume publication date January 1984), p. 195-222, 1984. DOI <https://doi.org/10.1146/annurev.fl.16.010184.001211>. Disponível em: <<https://www.annualreviews.org/doi/10.1146/annurev.fl.16.010184.001211>> . Acesso em: 06 abr. 2024.

BIMBATO, Alex Mendonça. **Estudo de escoamentos turbulentos em torno de um corpo rombudo de superfície hidraulicamente lisa ou rugosa utilizando o método de vórtices discretos**. Orientador: Prof. Dr. Miguel Hiroo Hirata. 2012. 165 p. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Itajubá - UNIFEI, Itajubá, MG, 2012. Disponível em: <<https://repositorio.unifei.edu.br/jspui/handle/123456789/1160>>. Acesso em: 06 abr. 2024.

BRASIL (Brasil). Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). **Boletim da Produção de Petróleo e Gás Natural**. 163. ed. Brasil, 03/2024. Disponível em: <<https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/boletins-anp/boletins/arquivos-bmppgn/2024/marco.pdf>> . Acesso em: 10 mar. 2024.

CARMO, Bruno Souza. **Estudo numérico do escoamento ao redor de cilindros alinhados**. 2005. Dissertação (Mestrado em Engenharia Mecânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2005. doi:10.11606/D.3.2005.tde-21072005-144943. Disponível em: <<https://teses.usp.br/teses/disponiveis/3/3132/tde-21072005-144943/pt-br.php>>. Acesso em: 28 abr. 2024.

CBIE (Brasil). **O que são os Custos de Extração do Petróleo?**. [S. l.]: CBIE – Centro Brasileiro de Infraestrutura, 15 nov. 2019. Disponível em: <<https://cbie.com.br/artigos/o-que-sao-os-custos-de-extracao-do-petroleo/>> . Acesso em: 10 mar. 2024.

CICOLIN, Murilo Marangon. **Supressão da vibração induzida por vórtices de cilindros com malha permeável**. 2015. Dissertação (Mestrado em Engenharia Naval e Oceânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2015. doi:10.11606/D.3.2016.tde-07032016-102934. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/3/3135/tde-07032016-102934/pt-br.php>> Acesso em: 10 mar. 2024.

FACCHINETTI, M. L.; de Langre, E. de; BIDDLE, F. Coupling of structure and wake oscillators in vortex-induced vibrations. **Journal of Fluids and Structures**, [s. l.], ano 2004, v. 19, n. 2, p. 123-140, 2004. DOI <https://doi.org/10.1016/j.jfluidstructs.2003.12.004>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0889974603001853>>. Acesso em: 10 mar. 2024.

FALTINSEN, O. M. **Sea loads on ships and offshore structures**. Reprint ed. Cambridge: Cambridge University Press, 1993.

FONSECA, Fábio Basaglia. **Estudo do escoamento ao redor de cilindros elípticos**. Orientador: Prof. Dr. Edson Del Rio Vieira. 2013. 97 p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Estadual Paulista - UNESP, Ilha Solteira, SP, 2013. Disponível em: <<https://repositorio.unesp.br/handle/11449/88849?show=full>>. Acesso em: 06 abr. 2024.

GARNIER, Paul; VIQUERAT, Jonathan; RABAULT, Jean; LARCHER, Aurélien; KUHNLE, Alexander; HACHEM, Elie. A review on deep reinforcement learning for fluid mechanics. **Computers & Fluids**, [s. l.], v. 225, p. 104973, 2021. DOI <https://doi.org/10.1016/j.compfluid.2021.104973>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0045793021001407?via%3Dihub>>. Acesso em: 01 jul. 2024.

GONÇALVES, Rodolfo Trentin. **Vibrações induzidas pela emissão de vórtices em cilindros com baixa razão de aspecto**. 2013. Tese (Doutorado em Engenharia Naval e Oceânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2013. doi:10.11606/T.3.2013.tde-08072014-104328. Disponível em:

<<https://teses.usp.br/teses/disponiveis/3/3135/tde-08072014-104328/pt-br.php>>.
Acesso em: 28 abr. 2024.

HINDMARSH, A. C., “**ODEPACK, A Systematized Collection of ODE Solvers**”
IMACS Transactions on Scientific Computation, Vol 1., pp. 55-64, 1983.

JERNELÖV, A. The threats from oil spills: now, then, and in the future. **Ambio**, [s. l.], v. 39, n. 5-6, p. 353-366, 2010. DOI <https://doi.org/10.1007/s13280-010-0085-5>.
Disponível em: <https://link.springer.com/article/10.1007/s13280-010-0085-5>. Acesso em: 18 out. 2024.

KAEHLING, L. P.; LITTMAN, M. L.; MOORE, A. W. Reinforcement learning: A survey. **Journal of Artificial Intelligence Research**, v. 4, p. 237-285, 1996. DOI: <https://doi.org/10.1613/jair.301>. Disponível em: <https://www.jair.org/index.php/jair/article/view/10166>. Acesso em: 01 jul. 2024.

KHALAK, A.; WILLIAMSON, C.H.K. Motions , forces and mode transitions in Vortex-Induced Vibrations at low mass-damping. **Journal of Fluids and Structures**, [s. l.], v. 13, n. 7-8, p. 813-851, 1999. DOI doi.org/10.1006/jfls.1999.0236, ISSN 0889-9746.
Disponível em:
<<https://www.sciencedirect.com/science/article/abs/pii/S0889974699902360>>.
Acesso em: 25 mai. 2024.

MENEGHINI, Julio Romano; ASSI, Gustavo Roque da Silva; ORSELLI, Reinaldo Marcondes; CARMO, Bruno Souza; SALTARA, Fábio; GIORIA, Rafael dos Santos; BONATTO, André dos Santos; TSILOUFAS , Stergios Pericles. **Ruído e vibração induzidos por vórtices**. In: **TURBULÊNCIA**. Rio de Janeiro: Associação Brasileira de Engenharia e Ciências Mecânicas – ABCM, 2010. cap. 7.

MORAIS, José Mauro de. **Petróleo em águas profundas**: uma história tecnológica da Petrobras na exploração e produção offshore. Brasília: Ipea, 2013. 424 p. ISBN 978-85-7811-159-5. Disponível em: <https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=18251>. Acesso em: 10 mar. 2024.

NORBERG, C. Flow around a circular cylinder: aspects of fluctuating lift. **Journal of Fluids and Structures**, [s. l.], v. 15, n. 3-4, p. 459-469, 2001. DOI doi.org/10.1006/jfls.2000.0367. Disponível em:
<<https://www.sciencedirect.com/science/article/abs/pii/S0889974600903670>>.
Acesso em: 19 mai. 2024.

ORTIZ NETO, José Benedito; DALLA COSTA, Armando João. A Petrobrás e a exploração de Petróleo Offshore no Brasil: um approach evolucionário. **Revista Brasileira de Economia**, [s. l.], v. 61, n. 1, p. 95-109, Jan-Mar 2007. DOI doi.org/10.1590/S0034-71402007000100006. Disponível em:
<<https://www.scielo.br/j/rbe/a/bbJ3zjwJBfYhkhtrtMQrvbF/?lang=pt>>. Acesso em: 10 mar. 2024.

PEREIRA, Felipe Rateiro. **Investigação das vibrações induzidas pela emissão de vórtices em modelos reduzidos de riser lançados em catenária**. 2014. Tese (Doutorado em Engenharia Naval e Oceânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2014. DOI:10.11606/T.3.2016.tde-04022016-183409. Disponível em: <<https://teses.usp.br/teses/disponiveis/3/3135/tde-04022016-183409/pt-br.php>>. Acesso em: 25 mai. 2024.

PETZOLD, L “Automatic selection of methods for solving stiff and nonstiff systems of ordinary differential equations”, **SIAM Journal on Scientific and Statistical Computing**, Vol. 4, No. 1, pp. 136-148, 1983.

RIBEIRO, Paulo Augusto Rodrigues. **Desprendimento de vórtices e controle em esteira de cilindros por simulação numérica direta**. Orientador: Prof. Dr. Edith Beatriz Camaño Schettini. 2002. 109 p. Dissertação (Mestre em Recursos Hídricos e Saneamento Ambiental.) - Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Porto Alegre, RS, 2002. Disponível em: <<https://lume.ufrgs.br/handle/10183/3214?show=full>>. Acesso em: 06 abr. 2024.

SILVA, Vinicius Girardi. **Estudo numérico da vibração induzida por vórtices em um corpo cilíndrico**. 2013. Dissertação (Mestrado em Engenharia Mecânica de Energia de Fluidos) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2013. doi:10.11606/D.3.2013.tde-26062014-112828. Disponível em: <<https://teses.usp.br/teses/disponiveis/3/3150/tde-26062014-112828/en.php>>. Acesso em: 06 abr. 2024

SUCENA, Marcelo Prado; MARCONDES, Bárbara Moraes; COUTO, Tatiane Barbosa Lima. A visão proativa da manutenção em sistema de exploração de petróleo. **Revista Gestão Industrial**, Ponta Grossa, v. 16, n. 4, p. 206-236, Out.Dez. 2020. DOI doi.org/10.3895/gi.v16n4.11627. Disponível em: <<https://periodicos.utfpr.edu.br/revistagi/article/view/11627>>. Acesso em: 10 mar. 2024

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. 2. ed. Cambridge: MIT Press, 2018.

TERREIRO, João Pedro de Andrade. **Modelo semi-empírico para vibração por vórtices com interferência**. Orientador: Gioria, Rafael dos Santos. 2019. 75 p. TCC (Graduação - Engenharia de Petróleo) - Escola Politécnica da Universidade de São Paulo, Santos – SP, 2019. Disponível em: <<https://bdta.aguia.usp.br/item/002992629>>. Acesso em: 10 mar. 2024.

VAN DYKE, Milton. **An Album of Fluid Motion**. Fourth print. ed. Stanford, California: The Parabolic Press, 1988. 176 p. ISBN 0-915760-02-9.

VIOLETTE, R.; de Langre, E. de; SZYDLOWSKI, J. Computation of vortex-induced vibrations of long structures using a wake oscillator model: Comparison with DNS and experiments. **Computers & Structures**, [s. l.], ano 2007, v. 85, n. 11-14, p. 1134-1141, June–July 2007. DOI doi.org/10.1016/j.compstruc.2006.08.005 - ISSN

0045-7949. Disponível em:

<<https://www.sciencedirect.com/science/article/abs/pii/S004579490600229X>>.

Acesso em: 28 abr. 2024.

WATKINS, C. J. C. H.; DAYAN, P. Q-learning. **Machine Learning**, v. 8, n. 3-4, p. 279-292, 1992. DOI: <https://doi.org/10.1007/BF00992698>. Disponível em:

<https://link.springer.com/article/10.1007/BF00992698>. Acesso em: 01 jul. 2024.

WILLIAMSON, C.H.K.; GOVARDHAN, R. Vortex-Induced Vibrations. **Annual Review of Fluid Mechanics**, [s. l.], v. 36, n. 1, p. 413-455, 2004. DOI

doi.org/10.1006/jfls.1999.0236. Disponível em:

<<https://www.annualreviews.org/doi/abs/10.1146/annurev.fluid.36.050802.122128>>.

Acesso em: 25 mai. 2024.

ZDRAVKOVICH, M.M. Conceptual Overview of Laminar and Turbulent Flows Past Smooth and Rough Circular Cylinders. **Wind Engineers: JAWE** (Japan Association for Wind Engineering), Kyoto, Japan, ano 1988, v. 1988, n. Issue 37, ed. Released September 28, 2010, p. Pages 93-102, 28 set. 2010. DOI

https://doi.org/10.5359/jawe.1988.37_93. Disponível em:

<https://www.jstage.jst.go.jp/article/jawe1982/1988/37/1988_37_93/article>. Acesso em: 28 abr. 2021.

APÊNDICE A - MAPEAMENTO DE VARIÁVEIS DO CÓDIGO E PARÂMETROS DO MODELO DE ACOPLAMENTO FLUIDO-ESTRUTURA

Parâmetro	Variável
Coeficiente de van der Pol (ϵ)	epsilon_num
Coeficiente de acoplamento (A)	a_num
Coeficiente de amortecimento estrutural (ξ)	xi_num
Coeficiente de amortecimento fluido (γ)	fluid_damping_coefficient_gamma
Relação de massa adimensional (μ)	nondimensional_mass_ratio_mu
Frequência angular reduzida (δ)	structure_reduced_angular_frequency_delta
Número de massa (M)	mass_number_M

APÊNDICE B - MAIN.PY

```

import numpy as np

from q_learning import QLearningAgent

from src.target_response_generator import
build_target_response

from src.environment import simulate_system_param

from src.results_plotter import plot_results

def run_q_learning_process():
    time = np.linspace(0, 150, 250 + 1)
    target_response = build_target_response(time)

    agent = QLearningAgent(
        alpha=0.8,  ## learning rate
        gamma=0.95,  ## discount parameter
        epsilon=0.25,  ## exploration probability initially
        epsilon_decay=0.9995,  ## decay of exploration
probability
        epsilon_min=0.05,  ## final asymptotic value of
exploration probability
    )

    total_rewards, q_table = agent.run(time, target_response,
episodes=1500, steps_per_ep=10)

    ijk = np.unravel_index(q_table.argmax(), q_table.shape)
    print(f"Final STATE: {ijk}")

```

```

final_params = np.array([
    agent.params_range[0, ijk[0]],
    agent.params_range[1, ijk[1]],
    agent.params_range[2, ijk[2]],
    agent.params_range[3, ijk[3]],
    agent.params_range[4, ijk[4]],
    agent.params_range[5, ijk[5]],
    agent.params_range[6, ijk[6]]
])

params_map = {
    'epsilon_num': final_params[0],
    'a_num': final_params[1],
    'xi_num': final_params[2],
    'fluid_damping_coefficient_gamma': final_params[3],
    'nondimensional_mass_ratio_mu': final_params[4],
    'structure_reduced_angular_frequency_delta':
final_params[5],
    'mass_number_M': final_params[6]
}

print(params_map)

simulated_response = simulate_system_param(final_params,
time)

plot_results(total_rewards, time, simulated_response,
target_response)

if __name__ == "__main__":
    run_q_learning_process()

```

APÊNDICE C - ENVIRONMENT.PY

```

import numpy as np

from scipy.integrate import odeint

from src.ModelParameters import ModelParameters

# oscilador de Facchinetti com van der Pol

def cylinder_wake_oscillator(x, t, csi, delta, gamma, mu,
epsilon, M, MMinv):

    # 4 positions x = [ y, ydot, q, qdot ]

    BB = np.array([[0.0, 1.0, 0, 0],
                    [-delta ** 2, -(2.0 * csi * delta + gamma /
mu), M, 0.0],
                    [0.0, 0.0, 0.0, 1.0],
                    [0, 0, -1, -epsilon * (x[2] ** 2.0 - 1.0)]])

    ## MM inv eh definido com parametros A

    res = MMinv.dot(BB.dot(x))

    return res

def simulate_system_param(params, ts):

    model_parameters = ModelParameters(epsilon_num = params[0],
a_num = params[1],
xi_num = params[2],

fluid_damping_coefficient_gamma = params[3],

nondimensional_mass_ratio_mu = params[4],

structure_reduced_angular_frequency_delta = params[5],

```



```

mass_number_M =
params[6]

)

# matrix for van der pol - depends on A_num == params[1]
MM = np.eye(4)
MM[3, 1] = -float(model_parameters.a_num)
MMinv = np.linalg.inv(MM)

# call ODE solver
xs = ode_solver(ts, model_parameters.xi_num,

model_parameters.structure_reduced_angular_frequency_delta,

model_parameters.fluid_damping_coefficient_gamma,

model_parameters.nondimensional_mass_ratio_mu,
                    model_parameters.epsilon_num,
                    model_parameters.mass_number_M,
                    MMinv
                )

return xs[:, [0, 2]] # this returns y and q

def compute_reward(simulated_response, target_response):
    simulated_y = simulated_response[:, 0]
    mse = np.mean((simulated_y - target_response) ** 2)
    reward = -mse
    return reward

```

```

def ode_solver(ts, xi_num,
structure_reduced_angular_frequency,
fluid_damping_coefficient, nondimensional_mass_ratio,

                epsilon_num, mass_number_M, MMinv):

return odeint(

    cylinder_wake_oscillator,

    (.5, 1e-10, 1e-10, 1e-10), # initial_conditions

    ts,

    args=(

        xi_num, structure_reduced_angular_frequency,

        fluid_damping_coefficient,

        nondimensional_mass_ratio,

        epsilon_num,

        mass_number_M,

        MMinv)

    )

```

APÊNDICE D - Q_LEARNING.PY

```

import numpy as np

from tqdm import tqdm

from environment import compute_reward, simulate_system_param

class QLearningAgent:

    def __init__(self, alpha, gamma, epsilon, epsilon_decay,
epsilon_min, initial_conditions=(.5, 1e-10, 1e-10, 1e-10),
q_table=None):

        self.alpha = alpha

        self.gamma = gamma

        self.epsilon = epsilon

        self.epsilon_min = epsilon_min

        self.epsilon_decay = epsilon_decay

        self.initial_conditions = initial_conditions

        self.n_params = 7

        self.n_steps = 14

        self.epsilon_range = np.arange(0.05, 1.00 + 1e-5, (1 -
0.05) / (self.n_steps - 1))

        self.A_range = np.arange(1.0, 20.0 + 1e-5, (20.0 - 1.0)
/ (self.n_steps - 1))

        self.xi_num_range = np.arange(1.0e-5, 1.0e-3 + 1e-5,
(1.0e-3 - 1.0e-5) / (self.n_steps - 1))

        self.fluid_damping_coefficient_gamma_range =
np.arange(0.05, 1.0 + 1e-5, (1.0 - 0.05) / (self.n_steps - 1))

        self.nondimensional_mass_ratio_mu_range =
np.arange(0.1, 5.0 + 1e-5, (5.0 - 0.1) / (self.n_steps - 1))

        self.structure_reduced_angular_frequency_delta_range =
np.linspace(0.5, 2.0, self.n_steps)

```

```

        self.mass_number_M_range = np.arange(1e-3, 1e-1 + 1e-5,
(1e-1 - 1e-3) / (self.n_steps - 1))

        self.params_range = np.stack((self.epsilon_range,

                                        self.A_range,

                                        self.xi_num_range,

self.fluid_damping_coefficient_gamma_range,

self.nondimensional_mass_ratio_mu_range,

self.structure_reduced_angular_frequency_delta_range,

                                        self.mass_number_M_range

                                        ))

        self.n_actions = 2 * self.n_params

        self.n_states = len(self.params_range)

        self.q_table = self.__initialize_q_table() if q_table
is None else q_table

    def generate_new_state(self, state, action):

        if state.size != self.n_params:

            raise ValueError(f"Estado esperado com
{self.n_params} parâmetros, mas recebeu {len(state)}
parâmetros.")

        if action < 0 or action > (2 * self.n_params - 1):

            raise ValueError(f"Ação esperada pertence a [0,{2 *
self.n_params - 1}] mas ação={action}.")

        new_state = state.copy()

        dir_action = 1 if action % 2 else -1

        which_param = action // 2

```

```

        new_state[which_param] = (
            (state[which_param] // self.n_steps * self.n_steps
+ (
                state[which_param] % self.n_steps +
self.n_steps - 1) % self.n_steps)
            if (dir_action > 0)
                else (state[which_param] // self.n_steps *
self.n_steps + (state[which_param] + 1) % self.n_steps)
        )
        return new_state

    def __initialize_q_table(self):
        dimensions = (self.n_steps,) * self.n_params +
(self.n_actions,)
        return np.zeros(dimensions) - 1

    def __select_action(self, state):
        if np.random.uniform() < self.epsilon:
            return np.random.randint(0, 2 * self.n_params)
        else:
            q_state =
self.q_table[tuple(state[:self.n_params])]
            return np.argmax(q_state)

    def __update_q_value(self, state, action, reward,
next_state):
        best_next_q_action =
self.q_table[tuple(next_state[:self.n_params])].max()
        self.q_table[tuple(state[:self.n_params]) + (action,)]
+= self.alpha * (

```

```

        reward + self.gamma * best_next_q_action -
self.q_table[tuple(state[:self.n_params]) + (action,)]

def __get_new_params(self, new_state):
    new_params = np.array([
        self.params_range[i, new_state[i]] for i in
range(self.n_params)
    ])
    return new_params

def run(self, time, target_response, episodes=15000,
steps_per_ep=1000):
    total_rewards = []

    for _ in tqdm(range(episodes), desc="Q-Learning
Progress"):
        total_reward = 0
        state = np.random.randint(0, self.n_steps,
self.n_params)

        for _ in range(steps_per_ep):
            action = self.__select_action(state)
            new_state = self.generate_new_state(state,
action)

            new_params = self.__get_new_params(new_state)

            simulated_response =
simulate_system_param(new_params, time)

            reward = compute_reward(simulated_response,
target_response)

            total_reward += reward

```

```
new_state)        self.__update_q_value(state, action, reward,  
  
                  state = new_state.copy()  
  
                  total_rewards.append(total_reward)  
  
return total_rewards, self.q_table
```

APÊNDICE E - MODEL_PARAMETERS.PY

```

from dataclasses import dataclass

from typing import Optional


import numpy as np


from src.constants import U_RED, CILINDER_DIAMETER, STROUHAL,
FLUID_DAMPING_CDosc, ADDED_MASS_COEFFICIENT_CM, \

    WATER_DENSITY_RHO, COUPLING_CL0,
CILINDER_FREQUENCY_OSCILATION_FS, NONDIMENSIONAL_MASS_M_STAR


def set_structural_angular_frequency():

    return 2.0 * np.pi * CILINDER_FREQUENCY_OSCILATION_FS


def set_infinity_flow_velocity(structural_angular_frequency):

    return U_RED * CILINDER_DIAMETER *
structural_angular_frequency / 2.0 / np.pi


def set_angular_frequency(infinity_flow_velocity):

    return 2.0 * np.pi * (STROUHAL * infinity_flow_velocity /
CILINDER_DIAMETER)


def
set_structure_reduced_angular_frequency(structural_angular_fre
quency, angular_frequency):

    return structural_angular_frequency / angular_frequency


def set_fluid_damping_coefficient():

    return FLUID_DAMPING_CDosc / (4.0 * np.pi * STROUHAL)

```



```

def set_fluid_mass():
    return ADDED_MASS_COEFFICIENT_CM * WATER_DENSITY_RHO *
    CILINDER_DIAMETER ** 2 * np.pi / 4.0

def set_structure_mass(fluid_mass):
    return NONDIMENSIONAL_MASS_M_STAR * fluid_mass

def set_nondimensional_mass_ratio(fluid_mass, structure_mass):
    return (fluid_mass + structure_mass) / (WATER_DENSITY_RHO *
    CILINDER_DIAMETER ** 2)

def set_M(nondimensional_mass_ratio):
    return 0.5 * COUPLING_CL0 / (8.0 * np.pi ** 2 * STROUHAL **
    2 * nondimensional_mass_ratio)

@dataclass
class ModelParameters:
    epsilon_num: float
    a_num: float
    xi_num: float
    fluid_damping_coefficient_gamma: float
    structural_angular_frequency: Optional[float] =
    set_structural_angular_frequency()
    fluid_mass: Optional[float] = set_fluid_mass()
    infinity_flow_velocity: Optional[float] =
    set_infinity_flow_velocity(structural_angular_frequency)
    structure_mass: Optional[float] =
    set_structure_mass(fluid_mass)

```

```
    angular_frequency: Optional[float] =  
set_angular_frequency(infinity_flow_velocity)  
  
    structure_reduced_angular_frequency_delta: Optional[float]  
=  
set_structure_reduced_angular_frequency(structural_angular_fre  
quency, angular_frequency)  
  
    nondimensional_mass_ratio_mu: Optional[float] =  
set_nondimensional_mass_ratio(fluid_mass, structure_mass)  
  
    mass_number_M: Optional[float] =  
set_M(nondimensional_mass_ratio_mu)
```

APÊNDICE F - CONSTANTS.PY

```

## hardcoded evaluation at a single Ured <-> Uinf

U_RED = 5.33  ## should results in  $2.0 \cdot \pi \cdot U_{inf} / \Omega_{gas} / D$ 
Uinf = 0.08


## harcoded VIV known parameters (not params!)

# From Assi 2010 experiments

CILINDER_FREQUENCY_OSCILATION_FS = 0.3  # structural - in
Hertz

CILINDER_DIAMETER = 50e-3  # meters

NONDIMENSIONAL_MASS_M_STAR = 2.6

WATER_DENSITY_RHO = 1000.0  # kg/m^3

STROUHAL = 0.2  # Assumed 0.2 usual for a wide range of
Reynolds

ADDED_MASS_COEFICIENT_CM = 1.0  # cylinder - potential
solution

# xi_num = .07e-2  # structural damping coefficient


# Coupling scales @ Violette 2007

COUPLING_CL0 = 0.3  # Gioria has chosen this value for
coupling

FLUID_DAMPING_CDosc = 1.2  # Gioria has chosen this value for
fluid damping

```

APÊNDICE G - TARGET_RESPONSE_GENERATOR.PY

```
import numpy as np

from src.environment import simulate_system_param

def build_target_response(time):

    target_response = np.array((0.4, 10.0, .07e-2, 0.47746,
2.8274, 0.9381, 0.01680))

    reference_response = simulate_system_param(target_response,
time)

    noise_lvl = 0.1

    reference_response[:, 0] += np.random.normal(0, noise_lvl,
reference_response.shape[0])

    reference_response[:, 1] += np.random.normal(0, noise_lvl /
.15, reference_response.shape[0])

    return reference_response[:, 0].copy()
```

APÊNDICE H - RESULTS_PLOTTER.PY

```

from matplotlib import pyplot as plt

def plot_results(total_rewards, t,
simulated_response_final_refined, target_response):

    plt.figure()

    plt.plot(t, simulated_response_final_refined[:, 0],
label="Simulated y(t) (Cylinder Position)")

    plt.plot(t, target_response, label="Target Response")

    plt.legend()

    plt.xlabel("Time")

    plt.ylabel("Amplitude")

    plt.title("Simulated vs Target Oscillation (Coupled
System)")

    plt.show()

plt.figure()

plt.plot(total_rewards, label="Total Rewards")

plt.xlabel("Episodes")

plt.ylabel("Total Reward")

plt.title("Evolution of Total Rewards During Training")

plt.legend()

plt.show()

```

APÊNDICE I - PSEUDO-CÓDIGO Q-LEARNING

para cada estado s em S :

 para cada ação a em A :

$Q(s, a) = 0$

$\alpha = \text{taxa_de_aprendizado}$

$\gamma = \text{fator_de_desconto}$

$\epsilon = \text{taxa_de_exploração}$

para cada episódio:

$s = \text{estado_inicial}$

 enquanto s não for um estado terminal:

 se número_aleatório $< \epsilon$:

$a = \text{ação_aleatória}$

 senão:

$a = \text{argmax}_{a'} Q(s, a')$

$s', r = \text{executar_ação}(a)$

$Q(s, a) = Q(s, a) + \alpha [r + \gamma * \max_{a'} Q(s', a') - Q(s, a)]$

$s = s'$

$\pi(s) = \text{argmax}_a Q(s, a)$ para cada estado s

APÊNDICE J - EXEMPLO DE APLICAÇÃO Q-LEARNING

Este código é de autoria de Rafael dos Santos Gioria.

```
grid_dimension = 4
number_of_states = grid_dimension**2
possible_actions = 4 # (cima, baixo, esquerda, direita)
goal_state = 13

def goto_newstate(cstate, action):
    if action == 0: # cima
        return (cstate + n_sides) % n_states
    elif action == 1: # baixo
        return (cstate + n_states-n_sides) % n_states
    elif action == 2: # esquerda
        return cstate//n_sides * n_sides + (cstate%n_sides+n_sides-1)%n_sides
    elif action == 3: # direita
        return cstate//n_sides * n_sides + (cstate+1)%n_sides

# Apenas inicializa a tabela-Q com zeros
Q_table = np.zeros((n_states, n_actions))

# Hiperparâmetros
learning_rate = 0.8
discount_factor = 0.95
exploration_prob = 0.2*2
epochs = 200
```

```

history = []
for epoch in range(epochs):
    tmp_hist= []
    current_state = np.random.randint(0, n_states)
    tmp_hist.append(current_state)

    while current_state != goal_state:

        if np.random.rand() < exploration_prob:
            action = np.random.randint(0, n_actions) # Exploração
        else:
            action = np.argmax(Q_table[current_state]) # Exploração

        next_state = goto_newstate(current_state, action)

        reward = 1 if next_state == goal_state else 0

        # Atualização da tabela-Q
        Q_table[current_state, action] += learning_rate * \
            (reward + discount_factor *
             np.max(Q_table[next_state]) - Q_table[current_state,action])

        current_state = next_state
        tmp_hist.append(current_state)

    history.append(tmp_hist)

```




Estudo de modelo fenomenológico para interação fluido-estrutura e solução usando Aprendizado por Reforço

Giovanni Simões Cotrim

Orientador: Prof. Rafael dos Santos Gioria

Artigo Sumário referente à disciplina PMI3349 – Trabalho de Conclusão de Curso II

Este artigo foi preparado como requisito para completar o curso de Engenharia de Petróleo na Escola Politécnica da USP.

Template versão 2021v01.

Resumo

Este trabalho apresenta uma análise e ajuste do modelo fenomenológico de interação fluido-estrutura. O modelo busca representar a dinâmica de vibrações induzidas por vórtices (VIV) e prever seus comportamentos – que podem acarretar falhas estruturais críticas. Buscou-se realizar esse ajuste através da utilização de Aprendizado por Reforço (AR), focando no algoritmo Q-Learning para ajustar os parâmetros do sistema de equações diferenciais que visam modelar as VIV em cilindros imersos em escoamento de fluido. O objetivo final é validar tanto o modelo proposto quanto o ganho de utilizar-se AR em pesquisas no contexto da indústria petrolífera offshore especialmente porque a técnica de aprendizado Q-learning não necessita de conhecimento do modelo sobre o qual atua. A escolha de usar em um modelo conhecido para VIV tem intuito de demonstrar a capacidade da técnica. Os dados utilizados no treinamento do modelo de aprendizado de máquina foram gerados de forma sintética, com simulações tanto em condições de ruído quanto sem ruído, a fim de avaliar a robustez dele em condições mais próximas à realidade. A análise de desempenho evidenciou que é capaz de encontrar parâmetros que aplicados à modelagem de VIV rendem simulações muito próximas aos sinais de entrada. Além disso, verificou-se que apesar de em geral o aumento de episódios no treinamento melhorar a precisão dos resultados, isso não ocorre indefinidamente e os ganhos marginais são progressivamente menores. Os achados levam à conclusão de que o modelo de acoplamento fluido-estrutura pode ser uma boa maneira analítica de se analisar VIV e que o aprendizado por reforço tem extenso potencial de aplicação em pesquisas na área.

Abstract

This paper presents an analysis and adjustment of the phenomenological fluid-structure interaction model. The model aims to represent the dynamics of vortex-induced vibrations (VIV) and predict their behaviors, which can lead to critical structural failures. This adjustment was achieved through the use of Reinforcement Learning (RL), focusing on the Q-Learning algorithm to tune the parameters of the differential equation system intended to model VIV in cylinders immersed in fluid flow. The ultimate goal is to validate both the proposed model and the benefits of using RL in offshore oil industry research, especially because the Q-learning technique does not require prior knowledge of the model it operates on. The choice to use a known model for VIV is intended to demonstrate the technique's capability. The data used in training the machine learning model were synthetically generated, with simulations conducted under both noisy and noise-free conditions, to assess its robustness in scenarios closer to reality. The performance analysis showed that it is capable of finding parameters that, when applied to VIV modeling, yield simulations very close to the input signals. Furthermore, it was observed that while, in general, increasing the training episodes improves result accuracy, this does not continue indefinitely, and the marginal gains become progressively smaller. The findings lead to the conclusion

that the fluid-structure coupling model can be an effective analytical approach for analyzing VIV and that reinforcement learning has extensive application potential in research within this area.

1. Introdução

1.1. Contextualização

Do início dos anos 1950 aos anos 1960, a produção de petróleo no Brasil ocorreu exclusivamente *onshore*. Entre as décadas de 1970 e 1980, a produção *offshore* da commodity superou a produção em terra (MORAIS, 2013, p. 383). No ano de 2008 o país iniciou a produção de petróleo no Pré Sal, atingindo valores diários de aproximadamente 4,262 milhões de barris de óleo equivalente (MMboe/d) em março de 2024 (BRASIL, 2024) e, segundo o Boletim de Produção de março de 2024 da ANP, os 30 maiores poços produtores de petróleo no Brasil são *offshore* (BRASIL, 2024).

Estruturas mal projetadas aumentam a necessidade de manutenção e reparos emergenciais. Em profundidades até 290 metros, conforme Barata (2003), ainda é viável a intervenção humana, mas profundidades maiores requerem dispositivos específicos, elevando os custos operacionais, que no Brasil chegam a cerca de US\$ 5,00 por barril (CBIE, 2019). Falhas estruturais em instalações offshore podem causar vazamentos, afetando o ecossistema marinho e as economias costeiras, além de gerar danos à reputação das empresas envolvidas (JERNELÖV, 2010). Além disso, a legislação, como a Lei nº 9.605/1998, impõe penalidades e sanções para danos ambientais, impactando a viabilidade financeira dos projetos.

Sendo assim, torna-se clara a necessidade de projetos robustos, capazes de reduzir a necessidade de intervenções. Instalações submersas como cabos, risers e dutos estão constantemente sujeitas a Vibrações Induzidas por Vórtices (VIV), que, ao longo do tempo, comprometem a integridade estrutural e a vida útil dos equipamentos (MORAIS, 2013; CICOLIN, 2015; TERREIRO, 2019).

1.2. Objetivo

Este trabalho tem como foco ajustar o modelo fenomenológico proposto por Facchinetti, de Langre e Biolley (2004) por meio de uma metodologia diferente da utilizada pelos autores – aprendizado por reforço, mais especificamente, o algoritmo Q-Learning – usando apenas informação da oscilação temporal da estrutura.

A proposta é encontrar os melhores parâmetros para o modelo de acoplamento fluido-estrutura, que visa descrever de maneira analítica as vibrações induzidas por vórtices, às quais um cilindro imerso em escoamento de fluido está sujeito. Com esses parâmetros, pode-se verificar se chega-se à mesma conclusão do trabalho original e se o modelo descreve adequadamente o fenômeno de VIV.

Além disso, buscamos validar os benefícios oferecidos pelo método de aprendizado de máquina, no que tange precisão na obtenção dos parâmetros e técnicas que não dependem de modelagem do processo.

2. Metodologia

2.1. Modelagem do fenômeno VIV

O modelo proposto por Facchinetti, de Langre e Biolley (2004) considera um cilindro circular rígido de diâmetro D , conectado a um suporte elástico, com um grau de liberdade - 1 dof -. Tal cilindro oscila somente na direção transversal a um escoamento laminar e uniforme, de velocidade U .




Figura 1 - Modelo de estrutura acoplada e osciladores de esteira para vibrações 2-D induzidas por vórtices. Fonte: Facchinetti, de Langre e Biolley (2004, p.124)

A proposta é modelar o sistema através de um sistema de equações diferenciais acopladas (Eq.(1) e Eq.(2)), onde a Eq.(1) descreve o oscilador estrutural e a Eq.(2) descreve o oscilador da esteira.

$$\ddot{y} + \left(2\xi\delta + \frac{\gamma}{\mu}\right)\dot{y} + \delta^2 y = s \quad (1)$$

$$\ddot{q} + \epsilon(q^2 - 1)\dot{q} + q = f \quad (2)$$

Os termos de acoplamento estão definidos em Eq.(3) e Eq.(4).

$$f = A\ddot{y} \quad s = Mq \quad (3)$$

$$M = \frac{1}{2} C_{L0} \cdot \frac{1}{8\pi^2 St^2 \mu} \quad (4)$$

Como ressaltado no tópico 1.2, a proposta do presente estudo é encontrar os melhores parâmetros (Coeficiente de acoplamento (A), Coeficiente de van der Pol (ϵ), Coeficiente de amortecimento estrutural (ξ), Coeficiente de amortecimento fluido (γ), Relação de massa adimensional (μ), Frequência angular reduzida (δ), Número de massa (M)), buscando validar o modelo proposto, através de aprendizado por reforço.

2.2. Aplicação de *Q-Learning* à equação de acoplamento

Aprendizado por reforço (AR) é uma área de aprendizado de máquina onde um agente aprende a tomar decisões realizando certas ações dentro de um ambiente, buscando maximizar uma recompensa cumulativa. Ao contrário do aprendizado supervisionado, onde o modelo é treinado em um conjunto de dados com pares de entrada-saída, AR foca em aprender através de tentativa e erro (SUTTON; BARTO, 2018).

Q-Learning é um algoritmo que visa encontrar a política de seleção de ações mais otimizada para qualquer Processo de Decisão de Markov (MDP) dado (WATKINS; DAYAN, 1992). Por sua vez, um MDP é uma estrutura matemática que modela problemas de decisão sequenciais em ambientes estocásticos, permitindo que um agente escolha ações de maneira a maximizar a soma de recompensas esperadas ao longo do tempo (SUTTON; BARTO, 2018).

Um algoritmo de Q-Learning revolve em torno de valores de qualidade (Valores Q), que representam a qualidade de uma ação em um determinado estado, ou seja, o valor esperado da recompensa futura ao tomar uma determinada ação a partir de um estado específico; da política (π), uma estratégia que define o comportamento do agente em cada estado do ambiente; a taxa de aprendizado (α), um hiperparâmetro que controla o quanto novos dados substituem os dados antigos durante o processo de aprendizado; e do fator de desconto (γ) que determina a importância das recompensas futuras em comparação com as recompensas imediatas. Ele assume um valor entre 0 e 1 ($0 \leq \gamma \leq 1$) e influencia como o agente avalia as recompensas que receberá ao longo do tempo (SUTTON; BARTO, 2018).

O projeto – disponível em <https://github.com/GSCotrim/Q-Learning-VIV> – foi desenhado seguindo a arquitetura padrão de um modelo de aprendizado por reforço, como definido por (SUTTON; BARTO, 2018), dividido em ambiente e agente.

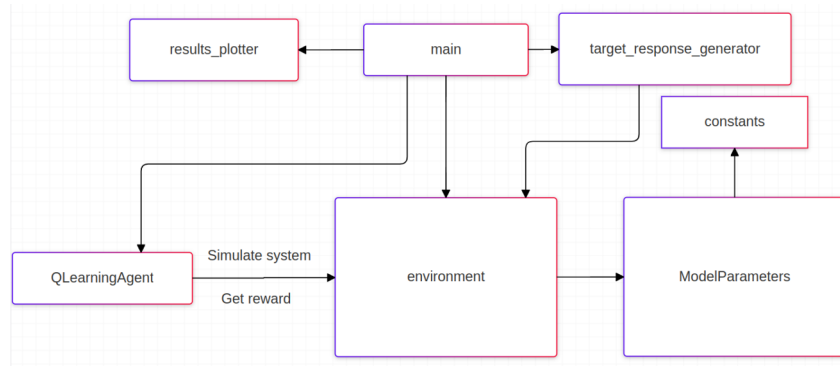


Figura 2 - Relações de chamadas e dependência entre os componentes do modelo de Q-Learning.

O arquivo *main.py* age como orquestrador, definindo a resposta esperada do modelo e iniciando o agente, definido por *QlearningAgent.py*.

O ambiente, definido por *environment.py*, segue o modelo de acoplamento fluido-estrutura proposto por Facchinetti, de Langre e Biolley (2004), descrito pelo sistema de equações diferenciais Eq.(1) e Eq.(2). Com diferentes parâmetros, diferentes $y(t)$ e $q(t)$ são gerados. O agente fornece combinações de parâmetros ($A, \epsilon, \xi, \gamma, \mu, \delta, M$), o ambiente simula como o modelo se comportaria e retorna uma recompensa, sendo esta o oposto do erro quadrático médio entre o comportamento simulado e o comportamento alvo. *ModelParameters.py* é uma classe de estrutura de dados com o propósito de facilitar o trânsito de dados. O arquivo *constants.py* contém valores de parâmetros retirados da literatura. Em *results_plotter.py* fica concentrada a lógica de geração de gráficos e *target_response_generator.py* é responsável por gerar os dados utilizados para o treinamento do modelo.

$$Recompensa = -\frac{1}{n} \sum_{i=1}^n \left(y_{simulation}(t_i) - y_{target}(t_i) \right)^2 \quad (5)$$

O agente trabalha com estados e ações associadas. Cada estado é uma lista com os índices do vetor que contém os valores de cada um dos sete parâmetros a serem definidos. As ações representam uma mudança em um dos valores do estado, somando ou subtraindo um. A ação pode assumir qualquer valor inteiro entre 0 e 13 (inclusos), e é esse valor que determina qual posição do vetor de estado será afetada, assim como a forma em que será alterada.

Para validar o modelo foram feitas duas aplicações: ambas abordando oscilações mais próximas daquilo observado experimentalmente, com efeitos não-lineares, mas uma levando em consideração ruídos no sinal de entrada e outra não, buscando analisar quão bem o modelo se adaptaria aos ruídos naturais às situações práticas.

Para cada uma das aplicações rodou-se três vezes, com diferentes números de episódios – 500, 1000, 2000, 3500 e 5000.

3. Resultados

No tópico 3.1 é demonstrada uma aplicação ao oscilador sem ruídos no sinal de entrada. No tópico 3.2 será apresentado um dos resultados da aplicação ao oscilador com ruídos.

Em ambos os cenários, independente do número de episódios rodados, observou-se que o agente encontrou parâmetros que, aplicados ao modelo de Facchinetti, de Langre e Biolley (2004), geraram simulações com comportamento muito próximo ao do alvo e não tão distantes daqueles presentes na literatura, sendo a maioria na mesma ordem de grandeza.

Os gráficos de recompensa comportam-se como esperado, apresentando valores maiores com o passar dos episódios. Em geral há uma concentração de picos negativos durante os episódios iniciais, indicando a maior predisposição do agente à exploração de novas ações. O aumento nas recompensas indica um conhecimento maior sobre o ambiente por parte do agente e mais foco na exploração de ações já conhecidas e bem avaliadas.

Entretanto, é perceptível que apesar de apresentar resultados próximos aos esperados, o modelo falha em acompanhar certas irregularidades da oscilação estrutural quando trabalhando num caso com ruído – sessão 3.2.

O aumento no número de episódios parece ter influência na qualidade dos resultados, com o modelo alcançando a simulação mais fiel ao alvo ao ser treinado com 2000 e 3500 episódios em ambos os casos. Os resultados apresentados a seguir correspondem aos treinamentos realizados com 2000 episódios. Contudo, o ganho marginal diminui à medida que o número de episódios aumenta, o que é esperado, além de observar-se um crescimento acentuado no tempo de processamento, embora de forma irregular, devido às variações no hardware utilizado na simulação.

3.1. Modelo de acoplamento fluido-estrutura sem ruídos no sinal de entrada.




Figura 3 - Oscilação simulada versus oscilação alvo e Evolução das recompensas durante o treinamento - 2000 episódios - sem ruído

Tabela 1 – Parâmetros - 2000 episódios - sem ruído

Parâmetro	Valor
Coefficiente de van der Pol (ϵ)	0.92692
Coefficiente de acoplamento (A)	6.84615
Coefficiente de amortecimento estrutural (ξ)	0.00092
Coefficiente de amortecimento fluido (γ)	0.26923
Relação de massa adimensional (μ)	0.47692
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.07715

3.2. Modelo de acoplamento fluido-estrutura com ruídos no sinal de entrada.




Figura 4 - Oscilação simulada versus oscilação alvo e Evolução das recompensas durante o treinamento - 2000 episódios - com ruído

Tabela 2 – Parâmetros - 2000 episódios - com ruído

Parâmetro	Valor
Coeficiente de van der Pol (ϵ)	0.56154
Coeficiente de acoplamento (A)	14.15385
Coeficiente de amortecimento estrutural (ξ)	0.00016
Coeficiente de amortecimento fluido (γ)	1.00000
Relação de massa adimensional (μ)	1.60769
Frequência angular reduzida (δ)	0.96154
Número de massa (M)	0.06192

4. Conclusão

Mesmo através de uma metodologia diferente chegamos à conclusão de que o modelo de acoplamento fluido estrutura de Facchinetti, de Langre e Biot (2004) descreve bem o fenômeno de VIV, sendo uma boa maneira analítica de analisar a questão. O comportamento simulado através do sistema de equações diferenciais proposto se aproxima daquele esperado na natureza.

Além disso, concluímos a validade da utilização de aprendizado de máquina – neste caso aprendizado por reforço – na análise da questão, chegando em bons resultados, sem a necessidade de passar extensivamente por literaturas e cálculos para obter-se os parâmetros da equação. Tendo uma ideia dos intervalos fisicamente lógicos de cada parâmetro, foi possível obter bons valores, de maneira rápida e direta. Ademais, validou-se certa flexibilidade do modelo de aprendizado por reforço, capaz de produzir comportamentos próximos dos sinais de entrada, sejam sinais com ou sem ruídos.

5. Referências

BRASIL (Brasil). Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). Boletim da Produção de Petróleo e Gás Natural. 163. ed. Brasil, 03/2024. Disponível em: <<https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/boletins-anp/boletins/arquivos-bmppgn/2024/marco.pdf>> . Acesso em: 10 mar. 2024.

BARATA, Germana. Pesquisa avalia rotina de mergulhadores em águas profundas. Cienc. Cult., São Paulo , v. 55, n. 2, p. 06, Apr. 2003 . Disponível em: <http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252003000200006&lng=en&nrm=iso> . Acesso em: 10 mar. 2024.

- CBIE (Brasil). O que são os Custos de Extração do Petróleo?. [S. l.]: CBIE – Centro Brasileiro de Infraestrutura, 15 nov. 2019. Disponível em: <<https://cbie.com.br/artigos/o-que-sao-os-custos-de-extracao-do-petroleo/>> . Acesso em: 10 mar. 2024.
- CICOLIN, Murilo Marangon. Supressão da vibração induzida por vórtices de cilindros com malha permeável. 2015. Dissertação (Mestrado em Engenharia Naval e Oceânica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2015. doi:10.11606/D.3.2016.tde-07032016-102934. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/3/3135/tde-07032016-102934/pt-br.php>> Acesso em: 10 mar. 2024.
- FACCHINETTI, M. L.; de Langre, E. de; BOLLLEY, F. Coupling of structure and wake oscillators in vortex-induced vibrations. *Journal of Fluids and Structures*, [s. l.], ano 2004, v. 19, n. 2, p. 123-140, 2004. DOI <https://doi.org/10.1016/j.jfluidstructs.2003.12.004>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0889974603001853>> . Acesso em: 10 mar. 2024.
- JERNELÖV, A. The threats from oil spills: now, then, and in the future. *Ambio*, [s. l.], v. 39, n. 5-6, p. 353-366, 2010. DOI <https://doi.org/10.1007/s13280-010-0085-5>. Disponível em: <https://link.springer.com/article/10.1007/s13280-010-0085-5>. Acesso em: 18 out. 2024.
- MORAIS, José Mauro de. Petróleo em águas profundas: uma história tecnológica da Petrobras na exploração e produção offshore. Brasília: Ipea, 2013. 424 p. ISBN 978-85-7811-159-5. Disponível em: <https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=18251> . Acesso em: 10 mar. 2024.
- SUTTON, R. S.; BARTO, A. G. Reinforcement Learning: An Introduction. 2. ed. Cambridge: MIT Press, 2018.
- TERREIRO, João Pedro de Andrade. Modelo semi-empírico para vibração por vórtices com interferência. Orientador: Gioria, Rafael dos Santos. 2019. 75 p. TCC (Graduação - Engenharia de Petróleo) - Escola Politécnica da Universidade de São Paulo, Santos – SP, 2019. Disponível em: <<https://bdta.aguia.usp.br/item/002992629>> . Acesso em: 10 mar. 2024.
- WATKINS, C. J. C. H.; DAYAN, P. Q-learning. *Machine Learning*, v. 8, n. 3-4, p. 279-292, 1992. DOI: <https://doi.org/10.1007/BF00992698>. Disponível em: <https://link.springer.com/article/10.1007/BF00992698>. Acesso em: 01 jul. 2024.