

**UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA**

VITOR TAKATA

**Controle ativo de escoamento ao redor de um cilindro fixo através
do uso de cilindros rotativos e redes neurais**

Santos
2019

VITOR TAKATA

**Controle ativo de escoamento ao redor de um cilindro fixo através
do uso de cilindros rotativos e redes neurais**

Trabalho de Formatura em Engenharia de
Petróleo apresentado à Escola Politécnica
da Universidade de São Paulo

Orientador: Prof. Dr. Rafael dos Santos
Gioria

Santos
2019

VITOR TAKATA

**Controle ativo de escoamento ao redor de um cilindro fixo através
do uso de cilindros rotativos e redes neurais**

Trabalho de Formatura em Engenharia de
Petróleo apresentado à Escola Politécnica
da Universidade de São Paulo

Área de Concentração: Dinâmica de
fluidos

Orientador: Prof. Dr. Rafael dos Santos
Gioria

Santos

2019

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.

Catálogo-na-publicação

Takata, Vitor

Controle ativo de escoamento ao redor de um cilindro fixo através do uso de cilindros rotativos e redes neurais / V. Takata -- São Paulo, 2019.
99 p.

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

1.REDES NEURAI 2.DINÂMICA DOS FLUÍDOS 3.MECÂNICA DOS FLUÍDOS COMPUTACIONAL I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Minas e Petróleo II.t.

Para minha família.

AGRADECIMENTOS

Aos meus pais, Carlos e Regina, pelo apoio e pela confiança durante minha graduação.

À minha irmã, Natália, pelo humor e pelas fotos de patos.

Ao prof. Dr. Rafael S. Gioria, pela orientação deste trabalho, tendo paciência e visão crítica tanto dos acertos quanto dos erros cometidos.

À amizades cultivadas durante esses anos. Aos encontros esporádicos ou noites via voz de amigos de Limeira e São Paulo, e à convivência diária dos amigos da Poli-Santos.

Às nove bolas de pelo que vivem em casa, pela companhia e alergias.

À Isabelly Baldo, pela companhia nesses últimos quatro anos e por me ensinar a importância da inteligência emocional.

RESUMO

O escoamento ao redor de cilindro fixo é um campo de estudo que requer muita atenção por ser recorrente em diversas atividades da indústria do petróleo, como na interação entre a correnteza do mar e *Spars* ou umbilicais. Observa-se que, no escoamento em torno destas estruturas, há formação de esteira resultante da interação hidrodinâmica, sinal de que as forças hidrodinâmicas presentes são grandes, aumentando requisitos e custos estruturais. Diversos métodos de controle foram e são propostos na literatura, como aplicação de jatos sintéticos e cilindros rotativos. Assim, a redução das forças hidrodinâmicas através de técnicas de controle de escoamento permitem aliviar requisitos de estruturas mais robustas e possivelmente seus custos, além de aumentar sua confiabilidade. Dentre os estudos propostos, surge um método que alia a capacidade de análise e tomada de decisão das redes neurais à simulação da computação fluidodinâmica para ativação de um controle ativo de circuito fechado. O trabalho proposto possui como objetivo efetivar o controle de escoamento ao redor de um cilindro fixo utilizando cilindros rotativos com redes neurais para sua ativação. Para isto, utiliza-se uma rede neural de aprendizado profundo, implementada em *Tensorforce*, utilizando a plataforma computacional *FEniCS Project* pra realização das simulações de escoamento. São realizados testes tanto de capacidade de malha quanto de funcionamento da rede neural, junto com implementação da rede neural para controle de cilindros rotativos, com diversas geometrias. Após treinamento das redes neurais, são realizados testes com parâmetros de rotação dos cilindros, adaptabilidade da rede neural para escoamentos variados e sensibilidade da função objetivo da rede neural. Obtém-se uma rede neural com cilindros rotativos capaz de reduzir em cerca de 23% as forças de arrasto em um cilindro fixo. Além disso, confirma-se a superioridade do uso de cilindros rotativos com rotação independente para controle, diminuindo tanto a força média de arrasto exercida sobre um cilindro quanto a oscilação desta força.

Palavras-Chave: Controle de escoamento. CFD. Controle de Esteira. Redes neurais.

ABSTRACT

Flow control around a fixed cylinder is a field that requires constant attention as it is recurrent in many activities in oil and gas industry, like in interactions of the sea currents with Spars and risers. In the flow around these structures, hydrodynamic interactions results in the formation of a wake, indicating that strong hydrodynamic forces are present, causing increased structural costs to guarantee structural integrity. Many flow control methods are found in the literature, like secondary flow using synthetic jets or rotating cylinders. Thus, flow control methods are used to reduce the hydrodynamic forces exerted by the wake of the flow, consequently reducing the need for expensive robust structures and increasing reliability. Among many approaches in this field, a method comes up to combine the analysis and decision making capabilities of neural networks with computational fluid dynamics simulations for the activation of a closed-loop active flow control method. The present work aims to accomplish the flow control around a fixed cylinder using rotating cylinders as the control method, and a neural network to activate the control of these cylinders. A deep learning neural network is implemented on Tensorforce, using the FeniCS Project platform for the flow simulations. Mesh quality and neural network functionality are tested before the implementation of the neural network for flow control with different geometries of rotating cylinders. After the neural network training is done, rotating parameters, adaptability for different flow conditions and objective function sensibility are tested. A neural network capable of controlling rotating cylinder to perform flow control, capable of reducing drag forces around a fixed cylinder by 23% is obtained as result. Furthermore, the superiority of independently rotating cylinders for flow control is confirmed, reducing both the average drag forces around a fixed cylinder and its amplitude of oscillation.

Keywords: Flow Control. CFD. Wake Control. Neural Networks.

LISTA DE FIGURAS

Figura 3.1 – Seção transversal do corpo cilíndrico no plano de incidência de escoamento.....	10
Figura 3.2 – Esquema da formação de vórtices proposto por Gerrard (1966)	13
Figura 3.3 – Perfil da esteira de Von Kármán.....	13
Figura 3.4 – Representação das forças de arrasto (F_D) e de sustentação (F_L) atuantes em um cilindro.	14
Figura 3.5 – Posicionamento dos cilindros rotativos	18
Figura 3.6 – Posicionamento dos cilindros rotativos utilizando o parâmetro de gap .	18
Figura 3.7 – Parâmetros de posicionamento dos jatos.	22
Figura 3.8 – Hipóteses de no-slip em vermelho e perfil de entrada do escoamento (U_e).	22
Figura 3.9 – Modelo de neurônio artificial [MP43]	25
Figura 4.1 – Representação do sistema a ser simulado, com cilindro fixo em branco, jatos sintéticos em vermelho e sensores em preto.....	30
Figura 4.2 – Representação dos cilindros rotativos com numeração e sentido positivo de rotação.	33
Figura 4.3 – Representação da rede neural utilizada, sendo i os dados de entrada, w os neurônios e o os dados de saída.....	34
Figura 5.1 – Teste de malha realizado com diferentes refinamentos	37
Figura 5.2 – Comparação do efeito da malha nos treinamentos realizados.....	38
Figura 5.3 – Comparação do C_D para três diferentes testes de rede neural.	39
Figura 5.4 – Comparação do C_L para três diferentes testes de rede neural.....	39
Figura 5.5 – Malha utilizada para simulação do teste rede_128.	39
Figura 5.6 – Teste de malha ao redor dos cilindros rotativos.	40
Figura 5.7 – Malha do sistema com foco nos cilindros presentes.	40
Figura 5.8 – Histórico de treinamento para a rede_128, com indicação do melhor modelo obtido pela rede com um círculo vermelho.	41
Figura 5.9 – C_D durante a atuação da rede_128 em comparação com o escoamento natural.	42
Figura 5.10 – C_L durante a atuação da rede_128 em comparação com o escoamento natural.	42

Figura 5.11 – Velocidade do escoamento no momento inicial para a simulação da rede _128.	43
Figura 5.12 – Velocidade do escoamento no momento final para a simulação da rede _128.	43
Figura 5.13 – Campo de pressão do escoamento no momento inicial para a simulação da rede _128.	44
Figura 5.14 – Campo de pressão do escoamento no momento final para a simulação da rede _128.	44
Figura 5.15 – Histórico de treinamento para a rede R_5_75, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.	46
Figura 5.16 – C_D durante a atuação da rede R_5_75	47
Figura 5.17 – C_L durante a atuação da rede R_5_75	47
Figura 5.18 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75.	48
Figura 5.19 – Campo de pressão do escoamento no momento inicial para a simulação da rede R_5_75.	49
Figura 5.20 – Campo de pressão do escoamento no momento final para a simulação da rede R_5_75.	49
Figura 5.21 – Velocidade do escoamento no momento inicial para a simulação da rede R_5_75.	49
Figura 5.22 – Velocidade do escoamento no momento final para a simulação da rede R_5_75.	50
Figura 5.23 – Histórico de treinamento para a rede R_5_75_I, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.	51
Figura 5.24 – C_D durante a atuação da rede R_5_75_I	52
Figura 5.25 – C_L durante a atuação da rede R_5_75_I	52
Figura 5.26 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75_I.	53
Figura 5.27 – Campo de pressão do escoamento no momento inicial para a simulação da rede R_5_75_I.	54
Figura 5.28 – Campo de pressão do escoamento no momento final para a simulação da rede R_5_75_I.	54
Figura 5.29 – Velocidade do escoamento no momento inicial para a simulação da rede R_5_75_I.	54

Figura 5.30 – Velocidade do escoamento no momento final para a simulação da rede R_5_75_I.....	55
Figura 5.31 – Histórico de treinamento para a rede R_5_75_I04, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.	56
Figura 5.32 – C_D durante a atuação da rede R_5_75_I04.....	56
Figura 5.33 – C_D durante a atuação da rede R_5_75_I04.....	57
Figura 5.34 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75_I04.....	57
Figura 5.35 – Atuação da rede neural com cilindros rotativos e $Re = 120$	59

Lista de tabelas

Tabela 3.1 – Regime de escoamento ao redor de cilindro.	11
Tabela 3.2 – Compilado de geometrias e condições de escoamento para cilindros rotativos.....	20
Tabela 4.1 – Testes de malha realizados.....	31
Tabela 4.2 – Parâmetros Originais de Simulação	31
Tabela 4.3 – Testes de treinamento realizados para controle por jatos.	32
Tabela 4.4 – Testes de treinamento realizados pra cilindros de controle.....	35
Tabela 5.1 – Eficiência de cada teste realizado no controle de escoamento por escoamento secundário junto com resultado obtido por Rabault et al.(2019).	45
Tabela 5.2 – Eficiência de cada teste realizado no controle de escoamento por cilindros rotativos.....	58
Tabela 5.3 – Aproximação dos coeficientes de arrasto reais e redução pela rede atuante para rede com jatos e variação do número de Reynolds.	59
Tabela 5.4 – Aproximação dos coeficientes de arrasto reais e redução pela rede atuante para rede com cilindros rotativos independentes e variação do número de Reynolds.	60

SUMÁRIO

1. INTRODUÇÃO	7
2. OBJETIVOS.....	9
3. REVISÃO DA LITERATURA	10
3.1. ESCOAMENTO AO REDOR DE UM CILINDRO	10
3.1.1. <i>Fenômenos do escoamento</i>	10
3.1.2. <i>Controle de escoamento</i>	15
3.2. FLUIDODINÂMICA COMPUTACIONAL	21
3.3. REDES NEURAIS	23
3.3.1. <i>Redes Neurais Aplicadas a Controle de Escoamento</i>	27
4. DESENVOLVIMENTO	29
4.1. REDE NEURAL PARA CONTROLE POR ESCOAMENTO SECUNDÁRIO.....	29
4.2. REDE NEURAL PARA CILINDROS.....	32
5. RESULTADOS E DISCUSSÕES.....	37
5.1. TESTES DE MALHA	37
5.2. TESTE DAS REDES NEURAIS ARTIFICIAIS PARA ESCOAMENTO SECUNDÁRIO.....	41
5.3. TESTE DAS REDES NEURAIS ARTIFICIAIS COM CILINDROS VIBRATÓRIOS	45
5.4. TESTE DAS REDES NEURAIS ARTIFICIAIS COM CILINDROS ROTATIVOS	46
5.5. OUTROS TESTES COM CILINDROS ROTATIVOS.....	50
5.5.1. CILINDROS COM ROTAÇÃO INDEPENDENTE	50
5.5.2. ALTERAÇÃO DA FUNÇÃO OBJETIVO	55
5.5.3. ADAPTABILIDADE DA REDE PARA MUDANÇA DO NÚMERO DE REYNOLDS	58
6. CONCLUSÃO	61
REFERÊNCIAS.....	63
APÊNDICE A – TESTES DE ESCOAMENTO SECUNDÁRIO.....	66
APÊNDICE B – TESTES DE CILINDROS VIBRATÓRIOS.....	76
APÊNDICE C – TESTES DE CILINDROS ROTATIVOS.....	89
APÊNDICE D – TESTES DE ADAPTABILIDADE DA REDE NEURAL.....	94
ANEXO A – ARTIGO SÍNTESE.....	100

1. INTRODUÇÃO

Inserida cada vez mais em ambientes de águas profundas e ultra profundas, a indústria do petróleo necessita continuamente estudar as interações entre suas instalações marinhas diversas e os elementos da natureza, como o vento e a água do mar, para viabilizar a exploração *offshore*. Um dos principais focos de estudo desta área, o escoamento ao redor de cilindros, ou de corpos rombudos em geral, se faz necessário por ser uma geometria recorrente em diversas estruturas *offshore*, como *risers*, que são os tubos que levam o óleo produzido do fundo do mar até a plataforma, plataformas monocoluna ou *Spars*, pernas de plataformas submersíveis e umbilicais.

Tal estudo se faz necessário devido à ação das forças de arrasto e sustentação originárias do escoamento ao redor da estrutura. Para evitar problemas estruturais, os sistemas *offshore* são projetados para suportar estes carregamentos ao longo de décadas. Além da intensidade da força de arrasto, outro fenômeno observado neste tipo de escoamento é o desprendimento de vórtices na esteira do escoamento, que podem causar vibrações, chamadas de Vibrações Induzidas por Vórtices (V.I.V., em inglês), que em ressonância com a estrutura pode causar fadiga do material e consequentemente falha (PATINO; GIORIA; MENEHINI, 2017; RABAULT et al., 2019).

Uma forma de aliviar a intensidade destes carregamentos é através do controle de escoamento. Diferentes métodos de controle de escoamento foram estudados ao longo dos anos, podendo estes ter duas classificações diferentes, uma em relação ao emprego de energia para sua atuação, diferenciados em método passivo, quando não há o uso de energia externa, e ativo, quando há o emprego de energia externa (RASHIDI; HAYATDAVOODI; ESFAHANI, 2016). Outra classificação possível é em relação ao local de atuação do método, podendo este ser na fronteira da camada limite do escoamento ou diretamente na esteira produzida (CHOI; JEON; KIM, 2008). Dentre os métodos ativos de controle da separação da camada limite, cita-se o método de Controle de Camada Limite de Superfície Móvel (MSBC, em inglês), no qual um elemento externo, geralmente cilindros rotativos de diâmetro menor que o corpo principal, injeta momento diretamente na fronteira da camada limite, retardando a separação e portanto inibindo a formação de vorticidade (PATNAIK; WEI, 2002).

Apesar dos benefícios que um controle de escoamento ativo pode trazer para uma estrutura, como a redução das forças exercidas e em alguns casos a anulação das forças causadas pela vorticidade, os pré-requisitos para a implementação de um tipo de controle, junto com as condições do ambiente, podem dificultar ou até mesmo impedir a utilização de tal método de controle. Enquanto este trabalho aborda apenas a capacidade ou não do método de controle de escoamento de reduzir as forças exercidas em um cilindro fixo, é importante considerar, em uma implementação real, o tipo de método a ser escolhido em relação ao custo energético, a eficácia do controle e a confiabilidade associados a cada método, fatores que, dentre outros, são levados em conta para aplicação na indústria.

Um dos parâmetros de funcionamento de métodos ativos de controle de escoamento é a estratégia de ativação do método. Devido à grande dificuldade de se analisar e montar uma estratégia de ativação em tempo real, gerada pela caoticidade do escoamento, o que corresponde a alto tempo gasto em simulações computacionais, grande parte dos métodos ativos possuem ativação harmônica ou constante (CHOI; JEON; KIM, 2008). Rede neurais são fortes candidatas a realizar esta função.

Provenientes da tentativa de aproximar a computação da mente humana, redes neurais são algoritmos que podem “aprender” a realizar ações dado um objetivo e estímulos, capazes de explorar diversos campos de ação, a fim de obter o melhor resultado capaz de atingir um objetivo proposto. Deste modo, uma possível resposta para a obtenção de uma estratégia de ativação em tempo real é através da implementação de redes neurais, que quando treinadas são capazes de analisar e devolver uma resposta a partir de medições realizadas do escoamento (RABAULT et al., 2019).

Devido a essa dificuldade na busca de uma estratégia de ativação de métodos ativos de controle de escoamento, e o contínuo avanço dos métodos de inteligência computacional, este trabalho tem como objetivo final a implementação de uma rede neural de aprendizado profundo, através de simulações computacionais, que seja capaz de controlar a ativação de um Controle de Camada Limite de Superfície Móvel, baseada no trabalho de Rabault et al. (2019), de modo a reduzir as cargas hidrodinâmicas numa geometria cilíndrica.

2. OBJETIVOS

O objetivo do presente trabalho consiste da implementação e teste, em ambiente de simulação computacional, de uma rede neural capaz de controlar a ativação de cilindros rotativos, de modo a se realizar o controle de escoamento ao redor de um cilindro circular fixo. Realiza-se também a avaliação da adaptabilidade da rede implementada para diferentes condições de escoamento às quais não fora treinada anteriormente, variando-se o número de Reynolds.

De modo a se alcançar o objetivo proposto, estabelecem-se objetivos intermediários descritos por: testes preliminares de validação e reprodução da parte computacional obtida do artigo base e adaptação da rede neural do artigo base para a situação proposta por este trabalho.

3. REVISÃO DA LITERATURA

A revisão bibliográfica aqui apresentada busca concentrar os estudos já produzidos sobre as áreas de escoamento ao redor de cilindro e seus fenômenos, junto com seus métodos de controle, métodos computacionais e redes neurais, além de aplicações de redes neurais no campo de controle de escoamento.


3.1. Escoamento ao redor de um cilindro

Esta primeira seção aborda fenomenologia e características do escoamento ao redor de um cilindro fixo e métodos de controle deste escoamento, baseando-se nas teses de Meneghini (2002) e Ortega (2015), além de artigos de revisão da literatura de Derakhshandeh e Alam (2019), Choi, Jeon e Kim (2008) e Rashidi, Hayatdavoodi e Esfahani (2016).

3.1.1. Fenômenos do escoamento

Observa-se separação massiva no escoamento ao redor de um cilindro em diversos regimes de escoamento práticos da indústria, fato que caracteriza um cilindro como um corpo rombudo (OERTEL, 1990). As principais características do escoamento são a velocidade ao longe U e o diâmetro do cilindro D , representados na Figura 3.1, e as propriedades do fluido do escoamento, massa específica ρ e viscosidade μ .

Figura 3.1 – Seção transversal do corpo cilíndrico no plano de incidência de escoamento



Fonte: Adaptado de Derakhshandeh e Alam (2019).

O número de Reynolds (Re) é um número adimensional, definido como parâmetro de similaridade de escoamento (POTTER; WIGGERT, 2004), e

representa a razão entre as forças inerciais e viscosas de um fluido quando submetido à um escoamento com a presença de camadas limite, como por exemplo ao redor de um cilindro fixo, sendo exibido na Equação 3.1,

$$Re = \frac{\rho U D}{\mu} = \frac{U D}{\nu} \quad (3.1)$$

onde ρ é a densidade do fluido, μ a viscosidade dinâmica, ν é a viscosidade cinemática, U é a velocidade do escoamento ao longe e D a dimensão linear característica do corpo imerso no fluido. Para o caso do cilindro circular, como observado na Figura 3.1 a dimensão linear característica é o seu diâmetro.

A importância do número de Reynolds se dá pela possibilidade de se prever o comportamento de um escoamento a partir dele, observável na Tabela 3.1.

Tabela 3.1 – Regime de escoamento ao redor de cilindro.

Intervalo de Re	Regime de escoamento	Característica
$Re < 1$	Sem separação	
$3-5 < Re < 40-48$	Separação estável	
$40-48 < Re < 300$	Laminar periódico	
$300 \leq Re < 1.4 \cdot 10^5$	Subcrítico	

$1.4 \cdot 10^5 < Re < 1 \cdot 10^6$	Crítico	
$1 \cdot 10^6 < Re < 5 \cdot 10^6$	Supercrítico	
$5 \cdot 10^6 < Re$	Turbulento	


Fonte: Adaptado de Derakhshandeh & Alam (2019) e Ortega (2015).

Um dos principais causadores de forças e vibrações em corpos imersos em um escoamento é a separação da camada limite com geração de vórtices. O fenômeno de desprendimento de vórtices ocorre devido à interação das camadas cisalhantes separadas.

Segundo Gerrard (1966), a periodicidade do desprendimento se deve ao fato de que um vórtice, ao ser alimentado pela sua camada cisalhante, atrai a camada cisalhante oposta, movimentando o fluido desta camada. Através da Figura 3.2, visualizam-se os possíveis caminhos que o fluido movimentado pode tomar, sendo eles **a)** se incorporar ao vórtice presente no lado oposto; **b)** se mover em direção à camada cisalhante oposta; **c)** se mover em direção à esteira imediatamente atrás do corpo, alimentando o vórtice de sua camada cisalhante. Devido ao fato de o crescimento do vórtice causar o desprendimento do vórtice anterior, a movimentação de fluido para o terceiro caminho que garante a periodicidade do fenômeno. Apesar disso, o balanço da quantidade de fluido que se desloca por cada caminho rege a frequência de formação e desprendimento dos vórtices, além de sua pressão de base, ou seja, a pressão na região posterior ao corpo.


Outro estudo sobre vorticidade, realizado por Von Kármán, idealizou o que se nomeia atualmente de esteira de Von Kármán, que é o perfil que os vórtices desprendidos pelo escoamento ao redor de um cilindro assumem para números de Reynolds maiores que $5 \cdot 10^6$ e entre ~ 47 e $1.4 \cdot 10^5$, e pode ser observada na Figura 3.3. Tal estudo mostrou que há um espaçamento típico e estável entre vórtices, caracterizando uma frequência de desprendimento bem delimitada (WILLIAMSON, 1996).

Figura 3.2 – Esquema da formação de vórtices proposto por Gerrard (1966)



Fonte: Ortega (2015).

Figura 3.3 – Perfil da esteira de Von Kármán



Fonte: Adaptado de Meneghini (2002).

Oriundo da normalização da frequência de desprendimento de vórtices (f_s), o número de Strouhal (St) é um adimensional que depende dessa frequência de desprendimento, da velocidade U do escoamento e da dimensão linear característica do corpo, que assume o valor do diâmetro D para o caso do cilindro circular, conforme Equação 3.2. Devido ao conceito de similaridade de escoamento, é possível também considerar o número de Strouhal como uma função do número de Reynolds (NORBERG, 2003):

$$St = \frac{Df_s}{U} = f(Re) \quad (3.2)$$

É possível calcular as forças instantâneas de arrasto (F_D) e de sustentação (F_L) na superfície de um cilindro C através das equações 3.3 e 3.4, que são:

$$F_D = \int_C (\sigma \cdot n) \cdot e_x dS \quad (3.3)$$

e

$$F_L = \int_C (\sigma \cdot n) \cdot e_y dS \quad (3.4)$$

onde n é o vetor normal à superfície do cilindro, $e_x = (1, 0)$, $e_y = (0, 1)$ e σ é o tensor de Cauchy, que simplificado para um escoamento 2D é representado por

$$\sigma = \begin{pmatrix} \sigma_{xx} & \tau_{xy} \\ \tau_{yx} & \sigma_{yy} \end{pmatrix} \quad (3.5)$$

sendo que:


$$\sigma_{xx} = -p + 2\mu \frac{du}{dx} + \lambda \nabla \cdot V \quad (3.6)$$

$$\sigma_{yy} = -p + 2\mu \frac{dv}{dy} + \lambda \nabla \cdot V \quad (3.7)$$

$$\tau_{xy} = \tau_{yx} = \mu \left(\frac{du}{dy} + \frac{dv}{dx} \right) \quad (3.8)$$

onde p é pressão, μ é a viscosidade, u é a velocidade na direção x , v é a velocidade na direção y , V é o campo de velocidade e λ é um coeficiente de viscosidade, que para escoamentos incompressíveis de fluido newtoniano pode ser considerado nulo (RABAULT et al. (2019); POTTER; WIGGERT, 2004). Tais forças são demonstradas na Figura 3.4.

Figura 3.4 – Representação das forças de arrasto (F_D) e de sustentação (F_L) atuantes em um cilindro.



Fonte: Adaptado de Potter e Wiggert (2004).

Por elegância de notação e usando a ideia de similaridade do escoamento dada pelo número de Reynolds, ou seja, a ideia de que variações proporcionais de forças e geometria resultam na mesma fenomenologia, as forças de arrasto e de sustentação serão apresentadas na forma adimensional, sendo elas os coeficientes

de arrasto, C_D , e de sustentação C_L , que são a normalização de suas respectivas forças, assumindo envergadura unitária para o caso bidimensional. O cálculo desses coeficientes é explicitado nas equações 3.9 e 3.10

$$C_D = \frac{F_D}{\frac{1}{2}\rho U^2 D} \quad (3.9)$$

$$C_L = \frac{F_L}{\frac{1}{2}\rho U^2 D} \quad (3.10)$$

sendo ρ a densidade do fluido, U a velocidade média do escoamento e D o diâmetro do cilindro.

3.1.2. Controle de escoamento

Segundo a revisão de Choi, Jeon e Kim (2008), os métodos de controle de escoamento possuem diferentes classificações. A primeira classificação possível é em relação ao gasto energético necessário para obtenção do controle desejado. Enquanto os métodos que não dependem de energia externa são denominados métodos passivos de controle, os métodos que necessitam de energia para funcionamento são chamados de métodos ativos de controle de escoamento.

Outra classificação que os métodos podem receber é em relação ao local de ação destes. Aos métodos que agem sobre a camada limite, retardando a sua separação ou incitando a transição do regime de escoamento (GAD-EL-HAK; BUSHNELL, 2008), atribui-se o nome de método de controle de camada limite. Para os métodos que atuam modificando a esteira do escoamento após o corpo presente no escoamento, dá-se o nome de método de controle direto de esteira.

Zdravkovich (1981) realizou uma revisão dos métodos passivos de controle de escoamento, separando-os em três grupos principais, os métodos que utilizam protuberâncias na superfície do cilindro e os métodos que utilizam protetores, atuando na camada limite tentando diminuir ou evitar a formação de vórtices, e os métodos que utilizam estabilizadores na esteira do escoamento, como por exemplo placas divisoras, que funcionam evitando a interação dos vórtices com a camada cisalhante oposta, impedindo o desprendimento dos vórtices.

Devido ao foco deste trabalho, realiza-se a seguir uma revisão mais detalhada dos métodos de controle ativo, especialmente do método de cilindros rotativos.

3.1.2.1. Controle ativo de escoamento

A seguir citam-se os principais métodos de controle ativo conhecidos, segundo o artigo revisão de Rashidi, Hayatdavoodi e Esfahani (2016), com descrição mais minuciosa do método de cilindros rotativos, método de interesse deste trabalho.

O método de controle por meios elétricos, que atua na camada limite do escoamento, funciona através do uso de descargas elétricas que alteram o campo de velocidade do escoamento, retardando a separação do escoamento. Este método é favorável para aplicações aerodinâmicas, com difícil implementação em fluidos líquidos. Suas vantagens são a fácil instalação, alta frequência e ação e baixo consumo energético.

Atuante na esteira do escoamento, o método de geração de escoamento secundário possui diversas formas de implementação, como jatos sintéticos e tubos de sucção ou injeção, que modificam o escoamento através da interação deste com o escoamento secundário gerado. Um dos principais parâmetros deste método é o balanço de massa no sistema. Quando o balanço de massa é nulo, o escoamento secundário se dá pela movimentação do fluido do próprio escoamento. Quando este balanço difere de zero, ocorre a transferência de fluido entre o local do escoamento e tanques externos, causando um aumento do gasto energético do método. Nota-se também a possibilidade de jatos sintéticos estarem acoplados no cilindro fixo, tendo uma ação direta na camada limite e não na esteira de escoamento (RABAULT et al., 2019).

Um método atuante na camada limite do escoamento, o método de campos magnéticos requer um fluido que seja capaz de conduzir eletricidade para funcionamento, sendo prático em aplicações oceânicas. Tal método funciona através da aplicação de um campo magnético no sistema, criando forças resistivas no fluido em movimento, modificando o escoamento. A principal vantagem deste método é a possibilidade de se alterar o campo elétrico localmente e temporalmente, obtendo-se possibilidade de controles específicos para o escoamento.

Devido à dependência da viscosidade e da densidade do fluido com a temperatura, os métodos termiais agem modificando as forças viscosas na camada

limite, alterando o perfil de velocidade do escoamento ao redor do corpo fixo, desestruturando a formação de vórtices, tendo portanto atuação na camada limite.

3.1.2.2. Controle por cilindros rotativos

O método de controle por cilindros rotativos, da categoria de MSBC, funciona através da locação de pequenos cilindros nas proximidades do corpo principal, de modo que a rotação destes incorra na injeção de momento na camada limite, modificando o escoamento, sendo considerado portanto um método com atuação na camada limite. Seus principais parâmetros de atuação são a quantidade de cilindros rotativos alocados, o posicionamento de tais cilindros, seus diâmetros e a velocidade angular durante atuação.


Com relação à velocidade de rotação dos cilindros, esta geralmente é medida através de um adimensional α , que representa a razão entre a velocidade escalar a um raio de distância do centro do cilindro rotativo e a velocidade do escoamento, possuindo U_c/U como a notação mais utilizada. A equação que relaciona esse adimensional com a velocidade angular do cilindro é:

$$\frac{U_c}{U} = \frac{\omega d}{2U} \quad (3.11)$$

sendo ω a velocidade angular, d o diâmetro do cilindro de controle e U a velocidade do escoamento ao longe.


Com relação ao posicionamento dos cilindros rotativos, o método mais comum de notação é por coordenadas cilíndricas, com distância radial em relação ao centro do cilindro fixo, geralmente em razão do diâmetro D do cilindro, e distância angular em relação à jusante do escoamento, como observado na Figura 3.5. Outra possível notação para a posição radial do cilindro rotativo é pelo uso do parâmetro *gap*, sendo este parâmetro a menor distância entre a superfície do cilindro fixo e do cilindro rotativo, exemplificado na Figura 3.6.

Figura 3.5 – Posicionamento dos cilindros rotativos



Fonte: Adaptado de Dehkordi, Goodarzi e Nourbakhsh (2018).

Figura 3.6 – Posicionamento dos cilindros rotativos utilizando o parâmetro de gap



Fonte: Adaptado de Dehkordi, Goodarzi e Nourbakhsh (2018).

Diâmetro e quantidade dos cilindros rotativos são dois parâmetros geométricos que afetam a quantidade de momento que estes são capazes de injetar. Sobre o diâmetro, tal propriedade tem uma relação diretamente proporcional com a quantidade de momento injetável para uma mesma situação de atuação. Com relação ao número de cilindros, há um consenso de se utilizar um número par de corpos rotativos, devido ao fato de que a separação da camada cisalhante ocorre em ambos os lados do cilindro fixo, de forma simétrica. Caso haja um posicionamento assimétrico dos cilindros de controle, haverá a uma concentração das forças de sustentação em um lado do escoamento, deslocando a média de seu coeficiente do valor nulo.

Diversos autores estudaram os diversos parâmetros deste método, para variados intervalos de número de Reynolds, na busca da melhor redução possível das forças atuantes. Modi (1997) realizou uma revisão do campo de estudo de cilindros rotativos, chegando às principais conclusões de que o método era capaz de diminuir forças de arrasto e aumentar forças de sustentação, tendo promissora

capacidade de aplicação na melhora de performance de aeronaves, e de ter sua atuação calculada por meios computacionais com economias computacionais.

Mittal (2001) realizou testes computacionais de posicionamento e rotação para cilindros rotativos em escoamentos com $Re = 10^2$ e 10^4 . A partir de um sistema com um cilindro fixo de diâmetro D , o posicionamento de um par de cilindros menores em posição normal à direção do escoamento, isto é, a 90° e 270° da jusante, com diâmetro igual a $0.05D$ e *gaps* de $0.01D$ e $0.075D$, realizou-se o cálculo da eficácia do método em função da velocidade U_c/U , através de cálculos computacionais. Mittal chegou à conclusão de que para um número de Reynolds de 10^2 , a razão $U_c/U = 5$ é o suficiente para suprimir a formação de vórtices, reduzindo drasticamente as forças atuantes. Para Reynolds de 10^4 , porém, não houve a supressão da vorticidade, havendo porém uma melhora significativa da organização da esteira para $U_c/U > 5$.

Korkischko e Meneghini (2012) realizaram testes experimentais de atuação dos cilindros rotativos no controle de escoamento, para Reynolds entre 1600 e 7500, com um intervalo da razão U_c/U entre 5 e 10. Foi observado uma diminuição do arrasto médio em cerca de 60% para a razão $U_c/U = 5$, tendo boa concordância com o experimento computacional de Mittal (2001).

Patino, Gioria e Meneghini (2017) desenvolveram um estudo computacional de sensibilidade para definição dos parâmetros de posicionamento de cilindros rotativos e não rotativos e de velocidade angular para os cilindros rotativos para controle de escoamento ao redor de um cilindro de diâmetro D , para $Re = 50$, e diâmetro do cilindro de controle igual a $0.06D$, posicionados a 90° e 270° em relação ao escoamento. Foi obtido um valor de *gap* de $0.07D$ para o posicionamento dos cilindros, e para o caso do método ativo, uma razão U_c/U mínima de 1.89. Foi realizado também uma extrapolação dos resultados obtidos em relação ao número de Reynolds, obtendo-se valores condizentes com o experimento computacional de Mittal (2001).

Zhu e Gao (2017) realizaram um estudo computacional sobre método de MSBC utilizando cilindros rotativos com diâmetro igual a $0.06D$, sendo D o diâmetro do cilindro fixo pelo qual ocorre o escoamento, posicionados simetricamente a 135° em relação à montante do escoamento, com $Re = 3484$ e $U_c/U = 6$. O principal objetivo deste estudo foi avaliar a atuação do método de controle para as situações em que os cilindros não possuem sincronia de rotação. As principais conclusões

obtidas indicam que a rotação para fora de ambos os cilindros de controle possui efeito contrário ao de controle de escoamento, enquanto que a rotação com direções alternadas causa uma assimetria no desprendimento de vórtices, sem realizar o controle efetivo da esteira.

Assi, Orselli e Ortega (2019) experimentaram computacionalmente um arranjo de cilindros rotativos composto pelo cilindro principal de diâmetro D e oito cilindros de controle com diâmetro $0.05D$, espalhados de forma homogênea ao redor do cilindro fixo. Para $Re = 100$, o sistema foi capaz de impedir o desprendimento de vórtices para $U_c/U > 3$, havendo porém uma resultante alta de forças de sustentação no sistema. Nota-se que tal arranjo gera a possibilidade do método de controle ser omnidirecional, podendo controlar o escoamento independente da direção de incidência de corrente.

Compilam-se na Tabela 3.2 as diferentes geometrias e condições de escoamento dos autores citados anteriormente.

Tabela 3.2 – Compilado de geometrias e condições de escoamento para cilindros rotativos

Autor(es)	Nº de Cilindros	Posicionamento	Diâmetro	Gap	Nº Reynolds	U_c/U
Mittal	2	90° e 270°	0.05D	0.01D; 0.075D	100	5
Mittal	2	90° e 270°	0.05D	0.01D; 0.075D	10000	>5
Korkischko, Meneghini	2	90° e 270°	0.06D	0.07D	1600 < Re < 7500	5 < U_c/U < 10
Patino, Gioria e Meneghini	2	90° e 270°	0.06D	0.07D	50	>1.89
Zhu, Gao	2	45° e 135°	0.06D	0.09D	3484	6
Assi, Orselli e Ortega	8	Distribuição uniforme	0.05D	0.1D	100	>3

Fonte: Adaptado de Mittal (2001), Korkischko e Meneghini (2012), Patino, Gioria e Meneghini (2017), Zhu e Gao (2017) e Assi, Orselli e Ortega (2019).

3.2. Fluidodinâmica Computacional

A fluidodinâmica computacional (Computational Fluid Dynamics) é definido por Hirsch (2007) como o conjunto de metodologias que permitem a resolução de problemas que envolvem escoamento de fluidos através de simulações computacionais. Deste modo, é possível utilizar CFD para simular e analisar o escoamento ao redor de um cilindro fixo sob efeito de cilindros rotativos.

Nesta seção da revisão bibliográfica, será descrito o ambiente de simulação utilizado no artigo de Rabault et al. (2019), que será utilizado como base para as simulações do presente trabalho.

Inicialmente, é imprescindível a citação do conjunto de equações que regem o escoamento incompressível, as equações de Navier-Stokes, representadas na forma vetorial:

$$\frac{\partial \mathbf{V}}{\partial t} + \mathbf{V} \cdot \nabla \mathbf{V} = -\nabla p + \frac{1}{Re} \nabla^2 \mathbf{V} \quad (3.12)$$


$$\nabla \cdot \mathbf{V} = 0 \quad (3.13)$$

onde Re é o número de Reynolds, p é a pressão e $\mathbf{V}$ é o campo de velocidade.

Para o fechamento das equações 3.12, oriunda da conservação de momento e 3.13, de conservação de massa, são definidas como hipóteses a condição de *no-slip* para as superfícies das paredes horizontais do sistema e do cilindro fixo, ou seja, no contato entre o fluido e essas superfícies há a aderência do fluido, e a condição de tensão nula de saída, representada na Equação 3.14, onde p representa a pressão, $\mathbf{U}$ a velocidade e $\vec{n}$ o vetor normal de saída. Para o ambiente original do artigo de Rabault et al (2019), há também a condição de que os jatos utilizados para controle de escoamento resultam em uma adição ou subtração nula de massa no sistema. O posicionamento dos jatos está representado na figura 3.7, onde ω representa o ângulo da largura de atuação do jato e θ o ângulo entre a jusante do escoamento e o centro de ω .

$$p\vec{n} - \frac{1}{Re} \frac{\partial \mathbf{U}}{\partial n} = 0 \quad (3.14)$$

Figura 3.7 – Parâmetros de posicionamento dos jatos.



Fonte: Adaptado de Rabault et al. (2019).

Figura 3.8 – Hipóteses de no-slip em vermelho e perfil de entrada do escoamento (U_e).



Fonte: O autor (2019).

Para a obtenção da solução das equações 3.12 e 3.13 ao longo do tempo, foi utilizado o esquema de correção de pressões incrementais (Incremental Pressure Correction Scheme) proposto por Goda (1979), que utiliza o método de elementos finitos.

Para a explicação do método de IPCS, discute-se primeiramente o método de elementos finitos. Considerado como um método universal de resolução de equações diferenciais, o método de elementos finitos consiste de forma simplificada na discretização do espaço do domínio das equações em um número finito de elementos, de modo que seja possível resolver cada elemento individualmente, para que a solução geral seja obtida pela combinação das soluções individuais. Para equações dependentes do tempo, como é o caso da equação de Navier-Stokes, para uma variação no tempo Δt pequeno, e um tempo inicial t_0 , existem duas formas de cálculo da solução das equações no tempo seguinte $t_0 + \Delta t$, o método explícito, que obtém a solução das equações de $t_0 + \Delta t$ a partir do estado de t_0 , e o método implícito, que obtém um sistema de equações para obtenção dos estados do sistema para t_0 e $t_0 + \Delta t$. As principais características do método implícito em relação ao método explícito é a alta estabilidade e nível de convergência em troca de altos custos computacionais.

Voltando ao método de IPCS, demonstra-se o processo através das equações seguintes:

$$\frac{u^* - u_0}{\Delta t} + u_0 \cdot \nabla u_0 = \frac{1}{Re} \Delta \frac{u^* + u_0}{2} \quad (3.15)$$

$$\Delta(p - p_0) = \frac{1}{\Delta t} \nabla \cdot u^* \quad (3.16)$$

$$\frac{1}{\Delta t} (u - u^*) = -\nabla p \quad (3.17)$$

onde u_0 e p_0 são as velocidades e pressão iniciais, u^* a velocidade estimada, u e p as velocidades e pressão no momento seguinte e Δt o passo no tempo. Deste modo, resolvem-se as equações de Navier-Stokes através de três passos: em 3.15 realiza-se a estimativa da velocidade no momento seguinte a t_0 utilizando a Equação 3.12, em 3.16 a projeção da pressão é calculada utilizando-se a Equação 3.13 e a velocidade calculada em 3.15, e em 3.17 ocorre a correção da velocidade calculada através da pressão projetada em 3.16 e da Equação 3.13. Neste processo, a discretização espacial por elementos finitos é feita em elementos triangulares, e ocorre tratamento explícito no tempo para cálculo da Equação 3.15 (GUNZBURGER, 1989; LOGG; MARDAL; WELLS, 2015; RABAULT et al., 2019).

Para a simulação computacional do problema proposto, foi utilizado o framework de elementos finitos *Fenics Project* (LOGG et al., 2012, ALNAES et al., 2015), junto com o módulo *Dolfin* (LOGG; WELLS, 2010) e utilização do *software Gmsh* (GEUZAIN; REMACLE, 2009) para a geração das malhas triangulares.

3.3. Redes neurais

Para a justificativa do uso de sistemas de redes neurais, realiza-se primeiramente a explicação de um conceito propositalmente omitido sobre os métodos de controle ativo de escoamento.

Ao se analisar o método de ativação de um controle ativo de escoamento, este pode ser dividido em duas categorias: ativação com circuito aberto (ou *open loop*) e ativação com circuito fechado (ou *closed loop*). Para a ativação com circuito fechado, por vezes também denominado como método de controle por *Feedback*, o sistema é munido de sensores ao redor da área de interesse do escoamento,

geralmente a esteira e a vizinhança do cilindro fixo, que avaliam a situação do escoamento ao longo do tempo e controlam a ativação do método de controle em tempo real. Já a ativação com circuito aberto se dá em um momento inicial e permanece constante durante todo seu funcionamento, ou com variações periódicas pré-definidas (CHOI; JEON; KIM, 2008; DERAKHSHANDEH; ALAM, 2019).


Embora a eficiência do método por ativação com circuito fechado seja superior à de circuito aberto, o alto tempo de simulação devido à caoticidade inerente do comportamento de um escoamento gera uma dificuldade na sua implementação fazendo com que a ação calculada por uma observação dos sensores não seja obtida a tempo. Por esse motivo, o sistema de redes neurais é utilizado como interface observação-ação para o controle ativo de circuito fechado.

Para esta última seção da revisão bibliográfica, utiliza-se como base os livros de Haykin (2005) e Nandy e Biswas (2018), além de anotações de aula da disciplina PMI3927 - Inteligência Computacional Aplicada à Indústria de Petróleo.

Segundo Haykin (2005), uma rede neural artificial, ou simplesmente rede neural, é um processador paralelamente distribuído, composto por unidades simples, os neurônios, que possuem capacidade de armazenar conhecimento na forma de pesos sinápticos, obtidos a partir de estímulos do ambiente durante um processo de aprendizagem. Baseado no funcionamento do cérebro humano, as aplicações de redes neurais incluem classificação, categorização, aproximação, previsão e otimização.

O primeiro modelo de neurônio artificial, proposto por McCulloch e Pitts em 1943, foi nomeado como [MP43] e apresentava as características principais do funcionamento de um neurônio biológico. Ele apresentava um número de entradas de dados, representando os dendritos, uma função de ativação que era calculada e um terminal de saída, representando o axônio. A estrutura de um neurônio artificial pode ser observada na Figura 3.9. Com o primeiro modelo de neurônio artificial proposto, Hebb difundiu a ideia de algoritmo de aprendizado, pelos quais um neurônio poderia alterar seus pesos específicos, “aprendendo” a analisar um estímulo dado pelos dados de entrada (HAYKIN, 2005).

Figura 3.9 – Modelo de neurônio artificial [MP43]



Fonte: Adaptado de Haykin (2005).

A função de ativação do [MP43] atribuía w_i como um peso específico para cada dado de entrada x_i , e utilizava a somatória dos dados multiplicados por seu respectivo peso para comparação com um *threshold*, ou bias, b de ativação, enviando um sinal y de resposta caso a função fosse ativada.

Com relação ao aprendizado de uma rede neural, este pode ser dividido em duas categorias: aprendizado supervisionado ou não supervisionado. Para uma rede neural com aprendizado supervisionado, possui-se o conhecimento do resultado a ser obtido, como por exemplo a classificação de um número manuscrito. Deste modo, a rede é treinada a partir de exemplos em que ela recebe os dados de entrada e a resposta esperada para aquela entrada, buscando minimizar o erro entre a resposta obtida e a resposta esperada.

Para o aprendizado não supervisionado, os resultados esperados não são expostos à rede neural, tendo esta que identificar padrões entre os dados de entrada para desenvolver seus pesos w_i . Uma das subcategorias do aprendizado não supervisionado, o aprendizado por reforço (Reinforcement Learning, em inglês) é um processo no qual a rede não é exposta a uma série de dados, mas sim a um ambiente contínuo, que representa algum cenário real a ser estudado. Com a definição de uma função objetivo, a rede interage com o ambiente a ela exposto, realizando ações e obtendo recompensas ou punições da função objetivo. Seu processo de aprendizagem se dá por reforço atrasado, ou seja, ela é capaz de observar uma sequência temporal de observação-ação-reação, tendo como objetivo definir, para a observação realizada, a ação a ser feita para que a recompensa acumulada seja máxima, ou sua punição acumulada seja mínima. O principal empecilho para a implementação do aprendizado por reforço, até a década de 50,

era a dificuldade de se implementar uma rede capaz de identificar, para uma observação temporal, a influência de cada ação realizada para o resultado final obtido. Tal dificuldade começou a ser superada com a apresentação da programação dinâmica por Bellman, em 1957.

O conceito de redes neurais profundas e aprendizado profundo (*Deep Neural Networks* e *Deep Learning*, em inglês) tem relação com a arquitetura da rede neural utilizada. Enquanto uma rede neural convencional, considerada uma rede de camada simples, possui, além das camadas de entrada e saída, apenas uma camada intermediária de neurônios, as redes profundas possuem múltiplas camadas intermediárias. O uso de redes e aprendizado profundos possui aplicações na exploração de dados de dimensões elevadas, como reconhecimento de imagem de fala, sendo portanto indicado para problemas complexos (LECUN; BENGIO; HINTON, 2015).

Assim, o aprendizado profundo por reforço funciona como um agente, ou seja um algoritmo, que realiza a interação com o ambiente, captando a observação, realizando a ação e obtendo a recompensa ou punição, que controla a rede neural artificial.

O algoritmo utilizado como agente de aprendizado profundo por reforço foi o *Proximal Policy Optimization*, ou simplesmente PPO, tendo sido apresentado por Schulman et al. (2017). Tal método, de forma simplificada, busca obter a distribuição probabilística da ação a ser tomada para uma observação, de modo que a recompensa a longo prazo seja maximizada. Elaborada na tentativa de se obter um agente de treinamento que possuísse a simplicidade de um gradiente descendente e a precisão de um agente de região de confiança, o agente PPO simplifica o processo de aprendizado pois, ao invés de eliminar ações consideradas como restritas, ele atribui uma penalidade a estas ações, reduzindo cálculos necessários durante o aprendizado. Durante seu treinamento, o agente explora as possíveis ações a serem tomadas e atribui a probabilidade destas ações de resultarem no melhor resultado. A partir de um parâmetro de *clipping*, as ações com a razão de sua probabilidade com a da melhor ação menor que este parâmetro são eliminadas, até que a melhor ação seja definida. A randomicidade do processo de exploração se dá devido à incerteza da rede de escolher alguma ação quando todas as possíveis possuem uma probabilidade igual de maximizar a recompensa, sendo escolhida então uma aleatória de uma alta gama de opções.

3.3.1. Redes Neurais Aplicadas a Controle de Escoamento

Uma gama de autores relataram o uso de redes neurais para o controle ativo de escoamento, seja de circuito aberto ou fechado. A seguir apresentam-se alguns usos de redes neurais neste ramo.

Fujisawa e Nakabayashi (2002) desenvolveram uma simples rede neural de uma camada intermediária capaz de controlar a ativação de cilindros rotativos para controle de escoamento em volta de um cilindro. A rede era alimentada pelo campo de pressão ao redor de um sensor, que teve sua posição como objeto de teste de sensibilidade. Por fim, computou-se uma redução do coeficiente de arrasto e de sustentação de 16% e 70% maior, respectivamente, em relação ao emprego de cilindros não rotativos. Com relação ao posicionamento dos sensores, chegou-se à conclusão de que o seu posicionamento na esteira do escoamento traz medidas mais úteis e precisas para a rede neural.

Shin et al. (2006) realizaram uma análise de comparação da atuação de uma rede neural de camada intermediária única com 8 neurônios com um Estimador Linear Estocástico (Linear Stochastic Estimator), com relação à eficiência e número de sensores. Foi observado que para sensores sem nenhum tipo de interferência, o método de LSE com 12 sensores era superado pela rede neural utilizando menos que 4 sensores, além de que para sensores com 30% de interferência, a rede neural com 4 sensores teve desempenho muito superior ao LSE com 12 sensores.

Dehkordi et al. (2017) utilizaram redes neurais para estimar os parâmetros ideais para implementação do método de controle por cilindros rotativos para $Re = 150$. Os parâmetros de velocidade angular, diâmetro dos cilindros de controle e o posicionamento destes foi estimado por uma rede neural com auxílio da metodologia Taguchi de estatística, substituindo a simulação de todos os casos possíveis de teste. Com os parâmetros obtidos obteve-se redução da oscilação de arrasto e de sustentação em 99.9% e redução do coeficiente médio de arrasto em 29.16%, além da supressão da formação de vórtices (supressão associada à redução das oscilações das forças).

Rabault et al. (2019) desenvolveram a primeira rede neural treinada por aprendizado profundo por reforço capaz de realizar controle ativo de escoamento. O método utilizado foi o de um par de jatos sintéticos posicionados no raio do cilindro principal, capaz de inserir ou succionar fluxo no escoamento. Com uma rede

profunda de duas camadas intermediárias de 512 neurônios cada, a rede neural foi capaz de controlar a ativação dos jatos, obtendo uma redução do coeficiente de arrasto de 8%, sendo uma prova de conceito de que o aprendizado profundo por reforço é capaz de obter uma estratégia de controle para os jatos sintéticos.

4. DESENVOLVIMENTO


4.1. Rede Neural para Controle por Escoamento Secundário

Para a realização dos testes iniciais deste trabalho, de modo que se obtenha o conhecimento da interface de trabalho utilizada por Rabault et al.(2019), utilizou-se além dos mesmos *softwares* de CFD, a mesma interface para redes neurais, sendo essa a utilização do Tensorflow (Abadi et al., 2016) para definição da rede neural, e do *Tensorforce* (Schaarschmidt et al., 2017), uma biblioteca *open source* do *Tensorflow* para implementação do agente de aprendizado profundo por reforço. As simulações neste primeiro momento foram realizadas com uma rede neural com duas camadas intermediárias de 128 neurônios cada, em contraste com as duas camadas de 512 do trabalho original. Tal escolha foi influenciada principalmente pela necessidade apenas de familiarização com a interface de trabalho, aliada à redução de custo computacional que esta redução acarreta para a simulação total.

O escoamento simulado tem como características principais um cilindro fixo com diâmetro adimensional $D = 1$ e um perfil de velocidade parabólico com velocidade média adimensional $U_m = 1.5$, resultando em $Re = 100$; dois jatos controladores posicionados a 90° e 270° em relação à jusante do escoamento, no raio do cilindro, com 10° de ângulo de atuação e parametrizados de modo que, sendo Q o fluxo de cada jato, para que não ocorra injeção de massa no sistema, $Q_1 = Q_2$.

De modo a se fazer a observação do estado do escoamento, o sistema possui 151 sensores, que são capazes de medir tanto pressão quanto velocidade. Para o caso do trabalho original, foram utilizados sensores de velocidade, enquanto que os testes deste trabalho utilizou sensores de pressão e apenas um teste com sensores de velocidade, de modo a validar os resultados com os obtidos originalmente. A representação da simulação original pode ser observada na Figura 4.1, onde os pontos pretos são os sensores do sistema, os pontos vermelhos os jatos e a circunferência branca o cilindro de diâmetro D .

Figura 4.1 – Representação do sistema a ser simulado, com cilindro fixo em branco, jatos sintéticos em vermelho e sensores em preto.



Fonte: Rabault et al., 2019.

Os parâmetros de aprendizado da rede neural são definidos como um aprendizado durante 300 episódios, onde cada episódio é o período de tempo em que a rede atua no escoamento antes de analisar os resultados obtidos e realizar o aprendizado. O tempo de cada episódio é definido como 2 segundos, assim como no trabalho original, correspondendo a 6.5 vezes o período de desprendimento de vórtices. Na simulação, são computados 4000 passos no tempo por episódio, com um $\Delta t = 5 \cdot 10^{-3}$ segundos.

De modo a realizar o aprendizado por reforço, utilizando o algoritmo de *PPO* como agente de aprendizado, a função objetivo da rede treinada é apresentada a seguir:

$$r_t = -\langle C_D \rangle_T - 0.2|\langle C_L \rangle_T| \quad (4.1)$$

onde r_t é o valor a ser maximizado e $\langle X \rangle_T$ indica o valor médio de X ao longo de tempo T . Deste modo, a função objetivo busca reduzir a média do coeficiente de arrasto, tentando manter a média do coeficiente de sustentação próxima de nula, evitando quebra de simetria. Para cada treinamento, a rede neural passará por 300 episódios de 2 segundos cada, totalizando 4000 passagens de tempo em cada episódio. Nesta função objetivo, como foi dito por Rabault et al. (2019), o coeficiente de sustentação é utilizado de modo que a rede não tente diminuir o coeficiente de arrasto com uma injeção excessiva de forças de sustentação, fato que atenderia o objetivo apenas por mudar a direção do deslocamento do cilindro de horizontal para vertical.

Elencam-se na Tabela 4.1 os testes de malha realizados, na Tabela 4.2 os parâmetros originais de simulação e na Tabela 4.3 todos os testes de sistema de escoamento realizados, com comparação dos parâmetros modificados em relação ao exemplo original. Observa-se que na Tabela 4.1, os tamanhos da malha representam a distância adimensional máxima permitida entre nós.

Tabela 4.1 – Testes de malha realizados.

Teste	Tamanho da malha no cilindro	Tamanho da malha longe do cilindro	Número total de células
Malha original	0.01	0.05	9640
Malha fina	0.005	0.01	40334
Malha grosseira	0.04	0.1	4710
Malha muito grosseira	0.08	0.4	3260

Fonte: O autor (2019).

Tabela 4.2 – Parâmetros Originais de Simulação

Parâmetro	Valor Original
Nº Neurônios por camada	512
Posição dos jatos	90° e 180°
Largura de atuação do jato	10°
Número de sensores	151
Tipo de sensor	Velocidade

Fonte: O autor (2019).

Tabela 4.3 – Testes de treinamento realizados para controle por jatos.

Nome do teste	Parâmetro modificado	Valor modificado
rede_128	Nº Neurônios por camada	128
rede_128_vel	Tipo de sensor	Velocidade
rede_128-45	Posição dos jatos	45° e 315°
rede_128_jw30	Largura de atuação do jato	30°
rede_128_probes_reduzidos	Número de sensores	37, bem distribuídos
rede_128_probes_cilindro	Número de sensores	36, ao redor do cilindro
rede_128_probes_esteira	Número de sensores	36, concentrados na esteira

Fonte: O autor (2019).

Nota-se que, apesar de estar indicado apenas para o primeiro teste na Tabela 4.3, como dito no início desta seção, todos os testes foram realizados com uma rede neural com duas camadas intermediárias de 128 neurônios cada. Ressalta-se também que todos os testes, com exceção do teste “rede_128_vel” foram realizados com sensores de pressão.

4.2. Rede Neural para Cilindros


Como parte do desenvolvimento da parte final deste trabalho, foi realizado primeiramente a adaptação do problema proposto por Rabault et al. (2019) com o objetivo de inserir um par de cilindros à geometria do problema. Em concordância com o trabalho de Patino, Gioria e Meneghini (2017), os cilindros inseridos possuem um raio de 0.06D e um gap em relação ao cilindro principal de 0.07D, posicionados porém com uma angulação de 45° em relação à jusante do escoamento. Com os cilindros inseridos, foi realizado um teste de malha para averiguar a capacidade da mesma de computar corretamente as informações destes novos cilindros, por serem notoriamente menores que o cilindro principal. Realizou-se teste utilizando tamanhos

de malha de 0.02 e 0.01, e um teste do funcionamento da rede neural nesta nova geometria, utilizando jatos como método de controle, e os novos cilindros sem rotação.

A seguir, foi implementado o movimento para os cilindros de controle. Em primeiro momento, foi implementado um movimento vibratório de controle, no qual os cilindros de controle deslocavam o fluido na direção y.

Após treinamento da rede neural para cilindros vibratórios, foi implementado o movimento de rotação dos cilindros de controle como método de controle de escoamento. Foi definido uma rotação positiva para a direção interna em relação ao cilindro principal, como observado na Figura 4.2, e rotação dependente para os cilindros de controle, ou seja, a mesma rotação para ambos. Ressalta-se que as condições de escoamento e parâmetros de aprendizado para implementação dos cilindros são as mesmas das redes de controle por jatos, mudando-se apenas a geometria e o método de controle.

Figura 4.2 – Representação dos cilindros rotativos com numeração e sentido positivo de rotação.




Fonte: O autor (2019).

Devido a algumas limitações de malha e impossibilidade de realização de treinamentos para malhas muito finas em tempo hábil, para todos os treinamentos que envolvem cilindros de controle, estes foram posicionados a 45° e -45° da jusante do escoamento, e para o caso de cilindros rotativos, a rotação foi limitada para 1200 rad/s.

Foi utilizada para ambos os movimentos de cilindros uma rede composta por duas camadas de 512 neurônios, com as informações dos 151 sensores de pressão como dados de entrada e a ação de cada cilindro como saída, como representado na Figura 4.3. Ressalta-se que, por ser uma rede de aprendizado profundo, todos os

elementos de cada camada estão interligados com os elementos das camadas adjacentes.

Figura 4.3 – Representação da rede neural utilizada, sendo i os dados de entrada, w os neurônios e o os dados de saída.



Fonte: O autor (2019).

Na Tabela 4.4, encontram-se todas as geometrias treinadas, junto com nome para referenciamento ao longo do trabalho, seguindo o código:

$$a_x_y \quad (4.3)$$

onde a indica o tipo de movimento do cilindro, podendo ser V para cilindro vibratório e R para cilindro rotativo, x se refere ao diâmetro d do cilindro de controle e y ao gap entre os cilindros de controle e o cilindro principal de diâmetro D , sendo:

$$d = x10^{-2}D \quad (4.4)$$

$$gap = y10^{-2}D \quad (4.5)$$

Tabela 4.4 – Testes de treinamento realizados pra cilindros de controle.

Nome do Teste	Tipo de movimento	Diâmetro do cilindro de controle	Gap
V_5_1	Vibração	0.05D	0.01D
V_5_7	Vibração	0.05D	0.07D
V_5_7.5	Vibração	0.05D	0.075D
V_5_9	Vibração	0.05D	0.09D
V_6_1	Vibração	0.06D	0.01D
V_6_7	Vibração	0.06D	0.07D
V_6_7.5	Vibração	0.06D	0.075D
V_6_9	Vibração	0.06D	0.09D
R_5_75	Rotação dependente	0.05D	0.075D
R_6_7	Rotação dependente	0.06D	0.07D

Fonte: O autor (2019).

Realizados os treinamentos, utilizou-se a mesma geometria de R_5_75 e R_6_7 para o treinamento de duas novas redes neurais, mas desta vez com os cilindros de controle com rotação independente entre si. Tais testes recebem o nome R_5_75_I e R_6_7_I para indicar a independência de rotação dos cilindros.

Com o treinamento destas últimas redes, foi realizado um teste de adaptabilidade da rede neural para escoamentos diferentes do escoamento do ambiente de treino. Para este teste foi utilizado uma rede semelhante à rede proposta por Rabault et al. (2019), com controle por jatos, e a rede R_5_75_I. Estas redes foram utilizadas para realizar o controle de escoamento com diferentes números de Reynolds, começando em $Re = 100$, que foi a condição de treinamento, com incrementos de 10 em 10, até o momento que a malha não fosse capaz de computar o resultado.

Como último teste, foi realizado o treinamento de uma rede com mesma geometria da rede R_5_75_I, porém com alteração na função objetivo da rede

neural apresentada na Equação 4.1, aumentando o impacto do coeficiente de sustentação, como representado na Equação 4.6:

$$r_t = -\langle C_D \rangle_T - 0.4|\langle C_L \rangle_T| \quad (4.6)$$

Tal rede recebe o nome de R_5_75_I04.


Nota-se portanto que, enquanto a metodologia e o meio de treinamento da rede neural é semelhante ao apresentado pelo artigo base, este trabalho propõe um foco na geometria nova através da implementação do método de cilindros rotativos, além da contribuição através de testes de adaptabilidade da rede neural para variação do número de Reynolds.

5. RESULTADOS E DISCUSSÕES

5.1. Testes de malha


Realizados os testes e simulações iniciais, apresentam-se primeiramente os resultados para testes de malha, observáveis nas imagens 5.1 e 5.2. Tais testes de malha foram realizados devido ao desconhecimento dos reais valores dos coeficientes de arrasto e sustentação ao redor do cilindro, fato comum para diversas variáveis em simulação. Deste modo, com o intuito de se obter o menor custo computacional possível com o menor erro possível do cálculo destes valores, comparam-se os resultados obtidos para diferentes refinamentos de malha, até que a variação do resultado seja desprezível (ROACHE, 1994).

Figura 5.1 – Teste de malha realizado com diferentes refinamentos



Fonte: O autor (2019).

Figura 5.2 – Comparação do efeito da malha nos treinamentos realizados




Fonte: O autor (2019).

Para este teste de malha, a malha foi criada com características diferentes da original, e foi simulado um escoamento no sistema, sem nenhuma ação de controladores. Como pode ser observado nas figuras 5.1 e 5.2, o coeficiente de arrasto e de sustentação para a malha original possuem uma curva periódica quando agem naturalmente, devido às vibrações induzidas por vórtices. Através destas figuras é possível observar que as malhas grosseira e muito grosseira são incapazes de obter o valor total dos coeficientes, devido as aproximações feitas por elementos maiores de malha. Observa-se porém uma mudança desprezível no comportamento das curvas dos coeficientes para a malha mais refinada, fato que permite a utilização da malha original de modo a se obter ganhos computacionais. Sobre o fato de a média do coeficiente de arrasto ser menor para as malhas mais grosseiras, ressalta-se o fato de que a força de arrasto é calculada ao redor do cilindro, e uma malha insuficiente ao redor deste impede o cálculo correto dessa força. Com relação ao coeficiente de sustentação, apesar da média continuar nula para as malhas grosseiras, a variação diminui, pelo mesmo motivo do caso anterior.


Para a justificativa do uso da simulação da malha original para a rede de 128 neurônios como valor de referência para todos os testes observados, apresenta-se a seguir, nas figuras 5.3 e 5.4, a simulação do escoamento base para os testes rede_128_vel e rede_128_probes_cilindro junto com o teste original, comparando os coeficientes de arrasto e sustentação, respectivamente.

Figura 5.3 – Comparação do C_D para três diferentes testes de rede neural.



Fonte: O autor (2019).


Figura 5.4 – Comparação do C_L para três diferentes testes de rede neural.



Fonte: O autor (2019).

Como pode ser visto comparando-se os gráficos das figuras 5.3 e 5.4, as variações do comportamento dos coeficientes de arrasto e sustentação são mínimas, justificando o uso da malha do teste_128 como referência em prol da redução do custo computacional. Na Figura 5.5 encontra-se representação da malha utilizada durante a simulação da rede_128.


Figura 5.5 – Malha utilizada para simulação do teste rede_128.



Fonte: O autor (2019).


Com relação à malha próxima aos cilindros rotativos implementados, obteve-se na Figura 5.6 a comparação entre dois diferentes tamanhos de malha, comprovando-se a possibilidade de utilização do tamanho de malha de 0.02 ao redor dos cilindros menores, fato que gera ganho computacional e garante o cálculo de todas as informações ao redor destes cilindros com erro desprezível. Observa-se por fim na Figura 5.7 a malha gerada com foco nos cilindros presentes no sistema.

Figura 5.6 – Teste de malha ao redor dos cilindros rotativos.



Fonte: O autor (2019).

Figura 5.7 – Malha do sistema com foco nos cilindros presentes.




Fonte: O autor (2019).

5.2. Teste das redes neurais artificiais para escoamento secundário

Com o fim da fase de treinamento, acumulou-se um tempo médio de 30 horas de simulação para o treinamento de cada rede neural, totalizando 210 horas para o treinamento de todos os testes propostos. Para um primeiro momento, serão apresentados os resultados da rede neural sem adaptações em relação à rede utilizada originalmente, apenas com um número reduzido de neurônios. Observam-se nas figuras 5.8 a 5.10 o histórico de treinamento da rede¹, a atuação da rede no controle do C_D , e a atuação no controle do C_L , respectivamente. Ressalta-se que o C_D médio indicado no treinamento da rede é a média temporal do coeficiente de arrasto em cada episódio.


Figura 5.8 – Histórico de treinamento para a rede_128, com indicação do melhor modelo obtido pela rede com um círculo vermelho.



Fonte: O autor (2019).


¹ Histórico em relação ao número de episódios, onde cada episódio é o período de tempo em que a rede atua no escoamento antes de analisar os resultados obtidos e realizar o aprendizado, tempo este definido como 2 segundos.

Figura 5.9 – C_D durante a atuação da rede_128 em comparação com o escoamento natural.



Fonte: O autor (2019).

Figura 5.10 – C_L durante a atuação da rede_128 em comparação com o escoamento natural.




Fonte: O autor (2019).

Na Figura 5.8, que contém o histórico de treinamento da rede, é possível observar o processo de aprendizado da rede neural através da queda do C_D médio ao longo dos primeiros 100 episódios, fato que demonstra a escolha de diversas ações possíveis com o fim de diminuir o coeficiente, firmando as escolhas que

favoreceram tal diminuição. Pode-se confirmar também o caráter randômico da exploração da atuação ideal pela rede neural através da variação do coeficiente médio de arrasto de cada episódio. Para a atuação real da rede neural no controle de um escoamento, esta utiliza o melhor modelo obtido, ou seja, o conjunto de ações no episódio que resultou no menor coeficiente de arrasto.


Pode-se observar nas figuras 5.9 e 5.10 a ação da rede neural na ativação do controle do escoamento realizado, incorrendo numa diminuição de aproximadamente 0.23 na média do coeficiente de arrasto, caindo de 2.85 para 2.62, diminuição que representa cerca de 8% do total. Para este teste em específico, mostra-se nas figuras 5.11 e 5.12 a comparação de velocidades ao final e ao início do escoamento, e nas figuras 5.13 e 5.14 a mesma comparação do campo de pressão.

Figura 5.11 – Velocidade do escoamento no momento inicial para a simulação da rede _128.




Fonte: O autor (2019).

Figura 5.12 – Velocidade do escoamento no momento final para a simulação da rede _128.




Fonte: O autor (2019).

Figura 5.13 – Campo de pressão do escoamento no momento inicial para a simulação da rede _128.



Fonte: O autor (2019).

Figura 5.14 – Campo de pressão do escoamento no momento final para a simulação da rede _128.



Fonte: O autor (2019).

Confirma-se então modificação da magnitude das velocidades, principalmente na esteira do escoamento, e diminuição da presença de pressões muito baixas na esteira. Observa-se também diminuição notória da diferença de magnitude de pressão em pontos alternados, indicando a presença de vórtices menos intensos pelo escoamento.

Devido à grande quantidade de testes realizados, serão apresentados na Tabela 5.1 os coeficientes de arrasto médio final obtido pela simulação de cada teste, junto com a redução relativa. As figuras de histórico de treino e atuação de cada rede poderá ser encontrada no apêndice A deste trabalho.

Tabela 5.1 – Eficiência de cada teste realizado no controle de escoamento por escoamento secundário junto com resultado obtido por Rabault et al.(2019).

Nome do teste	C_D médio final	Redução [%]
Resultado de Rabault et al. (2019)	2.95	7.95
Rede_128	2.95	7.95
rede_128_vel	2.98	7
rede_128-45	3.13	2.3
rede_128_jw30	2.95	7.95
rede_128_probes_reduzidos	2.945	8.1
rede_128_probes_cilindro	3.06	4.5
rede_128_probes_esteira	2.96	7.6

Fonte: O autor (2019).

A partir dos dados compilados na tabela apresentada, observa-se que, das redes que obtiveram eficácia igual ou semelhante, todas apresentam sensores na esteira do escoamento seja estes em grande quantidade ou não. Com relação aos dois testes com reduções relativas menores que 5%, justifica-se o resultado do teste da rede_128_probes_cilindro pela não observação de como a esteira do escoamento se desenvolvia, tendo apenas medidas nos arredores do cilindro. Já para o teste da rede_128-45, é possível que a força de sucção dos jatos não tenham sido suficientes para atrair o escoamento para a esteira, de modo a inibir a formação de vórtices, sendo as posições de 45° e 315° portanto menos atraentes para o controle de escoamento por escoamento secundário.


5.3. Teste das redes neurais artificiais com cilindros vibratórios

Por não ser o foco deste trabalho, apresenta-se no Apêndice B os resultados obtidos pela rede neural com controle por cilindros vibratórios.


5.4. Teste das redes neurais artificiais com cilindros rotativos

Em primeiro momento, destaca-se o fato de os treinamentos para as redes neurais para cilindros foram realizados em um computador com capacidade de processamento maior em relação ao utilizado para os testes de redes neurais para escoamento secundário. Foram realizados treinamentos de 350 episódios, 50 episódios a mais em relação aos treinamentos de escoamento secundário, e com redes com camadas de 512 neurônios, contra 128 das redes anteriores, visando garantir a convergência do treinamento da rede. Apesar disso, cada treinamento durou cerca de 29 horas de simulação. Apresenta-se nas figuras 5.15, 5.16 e 5.17 o histórico de treinamento da rede R_5_75, a atuação da rede no controle das forças de arrasto e atuação contra forças de sustentação, respectivamente, após tempo transiente de atuação.


Figura 5.15 – Histórico de treinamento para a rede R_5_75, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.



Fonte: O autor (2019).

Figura 5.16 – C_D durante a atuação da rede R_5_75

Fonte: O autor (2019).

Figura 5.17 – C_L durante a atuação da rede R_5_75

Fonte: O autor (2019).

A partir dos resultados apresentados, é possível perceber primeiramente a diminuição do coeficiente de arrasto médio do escoamento sem controle em relação ao escoamento sem controle dos casos sem a presença de cilindros rotativos. Tal diminuição, de 3.2 para aproximadamente 3.1, uma redução de 3.1%, é causada pela simples presença dos cilindros menores no sistema, que atuam como um

método de controle passivo e dificultam a formação de vorticidade. Ressalta-se que esta redução passiva, mesmo que pequena, é maior que a redução gerada pelo controle ativo por jatos em situações não propícias, como o caso rede_128-45, que obteve uma redução do coeficiente de arrasto de apenas 2.3%.

Pode-se notar através da Figura 5.15 que o treinamento da rede neural conseguiu alcançar um valor médio de C_D menor que as redes anteriores, fato que em primeiro momento indica um controle melhor do escoamento pelos cilindros rotativos. Ao se observar a Figura 5.16, porém, observa-se que apesar de realmente ocorrer uma diminuição notável da média do coeficiente de arrasto, de cerca de 15.7% em relação ao escoamento sem cilindros, há um grande aumento de sua oscilação, em quase 10 vezes. Pela Figura 5.17, observa-se ainda um pequeno aumento do coeficiente de sustentação, tanto no sentido positivo quanto no negativo.

Na Figura 5.18, que mostra a velocidade de rotação dos cilindros de controle, utiliza-se para facilitar a visualização o sentido horário de rotação como sentido positivo para ambos os cilindros. Devido à dependência de rotação dos dois cilindros, observa-se que ambos os cilindros rodam sempre “para dentro” do escoamento, variando apenas em sua velocidade.

Apresenta-se nas figuras de 5.19 a 5.22 a comparação entre os campos iniciais e finais de pressão e velocidade.

Figura 5.18 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75.






Figura 5.19 – Campo de pressão do escoamento no momento inicial para a simulação da rede R_5_75




Fonte: O autor (2019).

Figura 5.20 – Campo de pressão do escoamento no momento final para a simulação da rede R_5_75




Fonte: O autor (2019).

Figura 5.21 – Velocidade do escoamento no momento inicial para a simulação da rede R_5_75.



Fonte: O autor (2019).

Figura 5.22 – Velocidade do escoamento no momento final para a simulação da rede R_5_75.



Fonte: O autor (2019).

Em primeiro momento, é possível notar a diminuição do coeficiente de arrasto pelo aumento do nível de pressão no momento final da simulação em relação ao momento inicial.

Comparando-se estes resultados com os campos de velocidade e pressão da simulação com escoamento secundário, observa-se que apesar do coeficiente de arrasto ser menor para o caso com cilindros rotativos, com o método de escoamento secundário a inibição de vórtices foi muito maior. Pode-se supor então que a alta oscilação do coeficiente de arrasto para este caso é causada tanto pela rotação dos cilindros quanto pela vorticidade ainda presente.


5.5. Outros testes com cilindros rotativos

Nesta seção serão apresentados os resultados para treinamento com cilindros rotativos com rotação independente, para os testes de adaptabilidade da rede neural e para o teste de mudança da função objetivo da rede neural.

5.5.1. Cilindros com rotação independente

Realizando-se o treinamento da rede com rotação independente e mesma geometria dos testes anteriores, é possível verificar o impacto da independência de rotação no coeficiente de arrasto. Apresenta-se o histórico de treinamento da rede R_5_75_I na Figura 5.23, a atuação do método no controle dos coeficientes de arrasto e sustentação nas figuras 5.24 e 5.25 e a rotação dos cilindros durante o controle na Figura 5.26.


Figura 5.23 – Histórico de treinamento para a rede R_5_75_I, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.



Fonte: O autor (2019).


Através do histórico de treinamento da rede com rotação independente, é possível perceber um controle muito mais eficaz do coeficiente de arrasto em relação tanto ao controle por escoamento secundário quanto ao controle por cilindros dependentes. Tal eficácia é confirmada pela atuação da rede na Figura 5.24, chegando a um coeficiente médio próximo de 2.48, uma redução de cerca de 23%. Além disso, observa-se uma oscilação muito menor do que a observada na Figura 5.16.

Figura 5.24 – C_D durante a atuação da rede R_5_75_I




Fonte: O autor (2019).

Figura 5.25 – C_L durante a atuação da rede R_5_75_I



Fonte: O autor (2019).

Figura 5.26 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75_I




Fonte: O autor (2019).

No que diz respeito ao coeficiente de sustentação, a Figura 5.25 possui duas informações importantes. A primeira delas é a redução da variação deste coeficiente, de aproximadamente 0.8 para 0.18, e a segunda e mais notável, o deslocamento da média do coeficiente de valor nulo para o escoamento natural para -0.2 para o escoamento controlado. Esta observação condiz com o fato de que a alteração da direção do escoamento pode acarretar na diminuição do coeficiente de arrasto e reafirma a necessidade da utilização do coeficiente de sustentação na função objetivo da rede neural, de modo que esta não tente apenas mudar a direção do escoamento para diminuir o arrasto do sistema.

Comparando-se as figuras 5.24 e 5.25 com a Figura 5.26, é possível perceber o efeito da rotação dos cilindros nos coeficientes de arrasto e sustentação. Nota-se que, após o pico de velocidade no momento $t=2$, há uma oscilação constante de menor intensidade da rotação dos cilindros, dando a entender que a rede utiliza um primeiro esforço para chegar na melhor condição de escoamento obtida pelo treinamento e rotações menores apenas para manter este escoamento.


Apresenta-se nas figuras 5.27 e 5.28 os campos inicial e final de pressão do escoamento da rede R_5_75_I, e nas figuras 5.29 e 5.30 os campos de velocidade inicial e final.

Figura 5.27 – Campo de pressão do escoamento no momento inicial para a simulação da rede R_5_75_I.




Fonte: O autor (2019).

Figura 5.28 – Campo de pressão do escoamento no momento final para a simulação da rede R_5_75_I.




Fonte: O autor (2019).

Figura 5.29 – Velocidade do escoamento no momento inicial para a simulação da rede R_5_75_I.



Fonte: O autor (2019).

Figura 5.30 – Velocidade do escoamento no momento final para a simulação da rede R_5_75_I.



Fonte: O autor (2019).

Comparando-se os campos finais de pressão e velocidade da rede R_5_75_I com as redes R_5_75 (figuras 5.20 e 5.22) e rede_128 (figuras 5.14 e 5.12), conclui-se que, apesar de ter atuação superior em relação à rede com cilindros dependentes, a rede com cilindros independentes não foi capaz de suprimir tão bem a vorticidade como a rede com jatos, indicado pela variação de pressão ao longo do canal de escoamento. Tal fato é reforçado pelo coeficiente de arrasto possuir uma oscilação durante a atuação da rede com cilindros independentes, e possuir oscilação quase nula após atuação dos jatos, como visto na Figura 5.9.

5.5.2. Alteração da função objetivo


De modo a se analisar o efeito do coeficiente de sustentação na diminuição do coeficiente de arrasto, a rede R_5_75_I4 teve o peso do C_L dobrado na função objetivo da rede neural durante o treinamento, de 0.2 para 0.4. O histórico de treinamento desta rede se encontra na Figura 5.31, a atuação da rede no controle de escoamento nas figuras 5.32 e 5.33 e a rotação dos cilindros durante o controle na Figura 5.34.

Em primeiro momento, é possível perceber pelo histórico de treinamento que o melhor modelo obtido possui um C_D médio maior que o melhor obtido pela rede R_5_75_I, resultando em uma redução média de 21.4%, sendo que a redução do melhor modelo da rede sem alteração da função objetivo foi de 27.6%.

Comparando-se a atuação desta rede com a rede sem alteração, observa-se que ambas não atingem o coeficiente de arrasto médio do melhor modelo. Enquanto


a redução média para a rede alterada atuante foi de cerca de 15.8%, a da rede sem alteração foi próxima de 23%. Outra diferença notada entre os coeficientes de arrasto após atuação das redes é a maior oscilação deste coeficiente para a rede alterada, de 3.7% do valor médio, contra uma variação de 1.6% do valor médio para a rede sem alteração.

Figura 5.31 – Histórico de treinamento para a rede R_5_75_I04, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura 5.32 – C_D durante a atuação da rede R_5_75_I04




Fonte: O autor (2019).

Figura 5.33 – C_D durante a atuação da rede R_5_75_I04

Fonte: O autor (2019).

Figura 5.34 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_5_75_I04



Fonte: O autor (2019).

Analisando-se o coeficiente de sustentação da rede após atuação, obtém-se um coeficiente médio de 0.02, com variação de 0.18 para ambos os sentidos positivo e negativo. Tal resultado comprova a maior consideração da rede alterada em minimizar também a média deste coeficiente, além do coeficiente de arrasto. Tal resultado, porém, causa também um aumento do coeficiente de arrasto médio final

obtido, quando comparado com a rede sem alteração, sendo forte indício da tentativa da rede em diminuir o arrasto do escoamento através da mudança da direção do escoamento quando permitida. Nota-se portanto um preço a se pagar: ao tentar garantir simetria, perde-se na redução do arrasto.

Com o fim dos treinamentos das redes com cilindros rotativos, apresenta-se na Tabela 5.2 os resultados obtidos pelas redes com cilindros rotativos, estando os resultados em forma gráfica presente no Apêndice C deste trabalho.

Tabela 5.2 – Eficiência de cada teste realizado no controle de escoamento por cilindros rotativos.

Rede	C_D Médio Final	Redução (%)
R_5_75	2.72	15.1
R_5_75_I	2.48	22.6
R_5_75_I04	2.7	15.8
R_6_7	2.75	14.2
R_6_7_I	2.97	7.3

Fonte: O autor (2019).


5.5.3. Adaptabilidade da rede para mudança do número de Reynolds

Após os testes de adaptabilidade, utilizando a rede original de Rabault et al.(2019) e a rede R_5_75_I, obteve-se os resultados presentes nas tabelas 5.3, para a rede de jatos, e 5.4, para a rede com cilindros rotativos. Nota-se que o teste foi realizado até o número de Reynolds máximo suportado pela malha de cada rede neural. Ressalta-se que é possível aumentar o número de Reynolds máximo com um melhor refinamento da malha. Porém, por este não ser o objetivo principal deste trabalho, este refinamento não foi realizado.

Nota-se também que os resultados apresentados nas tabelas citadas são uma aproximação feita devido a uma característica do ambiente de simulação da rede neural. Tal característica faz com que no primeiro momento de criação da malha para simulação, seja realizado uma simulação do escoamento de modo que o momento inicial de cada simulação já contenha o escoamento desenvolvido. Como este escoamento inicial foi realizado com $Re = 100$, durante a atuação da rede para diferentes números de Reynolds, no instante imediatamente anterior à primeira computação pela rede o escoamento possui características do número de Reynolds original, fato que pode ter diminuído o coeficiente de arrasto final da atuação. Na

Figura 5.35 observa-se os coeficientes de arrasto para atuação da rede com cilindros rotativos para $Re = 120$. É possível observar um coeficiente de arrasto controlado muito mais baixo em relação ao coeficiente sem controle e perda de simetria do coeficiente de sustentação.

Figura 5.35 – Atuação da rede neural com cilindros rotativos e $Re = 120$.



Fonte: O autor (2019).

Tabela 5.3 – Aproximação dos coeficientes de arrasto reais e redução pela rede atuante para rede com jatos e variação do número de Reynolds.

Nº Reynolds	Média C_D sem controle	Média C_D controlado aproximado	Redução [%]
100	3.2	2.95	7.8
110	3.5	3.23	7.7
120	3.8	3.53	7.1
130	4.1	3.87	5.6
140	4.4	4.28	2.7
150	4.72	4.57	3.1

Fonte: O autor (2019).

Tabela 5.4 – Aproximação dos coeficientes de arrasto reais e redução pela rede atuante para rede com cilindros rotativos independentes e variação do número de Reynolds.

Nº Reynolds	Média C_D sem controle	Média C_D controlado aproximado	Redução [%]
100	3.1	2.48	20
110	3.37	2.84	15.7
120	3.65	3.14	13.9
130	3.96	3.42	13.6
140	4.26	3.59	15.7
150	4.55	3.88	14.7
160	4.9	4.05	17.4

Fonte: O autor (2019).

A partir dos resultados aproximados, é possível observar que para ambos os métodos de controle a rede é capaz de reduzir o coeficiente de arrasto médio no escoamento, apesar de ter menor eficiência em relação ao escoamento com Reynolds = 100. Tal capacidade pode ser justificada pela característica da esteira de cilindros, já que o desprendimento de vórtices é recorrente em qualquer número de Reynolds a partir de ~47 para cilindros, com variação da intensidade e frequência de desprendimento com a variação do número de Reynolds. Tal recorrência de desprendimento de vórtices permite a rede neural reagir adequadamente ao desprendimento, tentando atenuar a intensidade dos vórtices com a ação dos jatos ou dos cilindros rotativos. Isto acaba resultando na redução do arrasto para os Reynolds testados.

No Apêndice D estão presentes todos os resultados das tabelas 5.4 e 5.5 em forma gráfica, semelhante à Figura 5.35.

6. CONCLUSÃO

A partir dos resultados obtidos, confirma-se a capacidade da rede neural de analisar, aprender e controlar a ativação de um par de jatos de modo a realizar o controle de um escoamento ao redor de um cilindro, além de se obter justificativas que ajudam a diminuir o custo computacional durante o treinamento destas redes.

Com a implementação dos cilindros rotativos e a utilização da rede neural para ativação dos mesmos, fica evidente a superioridade do uso de cilindros rotativos em relação aos jatos no controle de escoamento, ao se analisar puramente a redução obtida. Ressalta-se porém que, levando em conta a inibição da vorticidade, o uso de cilindros rotativos não foi tão eficaz quanto o uso de jatos. Pode-se justificar este resultado pelas limitações da malha utilizada, que limitaram a rotação máxima dos cilindros durante o treinamento da rede neural, já que o limite possível foi de $U_c/U = 3$, e a literatura (MITTAL, 2001; KORKISCHKO; MENEHINI, 2012) indica $U_c/U = 5$ como velocidade capaz de inibir a geração de vórtices. Considera-se porém que outros fatores devem ser levados em conta na escolha de um sistema de controle real, que não foram abordados até o presente momento, como o custo energético de ativação do método de controle, o custo de implementação e a capacidade do sistema de atuar com um número reduzido de sensores, de modo a tornar este sistema aplicável em uma situação real.

Com relação aos outros testes realizados, primeiramente percebe-se através do treinamento de redes com cilindros independentes que tal característica é benéfica para o controle por cilindros rotativos, permitindo um controle mais eficiente do escoamento. É possível concluir também a sensibilidade da rede neural em relação à função objetivo utilizada para o treinamento, função que, com o aumento de 20% do impacto do coeficiente de sustentação (um aumento de 100% em relação à função objetivo original) quase anula a média deste coeficiente após a atuação. Por fim, com os testes de adaptabilidade da rede neural, apesar da obtenção de resultados aproximados, conclui-se que o contínuo aumento do número de Reynolds causa uma perda de eficiência do método de controle. Tal conclusão gera uma consequência importante: a possibilidade de se realizar o treinamento da rede de controle em Reynolds baixos, com custos computacionais muito mais baratos, e uso desta rede em qualquer condição. Apesar de esta ser uma extrapolação muito

prática para a indústria, é necessário uma confirmação sistemática em faixas de Reynolds mais altas.

Para trabalhos futuros, sugerem-se dois pontos principais de estudo a partir deste trabalho. O primeiro é a implementação de uma rede neural para controle de vários cilindros rotativos, similar ao modelo de Assi, Orselli e Ortega (2019), de modo que seja possível realizar o controle de escoamento omnidirecional. O segundo ponto, levando em conta os teste de adaptabilidade da rede, é a avaliação de quais intervalos de Reynolds a rede é capaz de manter um controle com eficácia semelhante. Tal estudo seria interessante para estudos de viabilidade e principalmente de confiança do funcionamento da rede em situações reais, com variação do escoamento.

Por fim, ressalta-se a presença dos resultados não exibidos para redes neurais de controle por escoamento no Apêndice A, controle por cilindros vibratórios no Apêndice B, cilindros rotativos no apêndice C e testes de adaptabilidade da rede no Apêndice D, sendo que todos indicam e suportam as conclusões e discussões desenvolvidas no corpo do texto.

REFERÊNCIAS

- ABADI, M.; BARHAM, P.; CHEN, J.; CHEN, Z.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; IRVING, G.; ISARD, M. & OTHERS Tensorflow: A system for large-scale machine learning. In OSDI, vol. 16, p. 265–283. 2016.
- ASSI, G. R. S.; ORSELLI, R. M.; SILVA-ORTEGA, M. Control of vortex shedding from a circular cylinder surrounded by eight rotating wake-control cylinders at $Re=100$. **Journal of Fluids and Structures**, in press, 2019.
- ALNAES, M.S.; BLECHTA, J.; HAKE, J.; JOHANSSON, A.; KEHLET, B.; LOGG, A.; RICHARDSON, C.; RING, J.; ROGNES, M. R.; WELLS, G. N. The FEniCS Project Version 1.5. **Archive of Numerical Software**, vol. 3, 2015.
- CHOI, H.; JEON, W.-P.; KIM, J. Control of Flow Over a Bluff Body. **Annual Review of Fluid Mechanics**, v. 40, n. 1, p. 113–139, 2008.
- DEHKORDI, E. K.; GOODARZI, M.; NOURBAKHSH, S. H. Optimal active control of laminar flow over a circular cylinder using Taguchi and ANN. **European Journal of Mechanics, B/Fluids**, v. 67, p. 104–115, 2018.
- DERAKHSHANDEH, J. F.; ALAM, M. M. A review of bluff body wakes. **Ocean Engineering**, v. 182, p. 475–488, 2019.
- FUJISAWA, N.; NAKABAYASHI, T. Neural network control of vortex shedding from a circular cylinder using rotational feedback oscillations. **Journal of Fluids and Structures**, v. 16, n. 1, p. 113–119, 2002.
- GAD-EL-HAK, M.; BUSHNELL, D. M. Separation Control: Review. **Journal of Fluids Engineering**, v. 113, n. 1, p. 5, 2008.
- GERRARD, J. H. The mechanics of the formation region of vortices behind bluff bodies. **Journal of Fluid Mechanics**, v. 25, n. 2, p. 401-413, 1966.
- GEUZAIN, C.; REMACLE, J. Gmsh: A 3-d finite element mesh generator with built-in pre-and post-processing facilities. **International journal for numerical methods in engineering**, v. 79 n.11, p. 1309–1331. 2009.
- GODA, K. A multistep technique with implicit difference schemes for calculating two- or three-dimensional cavity flows. **Journal of Computational Physics**, v. 30, n. 1, p. 76–95, 1979.
- GUNZBURGER, M. D. **Finite Element Methods for Viscous Incompressible Flows**. [s.l.] Elsevier, 1989.
- HAYKIN, S. **Redes neurais: Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2002.
- HIRSCH, C. **Numerical Computation of Internal and External Flows**. Vol 1 and 2, 2nd edition, 2007.

KORKISCHKO, I.; MENEHINI, J. R. Suppression of vortex-induced vibration using moving surface boundary-layer control. **Journal of Fluids and Structures**, v. 34, p. 259–270, 2012.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015.

LOGG, A.; MARDAL, K.-A.; WELLS, G. N. Automated Solution of Differential Equations by the Finite Element Method — FEniCS Project. 2015.

LOGG, A.; WELLS, G.N. DOLFIN: Automated Finite Element Computing. **ACM Transactions on Mathematical Software**, vol. 37, 2012.

MENEHINI, J. R. **Projetos de pesquisa no t pico gera  o e desprendimento de v rtices no escoamento ao redor de cilindros** [tese]. S o Paulo: Escola Polit cnica, Universidade de S o Paulo; 2002.

MITTAL, S. Control of flow past bluff bodies using rotating control cylinders. **Journal of Fluids and Structures**, v. 15, n. 1, p. 291–326, 2001.

MODI, V. J. Moving surface boundary-layer control: A review. **Journal of Fluids and Structures**, v. 11, n. 6, p. 627–663, 1997.

NANDY, A.; BISWAS, M. **Reinforcement Learning**. Berkeley, CA: Apress, 2018

NORBERG, C. Fluctuating lift on a circular cylinder: Review and new measurements. **Journal of Fluids and Structures**, v. 17, n. 1, p. 57–96, 2003.

OERTEL, H. Wakes Behind Blunt Bodies. **Annual Review of Fluid Mechanics**, v. 22, n. 1, p. 539–562, 1990.

ORTEGA, M.S. **Suppression of vortex-induced vibration of a circular cylinder with fixed and rotating control cylinders** [tese]. S o Paulo: Escola Polit cnica, Universidade de S o Paulo; 2015.

PATINO, G. A.; GIORIA, R. S.; MENEHINI, J. R. Evaluating the control of a cylinder wake by the method of sensitivity analysis. **Physics of Fluids**, v. 29, n. 4, 2017.

PATNAIK, B. S. V.; WEI, G. W. Controlling Wake Turbulence. **Physical Review Letters**, v. 88, n. 5, p. 1-4, 2002.

Potter, M. C.; Wiggert, D. C. **Mec nica dos Fluidos**, Thomson, 2004.

RABAULT, J.; REGLADE, U.; CERARDI, N.; KUHTA, M.; JENSEN, A. Deep Reinforcement Learning achieves flow control of the 2D Karman Vortex Street. 2018.

RABAULT, J.; KUHTA, M.; JENSEN, A.; REGLADE, U.; CERARDI, N. Artificial neural networks trained through deep reinforcement learning discover control strategies for active flow control. **Journal of Fluid Mechanics**, v. 865, p. 281–302,

2019.

RASHIDI, S.; HAYATDAVOODI, M.; ESFAHANI, J. A. Vortex shedding suppression and wake control: A review. **Ocean Engineering**, v. 126, p. 57–80, 2016.

ROACHE, P. J. Perspective: A Method for Uniform Reporting of Grid Refinement Studies. **Journal of Fluids Engineering**, v. 116, n. 3, p. 405-413, 1994.

SCHAARSCHMIDT, M.; KUHNLE, A.; FRICKE, K. Tensorforce: A tensorflow library for applied reinforcement learning. Web page. 2017

SCHULMAN, J., WOLSKI F., DHARIWAL, P., RADFORD, A., KLIMOV, O. Proximal Policy Optimization Algorithms. 2017.

SHIN, Y.-S.; COHEN, K.; SIEGEL, S.; SEIDEL, J.; MCLAUGHLIN, T. Neural Network Estimator for Closed-Loop Control of a Cylinder Wake. In: AIAA GUIDANCE, NAVIGATION, AND CONTROL CONFERENCE AND EXHIBIT, Keystone, Colorado, 2006.

WILLIAMSON, C. H. K. Vortex Dynamics in the Cylinder Wake. **Annual Review of Fluid Mechanics**, v. 28, n. 1, p. 477–539, 1996.

ZDRAVKOVICH, M. M. Review and classification of various aerodynamic and hydrodynamic means for suppressing vortex shedding. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 7, n. 2, p. 145–189, 1981.

ZHU, H.; GAO, Y. Vortex-induced vibration suppression of a main circular cylinder with two rotating control rods in its near wake: Effect of the rotation direction. **Journal of Fluids and Structures**, v. 74, p. 469–491, 2017.

ZWINTZSCHER, P.; GOMÉZ, F.; BLACKBURN, H. M. Data-driven control of the turbulent flow past a cylinder. **Journal of Fluids and Structures**, in press, 2019.

APÊNDICE A – Testes de Escoamento Secundário

Encontram-se neste apêndice os parâmetros que diferenciam os diferentes testes realizados, junto com os resultados de cada teste.

Tabela A1 – Parâmetros Originais de Simulação

Parâmetro	Valor Original
Nº Neurônios por camada	512
Posição dos jatos	90° e 180°
Largura de atuação do jato	10°
Número de sensores	151
Tipo de sensor	Velocidade

Fonte: O autor (2019).


Tabela A2 – Testes de treinamento realizados.

Nome do teste	Parâmetro modificado	Valor modificado
rede_128	Nº Neurônios por camada	128
rede_128_vel	Tipo de sensor	Velocidade
rede_128-45	Posição dos jatos	45° e 315°
rede_128_jw30	Largura de atuação do jato	30°
rede_128_probes_reduzidos	Número de sensores	37, bem distribuídos
rede_128_probes_cilindro	Número de sensores	36, ao redor do cilindro
rede_128_probes_esteira	Número de sensores	36, concentrados na esteira

Fonte: O autor (2019).


1. Rede_128_vel

Figura A1 – Histórico² de treinamento da rede_128_vel, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.



Fonte: O autor (2019).


Figura A2 – C_D durante a atuação da rede_128_vel em comparação com o escoamento natural.



Fonte: O autor (2019).

² Históricos em relação ao número de episódios, onde cada episódio é o período de tempo em que a rede atua no escoamento antes de analisar os resultados obtidos e realizar o aprendizado, tempo este definido como 2 segundos.


Figura A3 – C_L durante a atuação da rede_128_vel em comparação com o escoamento natural.



Fonte: O autor (2019).


2. Rede_128-45

Figura A4 – Histórico de treinamento da rede_128-45, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura A5 – C_D durante a atuação da rede_128-45 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura A6 – C_L durante a atuação da rede_128-45 em comparação com o escoamento natural.



Fonte: O autor (2019).


3. Rede_128_jw30

Figura A7 – Histórico de treinamento da rede_128_jw30, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura A8 – C_D durante a atuação da rede_128_jw30 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura A9 – C_L durante a atuação da rede_128_jw30 em comparação com o escoamento natural.



Fonte: O autor (2019).


4. Rede_128_probes_reduzidos

Figura A10 – Histórico de treinamento da rede_128_probes_reduzidos, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura A11 – C_D durante a atuação da rede_128_probes_reduzidos em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura A12 – C_L durante a atuação da rede_128_probes_reduzidos em comparação com o escoamento natural.



Fonte: O autor (2019).


5. Rede_128_probes_cilindro

Figura A13 – Histórico de treinamento da rede_128_probes_cilindro, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura A14 – C_D durante a atuação da rede_128_probes_cilindro em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura A15 – C_L durante a atuação da rede_128_probes_cilindro em comparação com o escoamento natural.



Fonte: O autor (2019).


6. Rede_128_probes_esteira

Figura A16 – Histórico de treinamento da rede_128_probes_esteira, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura A17 – C_D durante a atuação da rede_128_probes_esteira em comparação com o escoamento natural.



Fonte: O autor (2019).

Figura A18 – C_L durante a atuação da rede_128_probes_esteira em comparação com o escoamento natural.



Fonte: O autor (2019).

APÊNDICE B – Testes de Cilindros Vibratórios

Encontram-se neste apêndice os parâmetros que diferenciam os diferentes testes realizados, na tabela B1, a compilação dos resultados na tabela B2 e os resultados gráficos de cada rede treinada.

Tabela B1 – Testes de treinamento realizados.

Nome do Teste	Diâmetro do cilindro de controle	Gap
V_5_1	0.05D	0.01D
V_5_7	0.05D	0.07D
V_5_7.5	0.05D	0.075D
V_5_9	0.05D	0.09D
V_6_1	0.06D	0.01D
V_6_7	0.06D	0.07D
V_6_7.5	0.06D	0.075D
V_6_9	0.06D	0.09D

Fonte: O autor (2019).


Tabela B2 – Eficiência de cada teste realizado no controle de escoamento por cilindros vibratórios.

Rede	C_D Médio Final	Redução (%)
V_5_1	3.1	3.3
V_5_7	2.99	6.7
V_5_7.5	3.03	5.5
V_5_9	3.01	6.1
V_6_1	3.04	5.1
V_6_7	2.97	7.3
V_6_7.5	2.97	7.3
V_6_9	3.02	5.8

Fonte: O autor (2019).


1. V_5_1

Figura B1 – Histórico de treinamento da rede V_5_1, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B2 – C_D durante a atuação da rede V_5_1 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B3 – C_L durante a atuação da rede V_5_1 em comparação com o escoamento natural.



Fonte: O autor (2019).


2. V_5_7

Figura B4 – Histórico de treinamento da rede V_5_7, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B5 – C_D durante a atuação da rede V_5_7 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B6 – C_L durante a atuação da rede V_5_7 em comparação com o escoamento natural.



Fonte: O autor (2019).


3. V_5_75

Figura B7 – Histórico de treinamento da rede V_5_75, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B8 – C_D durante a atuação da rede V_5_75 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B9 – C_L durante a atuação da rede V_5_75 em comparação com o escoamento natural.



Fonte: O autor (2019).


4. V_5_9

Figura B10 – Histórico de treinamento da rede V_5_9, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B11 – C_D durante a atuação da rede V_5_9 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B12 – C_L durante a atuação da rede V_5_9 em comparação com o escoamento natural.



Fonte: O autor (2019).


5. V_6_1

Figura B13 – Histórico de treinamento da rede V_6_1, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B14 – C_D durante a atuação da rede V_6_1 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B15 – C_L durante a atuação da rede V_6_1 em comparação com o escoamento natural.



Fonte: O autor (2019).


6. V_6_7

Figura B16 – Histórico de treinamento da rede V_6_7, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B17 – C_D durante a atuação da rede V_6_7 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B18 – C_L durante a atuação da rede V_6_7 em comparação com o escoamento natural.



Fonte: O autor (2019).


7. V_6_75

Figura B19 – Histórico de treinamento da rede V_6_75, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B20 – C_D durante a atuação da rede V_6_75 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura B21 – C_L durante a atuação da rede V_6_75 em comparação com o escoamento natural.



Fonte: O autor (2019).


8. V_6_9

Figura B22 – Histórico de treinamento da rede V_6_9, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura B23 – C_D durante a atuação da rede V_6_9 em comparação com o escoamento natural.



Fonte: O autor (2019).

Figura B24 – C_L durante a atuação da rede V_6_9 em comparação com o escoamento natural.



Fonte: O autor (2019).

APÊNDICE C – Testes de Cilindros Rotativos

Encontram-se neste apêndice os parâmetros que diferenciam os diferentes testes realizados, junto com os resultados de cada teste.


Tabela C1 – Testes de treinamento realizados.

Nome do Teste	Diâmetro do cilindro de controle	Gap
R_6_7	0.06D	0.07D
R_6_7_I	0.06D	0.07D

Fonte: O autor (2019).


1. R_6_7

Figura C1 – Histórico de treinamento da rede R_6_7, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura C2 – C_D durante a atuação da rede V_6_7 em comparação com o escoamento natural.




Fonte: O autor (2019).

Figura C3 – C_L durante a atuação da rede V_6_7 em comparação com o escoamento natural.



Fonte: O autor (2019).


Figura C4 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_6_7.



Fonte: O autor (2019).


2. R_6_7_I

Figura C5– Histórico de treinamento da rede R_6_7_I, junto de indicação do melhor modelo obtido pela rede com um círculo vermelho.




Fonte: O autor (2019).

Figura C6 – C_D durante a atuação da rede V_6_7_I em comparação com o escoamento natural.




Fonte: O autor (2019).

Figura C7 – C_L durante a atuação da rede V_6_7_I em comparação com o escoamento natural.



Fonte: O autor (2019).

Figura C8 – Velocidade de rotação dos cilindros durante o controle do escoamento pela rede R_6_7_I.



Fonte: O autor (2019).


APÊNDICE D – Testes de Adaptabilidade da Rede Neural

A seguir encontram-se os resultados do teste de adaptabilidade das redes neurais com controle por jatos e por cilindros, com variação do número de Reynolds.

1. Escoamento Secundário

Figura D1 – Atuação da rede neural com escoamento secundário e $Re = 110$.


Reynolds = 110



Fonte: O autor (2019).


Figura D2 – Atuação da rede neural com escoamento secundário e $Re = 120$.

Reynolds = 120




Fonte: O autor (2019).

Figura D3 – Atuação da rede neural com escoamento secundário e $Re = 130$.




Fonte: O autor (2019).

Figura D4 – Atuação da rede neural com escoamento secundário e $Re = 140$.



Fonte: O autor (2019).


Figura D5 – Atuação da rede neural com escoamento secundário e $Re = 150$.



Fonte: O autor (2019).

2. Cilindros Rotativos


Figura D6 – Atuação da rede neural com cilindros rotativos e $Re = 110$.



Fonte: O autor (2019).

Figura D7 – Atuação da rede neural com cilindros rotativos e $Re = 120$.


Reynolds = 120



Fonte: O autor (2019).

Figura D8 – Atuação da rede neural com cilindros rotativos e $Re = 130$.


Reynolds = 130



Fonte: O autor (2019).

Figura D9 – Atuação da rede neural com cilindros rotativos e $Re = 140$.


Reynolds = 140



Fonte: O autor (2019).

Figura D10 – Atuação da rede neural com cilindros rotativos e $Re = 150$.


Reynolds = 150



Fonte: O autor (2019).

Figura D11 – Atuação da rede neural com cilindros rotativos e $Re = 160$.

Reynolds = 160



Fonte: O autor (2019).

Anexo A – Artigo Síntese

Segue o artigo síntese referente a este trabalho nas páginas adiante.



Controle ativo de escoamento ao redor de um cilindro fixo através do uso de cilindros rotativos e redes neurais

Vitor Takata

Orientador: Prof. Dr. Rafael dos Santos Gioria

Artigo Sumário referente à disciplina PMI1096 – Trabalho de Formatura para Engenharia de Petróleo II

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

Template versão 2018v11.

Resumo

O trabalho proposto possui como objetivo efetivar o controle de escoamento ao redor de um cilindro fixo utilizando cilindros rotativos com redes neurais para sua ativação. Para isto, utiliza-se uma rede neural de aprendizado profundo, implementada em Tensorforce, utilizando a plataforma computacional FEniCS Project pra realização das simulações de escoamento. São realizados testes tanto de capacidade de malha quanto de funcionamento da rede neural, junto com implementação da rede neural para controle de cilindros rotativos, com diversas geometrias. Após treinamento das redes neurais, são realizados testes com parâmetros de rotação dos cilindros, adaptabilidade da rede neural para escoamentos variados e sensibilidade da função objetivo da rede neural. Obtém-se uma rede neural com cilindros rotativos capaz de reduzir em cerca de 23% as forças de arrasto em um cilindro fixo. Além disso, confirma-se a superioridade do uso de cilindros rotativos com rotação independente para controle, diminuindo tanto a força média de arrasto exercida sobre um cilindro quanto a oscilação desta força.

Abstract

The present work aims to accomplish the flow control around a fixed cylinder using rotating cylinders as the control method, and a neural network to activate the control of these cylinders. A deep learning neural network is implemented on Tensorforce, using the FeniCS Project platform for the flow simulations. Mesh quality and neural network functionality are tested before the implementation of the neural network for flow control with different geometries of rotating cylinders. After the neural network training is done, rotating parameters, adaptability for different flow conditions and objective function sensibility are tested. A neural network capable of controlling rotating cylinder to perform flow control, capable of reducing drag forces around a fixed cylinder by 23% is obtained as result. Furthermore, the superiority of independently rotating cylinders for flow control is confirmed, reducing both the average drag forces around a fixed cylinder and its amplitude of oscillation.

1. Introdução

Com o alcance de águas cada vez mais profundas pela indústria do petróleo, o estudo das interações entre as instalações marinhas e os elementos da natureza, como o vento e a água do mar, requer um amplo estudo de modo a garantir a integridade destas instalações. Uma das interações mais comuns nesta área, o escoamento ao redor de cilindros fixos é recorrente em diversas estruturas offshore, como plataformas monocolunas e Spars, pernas de plataformas submersíveis e risers. Dentre as possíveis causas de falha das estruturas, cita-se as forças de arrasto e sustentação, exercidas pelo escoamento, e a ressonância da estrutura com vibração causada pelo desprendimento de vórtices pela esteira do escoamento (PATINO; GIORIA; MENEZHINI, 2017. RABAULT et al., 2019).

Com o objetivo de reduzir essas forças causadas pelo escoamento, diversos métodos de controle de escoamento foram propostos na literatura. Tais métodos de controle podem ser classificados em controle

passivo, quando não há o uso de energia externa para realização do controle, e controle ativo, quando há o uso de energia externa. Enquanto os métodos de controle passivo são geralmente mudanças de geometria de estruturas ou pequenas estruturas fixas instaladas ao longo da esteira do escoamento, o controle ativo pode ser realizado por escoamento secundário a partir de jatos ou com uso de cilindros rotativos de controle, por exemplo. Além disso, o controle ativo de escoamento recebe duas classificações, de circuito aberto, quando sua ativação é constante ou periódica com frequência definida, ou circuito fechado, quando ocorre uma interação com o escoamento de ação, observação do resultado da ação e definição da próxima ação (RASHIDI; HAYATDAVOODI; ESFAHANI, 2016).

Um método ativo de controle de escoamento, o método de Controle de Camada Limite de Superfície Móvel (MSBC, em inglês), utiliza de cilindros rotativos para injetar momento na fronteira da camada limite do escoamento, retardando a separação e inibindo vorticidade. Um dos principais parâmetros de controle é a razão entre a velocidade tangencial no cilindro rotativo e a velocidade média do escoamento, recebendo a notação U_c/U (PATNAIK; WEI, 2002).

Diversos autores estudaram os diversos parâmetros deste método. Mittal (2001) realizou testes computacionais para escoamentos com número de Reynolds 100 e 10000, com cilindros posicionados a 90° e 180° em relação à jusante do escoamento, chegando à conclusão de que para Reynolds = 100, com $U_c/U = 5$ é possível inibir a vorticidade da esteira, sendo que para Reynolds = 10000, apesar de não ter sido possível eliminar totalmente a vorticidade, com $U_c/U = 5$ ela foi drasticamente reduzida.

Korkischko e Meneghini (2012) realizaram testes experimentais de atuação dos cilindros rotativos no controle de escoamento, para Reynolds entre 1600 e 7500, com um intervalo da razão U_c/U entre 5 e 10. Foi observado uma diminuição do arrasto médio em cerca de 60% para a razão $U_c/U = 5$, tendo boa concordância com o experimento computacional de Mittal (2001).

Patino, Gioria e Meneghini (2017) desenvolveram um estudo computacional para estabelecer parâmetros ótimos para o controle de escoamento por cilindros rotativos em um escoamento com Reynolds = 50 ao redor de um cilindro fixo de diâmetro D . Foi obtido um diâmetro $d = 0.06D$ para os cilindros de controle, uma distância de $0.07D$ entre os cilindros de controle e o cilindro fixo e uma rotação mínima $U_c/U = 1.89$.

Assi, Orselli e Ortega (2019) experimentaram computacionalmente um arranjo de cilindros rotativos composto pelo cilindro principal de diâmetro D e oito cilindros de controle com diâmetro $0.05D$, espalhados de forma homogênea ao redor do cilindro fixo. Para $Re = 100$, o sistema foi capaz de impedir o desprendimento de vórtices para $U_c/U > 3$, havendo porém uma resultante alta de forças de sustentação no sistema. Nota-se que tal arranjo gera a possibilidade do método de controle ser omnidirecional, podendo controlar o escoamento independente da direção de incidência de corrente.

Uma das dificuldades para a ativação do controle ativo de escoamento de circuito fechado é o tempo de simulação do escoamento, fato que faz com que uma ação seja tomada tarde demais para uma observação feita. De modo a reduzir este tempo de reação do controle, redes neurais podem ser utilizadas para, após realização de um treinamento, avaliar o escoamento e definir uma ação para o controle do escoamento observado em tempo real (RABAULT et al., 2019). Como uma prova de conceito desta ideia, Rabault et al. desenvolveram uma rede neural de aprendizado profundo que é capaz de observar um escoamento e ativar dois jatos sintéticos, de modo a controlar o escoamento através de escoamento secundário. Tal rede foi capaz de reduzir as forças de arrasto no cilindro principal em cerca de 8%, além de diminuir significativamente a vorticidade da esteira.

Este trabalho tem portanto o objetivo de implementar uma rede neural capaz de acionar o controle de escoamento por cilindros rotativos, além de testes de adaptabilidade da rede neural. Realiza-se também testes de refinamento de malha e de sensibilidade da função objetivo da rede neural.

2. Metodologia

De modo a realizar as simulações necessárias para este trabalho, utiliza-se a plataforma de elementos finitos *FEniCS Project* (LOGG et al., 2012, ALNAES et al., 2015). Tal plataforma é utilizada para resolução das equações de Navier-Stokes:

$$\frac{\partial \mathbf{u}}{\partial t} + \mathbf{u} \cdot \nabla \mathbf{u} = -\nabla p + \frac{1}{Re} \nabla^2 \mathbf{u} \quad (1)$$

$$\nabla \cdot \mathbf{u} = 0 \quad (2)$$

Para implementação da rede neural, utiliza-se o *Tensorflow* (Abadi et al., 2016) para definição da rede neural, e o *Tensorforce* (Schaarschmidt et al., 2017), uma biblioteca open source do *Tensorflow*, para implementação do agente de aprendizado.

Apresenta-se na figura 1 a representação do ambiente de simulação de Rabault et al. (2019), com o cilindro fixo em branco, os jatos de controle em vermelho e os 151 sensores em preto.




Figura 1 - Ambiente de simulação, adaptado de (Rabault et al., 2019)




Figura 2 – Cilindros de controle implementados.

Para o aprendizado da rede neural, utiliza-se a função objetivo descrita pela equação (3):

$$r_t = -\langle C_D \rangle_T - 0.2|\langle C_L \rangle_T| \quad (3)$$

onde r_t é o valor a ser maximizado, C_D é o coeficiente de arrasto, C_L o coeficiente de sustentação e $\langle X \rangle_T$ indica o valor médio de X ao longo de tempo T . Deste modo, a função objetivo busca reduzir a média do coeficiente de arrasto, mantendo a média do coeficiente de sustentação próxima de nula, evitando quebra de simetria. O aprendizado foi realizado durante 350 episódios, onde cada episódio é o período de tempo em que a rede atua no escoamento antes de analisar os resultados obtidos e realizar o aprendizado. O tempo de cada episódio é definido como 2 segundos, correspondendo a 6.5 vezes o período de desprendimento de vórtices para Reynolds igual a 100.

Devido ao desconhecimento dos reais valores dos coeficientes de arrasto e sustentação ao redor do cilindro, fato comum para diversas variáveis em simulação, foi realizado um teste de refinamento de malha de modo a se obter uma malha que fosse capaz de calcular as forças exercidas no cilindro com o menor erro possível, minimizando também o custo computacional (ROACHE, 1994). Com tal teste realizado, foi utilizado para este trabalho uma malha contendo 9640 elementos finitos.

3. Estudos de caso

3.1. Cilindros Rotativos

Realizados os testes de malha, implementou-se os cilindros rotativos ao ambiente de simulação. Apresenta-se na figura 2 a malha da simulação com foco nos cilindros presentes.

Foram realizados dois treinamentos principais, ambos com a mesma geometria. Tal geometria consiste do cilindro principal de diâmetro D , cilindros de controle com diâmetro $0.05D$, posicionados a 45° e -45° em relação à jusante do escoamento, de gap, ou seja, distancia entre os cilindros, de $0.075D$. A diferença entre os dois treinamentos foi que, enquanto no primeiro (nomeado como R_5_75) os cilindros de controle possuem rotação dependente, no segundo teste (R_5_75_I) cada cilindro pode rotacionar

independentemente do outro cilindro. Nota-se que os treinamentos foram limitados à uma velocidade $U_C/U = 3$, devido à capacidade da malha utilizada.

3.2. Adaptabilidade da Rede Neural

Para o teste de adaptabilidade de rede neural, foi utilizado a rede R_5_75_I treinada. Começando por Reynolds = 100, que é a condição de treinamento, realizou-se a atuação da rede no controle de escoamento variando-se o número de Reynolds de 10 em 10, até se chegar a um número de Reynolds que a malha utilizada não fosse capaz de computar corretamente, que para este caso foi Reynolds = 160. Comparou-se então o coeficiente de arrasto médio após cada atuação com o coeficiente médio do escoamento sem controle para o respectivo número de Reynolds.

3.3. Sensibilidade da Função Objetivo

Sabendo-se através da equação (3) que a função objetivo da rede neural considera um fator de 0.2 do coeficiente de sustentação durante o treinamento, foi realizado um teste alterando-se a função objetivo, aumentando o impacto do coeficiente de sustentação em 100%, de modo a se analisar como esta mudança atua no controle de escoamento, mais especificamente na manutenção da média nula da sustentação. O treinamento foi realizado com a geometria da rede R_5_75, e a equação (4) representa a nova função objetivo utilizada neste teste.

$$r_t = -\langle C_D \rangle_T - 0.4|\langle C_L \rangle_T| \quad (4)$$

4. Resultados

Apresentam-se os resultados obtidos para cada estudo de caso a seguir.

4.1. Cilindros Rotativos

Com a malha decidida, os cilindros rotativos implementados e o treinamento da rede neural durante 350 episódios, obtém-se um modelo considerado pela rede como o melhor modo de controlar o escoamento. Ressalta-se o caráter aleatório do treinamento, sendo possível a rede encontrar um melhor modelo diferente do encontrado por este trabalho caso seja realizado um novo treinamento. Encontram-se nas figuras 3 e 4 o controle realizado pela rede neural treinada durante um episódio, sendo a figura 3 contendo a atuação da rede R_5_75 e a figura 4 a da rede R_5_75_I.

Observa-se que, apesar das duas redes serem capazes de reduzir o coeficiente médio de arrasto, a rede R_5_75 causa um aumento da amplitude de oscilação deste coeficiente, enquanto a rede R_5_75_I causa uma diminuição maior do coeficiente médio e uma amplitude menor de oscilação. Com relação ao coeficiente de sustentação, observa-se um efeito quase nulo pelos cilindros com rotação dependente, e uma diminuição do coeficiente pelos cilindros com rotação independente, gerando porém um deslocamento da média deste coeficiente. Apresenta-se portando redução do coeficiente de arrasto médio de 15.1% para a rede R_5_75 e de 22.6% para a rede R_5_75_I. Ressalta-se que esta redução é em relação à média do coeficiente de arrasto do escoamento sem a presença dos cilindros menores, já que a simples presença destes funciona como um método passivo de controle. Considera-se portanto as reduções em relação a um $C_D = 3.205$.

4.2. Adaptabilidade da Rede Neural

Com o treinamento da rede R_5_75_I, utilizou-se deste rede para o teste de adaptabilidade da rede neural. Devido à uma característica da simulação, os resultados apresentados na tabela 2 são aproximações realizadas a partir dos resultados obtidos.





Figura 3 – Coeficientes de arrasto e sustentação durante atuação da rede R_5_75.





Figura 4 – Coeficientes de arrasto e sustentação durante atuação da rede R_5_75_I.





Figura 5 – Coeficientes de arrasto e sustentação durante atuação da rede R_5_75_I04, com função objetivo alterada.

Tabela 2 – Aproximação dos coeficientes de arrasto reais e redução pela rede atuante para rede com cilindros rotativos independentes e variação do número de Reynolds.

Nº Reynolds	Média C_D sem controle	Média C_D controlado	Redução [%]
100	3.1	2.48	20
110	3.37	2.84	15.7
120	3.65	3.14	13.9
130	3.96	3.42	13.6
140	4.26	3.59	15.7
150	4.55	3.88	14.7
160	4.9	4.05	17.4

Conclui-se portanto a capacidade da rede neural em controlar o escoamento para diferentes condições além da treinada, porém com eficiência reduzida. Tal fato é provavelmente devido à semelhança da fenomenologia do escoamento, tendo variações apenas de intensidade de frequência do desprendimento de vórtices ao se variar o número de Reynolds.

4.3. Sensibilidade da Função Objetivo

Observa-se na figura 5 a atuação da rede treinada com a função objetivo alterada.

Comparando-se a figura 5 com a figura 4, é possível notar que o coeficiente médio de sustentação para a rede com função objetivo alterada está muito mais próximo do valor nulo, garantindo simetria do escoamento e demonstrando o impacto da função objetivo no aprendizado da rede neural. Observa-se também que a rede alterada possui um controle menos eficaz do coeficiente de arrasto. Nota-se portanto um preço a se pagar: ao tentar garantir simetria, perde-se na redução do arrasto.

5. Conclusão

Através dos testes e treinamentos realizados, confirma-se em primeiro momento a capacidade da rede neural de analisar, aprender e controlar um par de cilindros rotativos para controle de escoamento ao redor de um cilindro fixo.

Comparando-se o resultado obtido, de redução de 22.6%, conclui-se também a superioridade do método de controle por cilindros rotativos, mais especificamente quando há rotação independente dos cilindros, em relação ao controle por jatos sintéticos, que obteve redução de cerca de 8% (RABAULT et al., 2019).

Com o resultado apresentado pela rede neural com função objetivo modificada, confirma-se a sensibilidade do treinamento com relação ao impacto definido pelos coeficientes de arrasto e sustentação, gerando um conflito entre reduzir as forças de arrasto e manter a simetria do escoamento. Tal conflito é presente devido ao fato de ser possível reduzir as forças de arrasto no cilindro mudando a direção do escoamento, fato que gera alteração da média das forças de sustentação.

Com relação à adaptabilidade da rede neural, observa-se a capacidade da rede de controlar o escoamento em condições diferentes da qual fora treinada, mesmo que com eficácia reduzida. Tal conclusão abre a possibilidade de extrapolação para uso na indústria, sendo possível treinar uma rede neural em Reynolds menores, com menor custo computacional, e utilizar em escoamentos com Reynolds maiores. É necessário porém uma confirmação sistemática para faixas de Reynolds maiores.

Por fim, sugerem-se dois pontos principais de estudo a partir deste trabalho. O primeiro é a implementação de uma rede neural para controle de vários cilindros rotativos, similar ao modelo de Assi, Orselli e Ortega (2019), de modo que seja possível realizar o controle de escoamento omnidirecional. O segundo ponto, levando em conta os teste de adaptabilidade da rede, é a avaliação de quais intervalos de Reynolds a rede é capaz de manter um controle com eficácia semelhante. Tal estudo seria interessante para estudos de viabilidade e principalmente de confiança do funcionamento da rede em situações reais, com variação do escoamento.

6. Referências

- ABADI, M.; BARHAM, P.; CHEN, J.; CHEN, Z.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; IRVING, G.; ISARD, M. & OTHERS Tensorflow: A system for largescale machine learning. In OSDI, vol. 16, p. 265–283. 2016.
- ASSI, G. R. S.; ORSELLI, R. M.; SILVA-ORTEGA, M. Control of vortex shedding from a circular cylinder surrounded by eight rotating wake-control cylinders at $Re=100$. *Journal of Fluids and Structures*, in press, 2019.
- ALNAES, M.S.; BLECHTA, J.; HAKE, J.; JOHANSSON, A.; KEHLET, B.; LOGG, A.; RICHARDSON, C.; RING, J.; ROGNES, M. R.; WELLS, G. N. The FEniCS Project Version 1.5. **Archive of Numerical Software**, vol. 3, 2015.
- KORKISCHKO, I.; MENEHINI, J. R. Suppression of vortex-induced vibration using moving surface boundary-layer control. **Journal of Fluids and Structures**, v. 34, p. 259–270, 2012.
- LOGG, A.; WELLS, G.N. DOLFIN: Automated Finite Element Computing. **ACM Transactions on Mathematical Software**, vol. 37, 2012.
- MITTAL, S. Control of flow past bluff bodies using rotating control cylinders. **Journal of Fluids and Structures**, v. 15, n. 1, p. 291–326, 2001.
- PATINO, G. A.; GIORIA, R. S.; MENEHINI, J. R. Evaluating the control of a cylinder wake by the method of sensitivity analysis. **Physics of Fluids**, v. 29, n. 4, 2017.
- PATNAIK, B. S. V.; WEI, G. W. Controlling Wake Turbulence. **Physical Review Letters**, v. 88, n. 5, p. 1–4, 2002.
- RABAULT, J.; KUCHTA, M.; JENSEN, A.; REGLADE, U.; CERARDI, N. Artificial neural networks trained through deep reinforcement learning discover control strategies for active flow control. **Journal of Fluid Mechanics**, v. 865, p. 281–302, 64 2019.
- RASHIDI, S.; HAYATDAVOODI, M.; ESFAHANI, J. A. Vortex shedding suppression and wake control: A review. **Ocean Engineering**, v. 126, p. 57–80, 2016.
- ROACHE, P. J. Perspective: A Method for Uniform Reporting of Grid Refinement Studies. **Journal of Fluids Engineering**, v. 116, n. 3, p. 405–413, 1994.
- SCHAARSCHMIDT, M.; KUHNLE, A.; FRICKE, K. Tensorforce: A tensorflow library for applied reinforcement learning. Web page. 2017