

## Aprendizado de máquina para previsão de vazão e pressão em um conversor de energia das ondas de coluna de água oscilante

### *Machine learning for predicting flow and pressure in an oscillating water column wave energy converter*

Eduardo Henrique T. Cunegatto<sup>1</sup>; Lenon Audibert Cisco<sup>2</sup>; Flávia Schwarz F. Zinani<sup>3</sup>; Sandro José Rigo<sup>4</sup>

<sup>1</sup>Aluno do Curso de Doutorado em Computação Aplicada, Universidade do Vale do Rio dos Sinos, São Leopoldo, Rio Grande do Sul, Brasil. Orcid: 0000-0002-2692-1479. E-mail: [eduardohtc@edu.unisinos.br](mailto:eduardohtc@edu.unisinos.br)

<sup>2</sup>Aluno do Curso de Doutorado em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre, Rio Grande do Sul, Brasil. Orcid: 0000-0002-6798-0934. E-mail: [lenon.cisco@ufrgs.br](mailto:lenon.cisco@ufrgs.br)

<sup>3</sup>Professor do Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, Rio Grande do Sul, Brasil. Orcid: 0000-0001-5402-900X. E-mail: [flavia.zinani@ufrgs.br](mailto:flavia.zinani@ufrgs.br)

<sup>4</sup>Professor do Programa de Pós-Graduação em Computação Aplicada, Universidade do Vale do Rio dos Sinos, São Leopoldo, Rio Grande do Sul, Brasil. Orcid: 0000-0001-8140-5621. E-mail: [rigo@unisinos.br](mailto:rigo@unisinos.br)

**RESUMO:** A utilização da energia das ondas se coloca como uma alternativa renovável, diversificando a matriz energética e reduzindo o consumo de fontes fósseis. Um dos dispositivos proeminentes para captação da energia das ondas é a Coluna de Água Oscilante (CAO), que consiste em uma câmara hidropneumática onde a oscilação da superfície oceânica comprime o ar confinado, acionando uma turbina. Este trabalho combina simulação numérica e algoritmos de aprendizagem de máquina, objetivando desenvolver modelos de previsão para vazão volumétrica e pressão através da câmara CAO. O banco de dados para os modelos foi criado utilizando técnicas de Design de Experimentos (DOE), onde diferentes combinações de altura e comprimento de onda foram simuladas via CFD (Computational Fluid Dynamics) através do método dos volumes finitos (MVF). Após, a informação da altura de elevação de onda é alimentada a uma rede neural profunda totalmente conectada, que utiliza os dados simulados para aprendizado e retorna previsões baseadas nas informações fornecidas. A performance do modelo é avaliada em termos de uma função custo (Mean Squared Error). O modelo empregado possibilita identificar picos de vazão e pressão para o período de onda fornecido na entrada e os resultados encontrados apresentam diferenças de até 5% no RMS (Root Mean Square) entre as previsões e os dados simulados via CFD. A principal contribuição do trabalho está na utilização de aprendizado de máquina na previsão de condições de operação tradicionais de um dispositivo CAO, trazendo um conceito que pode ser aplicado em fases iniciais do projeto destes dispositivos.

**Palavras-chave:** Energia das ondas, Dinâmica dos Fluidos Computacional, Coluna de água oscilante, Redes neurais artificiais, Modelo preditivo.

**ABSTRACT:** *The use of wave energy presents itself as a renewable alternative, diversifying the energy matrix and reducing the consumption of fossil fuels. One of the prominent devices for ocean wave harvesting is the Oscillating Water Column (OWC), which consists of a hydropneumatic chamber where the oscillation of the water surface compresses the confined air, driving a turbine. This work combines numerical simulation and machine learning algorithms, aiming to develop predictive models for mass flow rate and pressure through the OWC chamber. The database for the models was created using Design of Experiments (DOE) techniques, where different combinations of wave height and wavelength were simulated via Computational Fluid Dynamics (CFD) using the Finite Volume Method (FVM). Subsequently, the wave elevation height data is fed into a fully connected deep neural network, which uses the simulated data for learning and returns predictions based on the provided information. The model's performance is evaluated in terms of a cost function (Mean Squared Error). The employed model allows for the identification of flow rate and pressure peaks for the wave period provided at the input, and the results show differences of up to 5% in RMS (Root Mean Square) between the predictions and the CFD data. The main contribution of this work lies in the use of machine learning in predicting traditional operating conditions of an OWC device, introducing a concept that can be applied in the early stages of the design of such devices.*

**Keywords:** *Wave energy, Computational fluid dynamics, Oscillating water column, Artificial neural networks, Predictive model.*

## INTRODUÇÃO

O potencial energético oriundo dos oceanos tem ganhado muita atenção nos últimos 10 anos, não somente por ser uma fonte de energia limpa, mas também pela alta quantidade de energia disponível, com margens de 55-255 TWh por ano, a depender da localização, e pelas diferentes possibilidades de aproveitamento (Shadmani *et al.*, 2023). No entanto, as tecnologias para conversão de energia dos oceanos estão ainda em baixos graus de maturidade tecnológica, se comparadas a tecnologias para outros tipos de energias renováveis, como eólica e solar. Assim, considera-se o aproveitamento da energia dos oceanos uma alternativa com grande potencial de inovação tecnológica (Mahdy *et al.*, 2024). Neste contexto, muitos dispositivos de conversão de energia das ondas (*Wave Energy Converters*, WEC) têm sido pesquisados. Dentre os WECs disponíveis, uma das tecnologias mais viáveis são os dispositivos de coluna de água oscilante (CAO). Estes dispositivos utilizam o movimento oscilatório da interface água-ar das ondas para movimentar ar confinado em uma câmara parcialmente submersa e gerar energia através da passagem de ar por uma turbina (Mahmoud; Adbelkareem; Olabi, 2024). Os dispositivos CAO são atrativos de modo que não utilizam peças móveis submersas, possuem fácil manutenção e não prejudicam a vida marinha (Khaleghi; Lie; Baguley, 2022).

O aprimoramento de dispositivos CAO têm sido bastante explorados na literatura. Um estudo publicado por Rehman *et al.* (2023) mostra que foram publicados mais trabalhos sobre energia das ondas do que energia eólica nos últimos 20 anos e que grande parte dos trabalhos explora a otimização geométrica de dispositivos CAO. Os métodos empregados em tais pesquisas envolvem tanto simulação computacional quanto testes experimentais em escalas de laboratório e piloto. Neste contexto, a metodologia de modelagem dos conversores é um assunto com bastante demanda, pois, existe a necessidade de aprimorar não somente os sistemas, mas os processos de simulação, devido a modelagem matemática ser computacionalmente intensa, demandando memória e tempo computacional. Inúmeros trabalhos utilizam e citam Computational Fluid Dynamics (CFD) como uma ferramenta efetiva para simular e prever o comportamento de dispositivos (Zinani, 2023; Ding; Pang; Shen, 2023).

A crescente evolução dos trabalhos relacionados a CAO em geral também acompanha o desenvolvimento das metodologias de análise. Nesse contexto, cita-se a utilização de algoritmos computacionais de aprendizado de máquina (*machine learning*, em inglês). Em estudo publicado por Shadmani *et al.* (2023), o número de trabalhos, a partir do ano 2000, que utilizam técnicas de aprendizado de máquina em sistemas de energia obteve um crescimento significativo desde 2016, em que cerca de 500 trabalhos foram publicados, número que, até o momento, era inferior ao de trabalhos publicados sobre energia das ondas. Desde então, esse número aumentou consideravelmente para cerca de 3000 em 2021, superando em quase três vezes o número de publicações relacionadas à energia das ondas, mostrando que a implementação destas técnicas pode ser extremamente atrativa e benéfica no desenvolvimento de CAO.

Dentre os trabalhos relacionados que empregam machine learning no desenvolvimento de CAO, o trabalho de López e Iglesias (2014) apresenta um conceito de laboratório virtual, onde um modelo de machine learning via redes neurais é empregado para estimar a potência hidropneumática de um dispositivo CAO, para diferentes combinações geométricas. George *et al.* (2021) implementa redes neurais artificiais como

modelo de predição da performance para otimização de um CAO em formato 'U'. Silva *et al.* (2021) emprega uma arquitetura de rede neural LS-SVM (*Least Squares Support Vector Machine*) para estimar a pressão do ar de uma câmara de CAO, idêntica à instalada na planta de Mutriku, na Espanha. Seo *et al.* (2021) apresenta um modelo de machine learning capaz de lidar com grande quantidade de dados (big data), aplicados na previsão das condições de operação de um dispositivo CAO real, diante de diferentes condições de onda. Ahmad *et al.* (2023) estuda um turbinas eólicas offshore (distante da costa), com dispositivos CAO acoplados na estrutura. No estudo, os autores empregam redes neurais para estimar a rotação das turbinas e potência gerada pelos dispositivos.

Identificado que o campo de aplicação ainda é vasto, o presente trabalho tem por objetivo desenvolver modelos de previsão, baseado em algoritmos de aprendizado de máquina, sendo um modelo para estimar a vazão volumétrica e o outro a pressão de ar, em uma câmara de CAO, a partir da informação da altura de elevação livre da onda incidente. O banco de dados para criação dos modelos foi montado através de técnicas de Design de Experimentos (DOE, *design of experiments*), onde diferentes combinações de altura e comprimento de onda foram simuladas via CFD. A informação da altura de elevação de onda, isto é, a sequência da altura de onda para um determinado período, é alimentada no modelo, cuja arquitetura é uma rede neural profunda, totalmente conectada. Os dados de entrada percorrem a rede até a camada de saída, que retorna a previsão da sequência da vazão volumétrica e pressão, para o mesmo período informado nos dados de entrada, para que sejam aptos para futuro pós-processamento

O trabalho apresenta um conceito de aplicação promissor no desenvolvimento de CAO, trazendo uma metodologia de predição de parâmetros de operação destes dispositivos para diferentes configurações de onda. Contudo, existem lacunas que ainda podem ser exploradas para aprimorar ainda mais o modelo. Diante disso, espera-se que este trabalho contribua no desenvolvimento de técnicas e métodos aplicados no desenvolvimento de CAO, e que possa servir de inspiração para novos conceitos e oportunidades de estudo, não somente em energia das ondas, como nas demais áreas de aplicação


## MATERIAIS E MÉTODOS

Neste trabalho, um dispositivo de coluna de água oscilante offshore foi modelado computacionalmente. Foram realizadas simulações deste dispositivo utilizando fluidodinâmica computacional (CFD). Os resultados das simulações foram utilizados como treinamento e teste de uma rede neural artificial.

O sistema para análise computacional consiste em uma câmara de ar de um dispositivo de coluna de água oscilante (CAO) offshore. O modelo computacional para este sistema é a sua representação na forma bidimensional, apresentado na **Figura 1 (a)**, sendo caracterizado por um retângulo que envolve o canal de ondas. O dispositivo CAO está localizado no centro, a uma distância de  $3L$  das fronteiras esquerda e direita, onde  $L$  é o comprimento da onda incidente, que adentra o domínio pela fronteira esquerda e possui altura  $H$ . O dispositivo está parcialmente submerso a 5 m do leito oceânico e possui comprimento de 10 m, altura de 11 m, um orifício de 1,5 m representando a saída para turbina, e paredes de espessura 0,5 m, conforme **Figura 1 (b)**. No estudo, o estado de mar considerado é idealizado e a altura média de superfície livre é de 10 m. Para representar

os efeitos offshore e atenuar os efeitos de reflexão das ondas, implementou-se na modelagem a condição de praia numérica, que inicia a uma distância de  $2L$  da fronteira direita (saída) do domínio. A medição da pressão e vazão de ar é realizada por meio de uma sonda localizada na abertura da câmara, indicada pela linha vermelha, enquanto que o monitoramento da elevação da onda é realizado no gerador de ondas, na fronteira esquerda do domínio.

**Figura 1.** Domínio computacional: dimensões do tanque (a); dimensões do dispositivo CAO (b)



## Modelagem matemática

A simulação numérica (CFD) do problema foi realizada através do software comercial Ansys FLUENT 2023R2 (Ansys, 2023) o qual utiliza o método dos volumes finitos (Patankar, 1980) para aproximação das equações diferenciais de balanço de massa, quantidade de movimento e fração volumétrica, as quais estão expressas, respectivamente, por:

$$\frac{\partial \rho}{\partial t} + \nabla \cdot (\rho \mathbf{v}) = 0 \quad (1)$$

$$\frac{\partial (\rho \mathbf{v})}{\partial t} + \nabla \cdot (\rho \mathbf{v} \mathbf{v}) = -\nabla p + \nabla \tau + \rho \mathbf{g} + \mathbf{f} \quad (2)$$

$$\frac{\partial \alpha}{\partial t} + \nabla \cdot (\alpha \mathbf{v}) = 0 \quad (3)$$

Onde:  $\rho$  é a massa específica do fluido ( $\text{kg/m}^3$ ),  $t$  é o tempo (s),  $\mathbf{v}$  é o vetor velocidade (m/s),  $p$  é a pressão estática (Pa),  $\tau$  é o tensor das tensões (Pa),  $\mathbf{f}$  representa o termo fonte de forças externas ( $\text{N/m}^3$ ) e  $\mathbf{g}$  é a aceleração gravitacional, adotada como  $9,81 \text{ m/s}^2$ .

A equação da fração volumétrica (Eq. 3) é solucionada através do método *Volume of Fluid* (VOF), utilizada para calcular a porcentagem de um determinado fluido em cada elemento do domínio, de forma que a fração volumétrica ( $\alpha$ ) varie de 0 a 1 (Hirt; Nichols, 1981). O termo fonte,  $\mathbf{f}$ , na modelagem empregada, representa o artifício da praia numérica, conforme mencionado anteriormente. Matematicamente, o termo fonte é expresso da seguinte forma:

$$\mathbf{f} = -C(\rho \mathbf{v}) \left(1 - \frac{y - y_s}{y_e - y_s}\right) \left(\frac{x - x_s}{x_e - x_s}\right)^2 \quad (4)$$

Onde:  $C$  representa a resistência de amortecimento (1/m),  $x_s$  e  $x_e$  representam os pontos de início e fim da praia numérica, no eixo  $x$ ,  $y_s$  e  $y_e$  representam o início e fim da praia numérica no eixo  $y$ . O valor adotado para  $C$  é 20 (1/m) conforme recomendação de Lisboa *et al.* (2017).

Com relação à modelagem das ondas, utilizou-se a teoria das ondas de Stokes, de segunda ordem. As componentes de velocidade e a elevação da superfície livre são calculadas, respectivamente, por:

$$u = \frac{\pi H \cosh(h+z)}{T \sinh \sinh(kh)} \cos(kx - \sigma t) \quad (5)$$

$$v = \frac{\pi H \cosh k(h+z)}{T \sinh \sinh(kh)} \cos(kx - \sigma t) \quad (6)$$

$$\eta = \frac{H}{2} \cos(kx - \sigma t) \quad (7)$$

Onde:  $H$  é a altura da onda (m),  $\eta$  é a altura de elevação da onda (m),  $\sigma$  é a frequência da onda, determinado por  $\sigma = 2\pi/T$ ,  $k$  é número de onda, definido por  $k = 2\pi/L$ ,  $T$  é período da onda,  $u$  é a componente da velocidade no eixo  $x$  (m/s),  $v$  é a componente da velocidade no eixo  $y$  (m/s) e  $h$  é altura da superfície livre (m).

## Modelagem numérica


As condições de contorno do problema, também ilustradas na **Figura 1**, foram definidas da seguinte forma: na fronteira esquerda (azul), está o gerador das ondas incidentes; a fronteira superior determinou-se pressão atmosférica (laranja), cuja pressão manométrica é 0 [Pa]; a fronteira direita representa um perfil hidrostático (verde), influenciada pela presença da praia numérica; para a fronteira inferior do domínio, bem como as paredes do dispositivo CAO, a condição de parede impermeável foi implementada.

Na solução das equações, empregou-se como acoplamento pressão-velocidade o método PISO (*Pressure-Implicit with Splitting of Operators*). Já para as interpolações espaciais, utilizou-se PRESTO (*Pressure Staggering Option*) para pressão, Third-order MUSCL (*Monotone Upstream-Centered Schemes for Conservation Laws*) para momento e HRIC (*High Resolution Interface Capturing*) para a fração volumétrica. O critério de convergência para a equação da continuidade foi  $10^{-4}$  e  $10^{-6}$  para as demais equações. O número de passos de tempo foi definido como 2500, cujo passo de tempo foi definido como  $T/500$ . O escoamento foi considerado laminar e os fluidos são incompressíveis.

A malha computacional está ilustrada na **Figura 2**. Sua construção foi baseada na metodologia *stretched*, de Mavriplis (1997), e está presente na literatura em estudos de CAO, como nos trabalhos de Lima *et al.* (2019), Letzlow *et al.* (2020), Teixeira *et al.* (2021) e Lima *et al.* (2024). O método basicamente consiste na divisão do domínio computacional em regiões de interesse, para posterior refinamento nas regiões mais críticas.



**Figura 2.** Malha computacional: visão geral (a); detalhe no dispositivo CAO (b).



As regiões mais críticas do problema consistem na interface entre ar e água e no interior da câmara. Na interface ar/água, utilizou-se a altura de onda como referência, de modo que o tamanho de elemento seja definido como  $H/40$ . No interior da cavidade, elementos de 0,05 [m] foram implementados, mantendo os elementos uniformes, de modo a capturar os fenômenos dentro do dispositivo. O tamanho de elemento da direção  $x$  tem por referência o comprimento de onda, sendo definido como  $L/100$ . Os valores adotados têm por referência os trabalhos citados anteriormente, os quais demonstraram excelente performance numérica ao adotar o método *stretched*. Para validação da malha computacional e da modelagem numérica, as elevações da superfície de onda com diferentes características ( $H$  e  $L$ ) foram comparadas com a solução analítica (Equação 7), cujos resultados estão presentes na **Figura 3**.


Observando a **Figura 3**, nota-se que as ondas numérica e teórica não estão perfeitamente alinhadas, originando pequenas diferenças na elevação. Contudo, comparando-se as raízes quadrada média (*Root Mean Square*, RMS, Equação 8 abaixo) de cada onda, o caso (a) teve uma diferença de 0,982%, o caso (b) com 0,497% e o caso (c) com 0,249%. Com relação aos valores máximos e mínimos, o caso (a) obteve uma diferença de 0,089% e 0,108%, respectivamente, o caso (b) diferenças de 0,162% e 0,179% e o caso (c) apresenta diferenças de 0,135% e 0,141%. As métricas apresentam valores satisfatórios para o problema, indicando que a geração de ondas está a par com o modelo analítico, indicando que a modelagem está apropriada.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (8)$$

## Elaboração do modelo preditivo

A geração da base de dados para aplicação do modelo de aprendizagem de máquina foi feita a partir do método *Design of Experiments* (DOE), (Montgomery, 2012). Este método possui diversas técnicas para distribuição das amostras avaliadas dentro do espaço experimental. No presente estudo, utilizou-se uma combinação das técnicas *Central Composite Design* (CCD) e *Latin Hypercube Sampling* (LHS), (Stein, 1987). A primeira apresenta uma distribuição uniforme e fixa das amostras dentro do espaço experimental, enquanto a segunda distribui, aleatoriamente, um determinado número de amostras.

### Figura 3. Validação da geração de onda

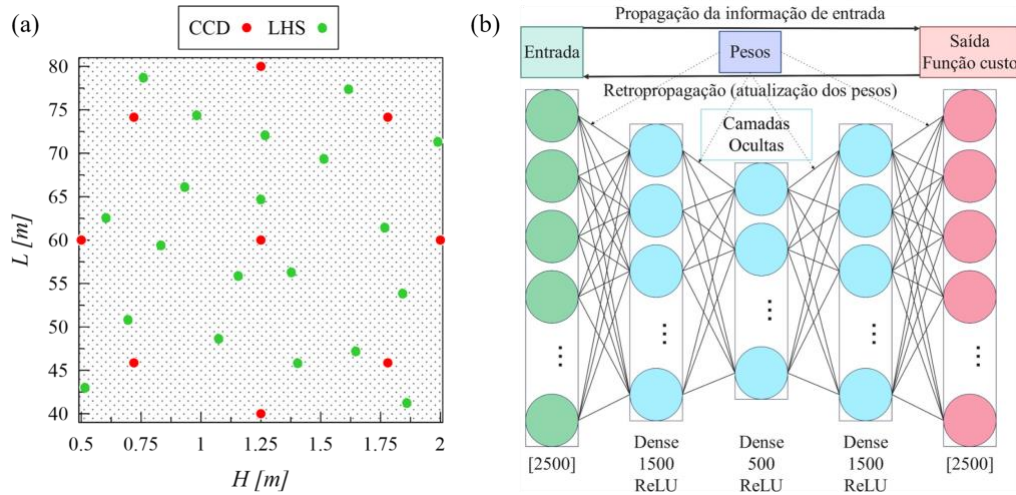


No presente estudo, dois graus de liberdade são utilizados: a altura da onda ( $H$ ) e o comprimento de onda ( $L$ ), de forma que os limites das variáveis definem o tamanho do espaço experimental. Para  $H$ , variou-se entre 0,5 m a 2 m, enquanto que  $L$  foi variado de 40 m a 80 m. De acordo com Misiulia *et al.* (2017), um modelo de predição necessita de um número de dados suficiente para capturar e entender as relações entre os dados de entrada e saída. Por isso, optou-se por utilizar a combinação dos métodos, como proposto por Yang e Palazzolo (2022), que aplicaram ambos os métodos em seu estudo. Com isso, o método CCD gerou 9 amostras para o caso de dois graus de liberdade e outras 20 amostras foram geradas através do método LHS, distribuídos dentro do espaço experimental, conforme mostra a **Figura 4(a)**.

O conceito do modelo de aprendizado de máquina empregado neste trabalho envolve a predição das condições de operação, no caso, a pressão e vazão de ar dentro da câmara do CAO, a partir da informação da onda incidente. No caso, deseja-se alimentar a rede com os dados da elevação livre da onda para um determinado período e receber da rede os parâmetros de resposta, para o mesmo período. Logo, alimenta-se a rede com um vetor de entrada, que representa a altura da elevação livre da onda e, como resposta, a rede retorna um vetor, referente à variável de resposta, cujo tamanho é o mesmo. Para tal, foram criados dois modelos separados, um para cada variável, de estrutura idêntica, apresentado na **Figura 4(b)**.

O modelo proposto trata-se de uma rede neural profunda (*Deep Neural Network*, DNN), composta por três regiões distintas: a camada de entrada, a qual recebe o vetor de entrada, de tamanho 2500; três camadas ocultas, responsáveis pela transmissão da informação dos dados de entrada, as quais duas possuem 1500 neurônios e uma com 500 neurônios; e a camada de saída, que retorna as previsões, cujo tamanho também é 2500.

**Figura 4.** Distribuição dos pontos dentro do espaço experimental (a); Estrutura geral do modelo de aprendizado de máquina (b)



Para a implementação do modelo, utilizou-se a linguagem de programação Python, através das bibliotecas *TensorFlow* (Abadi *et al.* 2015) e *Keras* (Chollet *et al.* 2015). O parâmetro *Dense*, mostrado na **Figura 4(b)** é a denominação utilizada na biblioteca *Keras* para denominar que a rede é totalmente conectada, o que significa que as informações são repassadas entre as camadas da rede, de neurônio em neurônio. A função de ativação empregada é a *Rectified Linear Unit* (ReLU). Com relação aos hiperparâmetros da DNN, utilizou-se o otimizador *Adaptive Momentum Estimation* (Adam), com taxa de aprendizado de  $10^{-4}$  e 50 iterações (*epochs*) para o treinamento. Dos 29 *datasets*, 80% foram utilizados para treinamento da rede e 20% para teste.

O processo de treinamento da rede envolve diminuir a função custo, que mede a diferença entre a previsão e os dados de treinamento, a cada iteração, permitindo que a rede ajuste seus pesos. A função custo empregada no presente estudo é o Erro Quadrático Médio (*Mean Squared Error*, MSE), definida matematicamente por:

$$MSE_i = \frac{1}{n} \sum_{i=1}^n \left( y_{prev\ i,j} - y_{CFD\ i,j} \right)^2 \quad (9)$$

$$MSE_{total} = \frac{1}{m} \sum_{i=1}^m MSE_i \quad (10)$$

Onde:  $n$  é o número de elementos do vetor,  $m$  é o número de vetores utilizados na avaliação da métrica,  $i$  representa o índice do vetor,  $j$  representa o índice do valor, e os subscritos *prev* e *CFD* representam os valores previstos pela rede e os valores da simulação CFD, respectivamente. Um importante aspecto a informar sobre a implementação do modelo é a normalização dos dados, utilizado para deixar os dados em escala comum para garantir melhor adequação dos pesos da rede, retornando resultados



mais precisos. A ideia é transformar todos os valores em um intervalo, como por exemplo, de 0 a 1, sem alterar a natureza dos dados. Neste estudo, empregou-se a normalização *min-max*, definida matematicamente por:

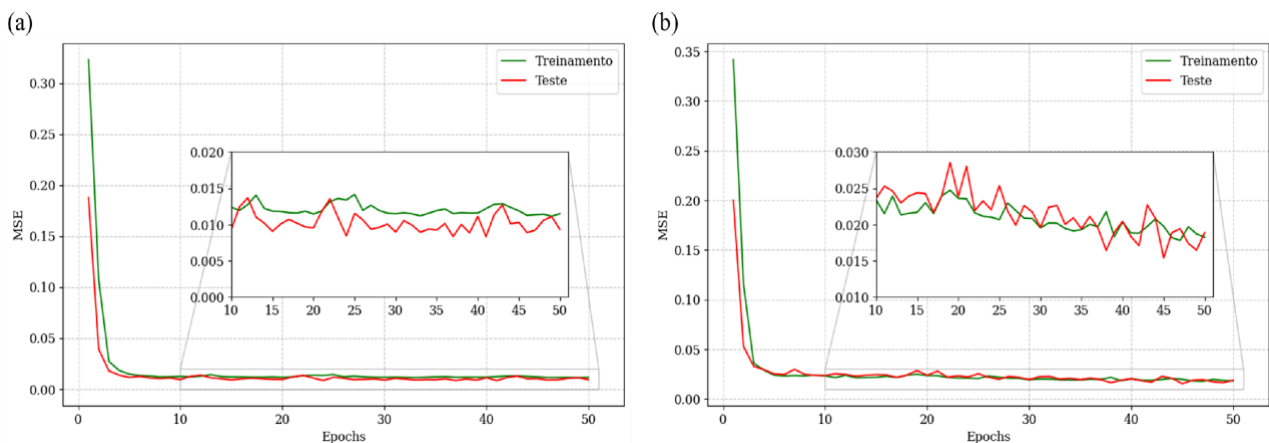
$$x_{norm_{ij}} = \frac{x_{ij} - x_{min_i}}{x_{max_i} - x_{min_i}} \quad (11)$$

onde:  $i$  representa o índice do vetor,  $j$  representa o índice do valor e os subscritos *norm*, *min* e *max* representam o valor normalizado, o valor mínimo do vetor e o valor máximo do vetor, respectivamente. Com isso, o modelo é avaliado a partir dos valores normalizados.

## RESULTADOS

O primeiro passo para aplicação do modelo é a análise do processo de treinamento. Conforme mencionado na seção anterior, a métrica MSE foi implementada como função a ser minimizada. Em tese, a função custo empregada (MSE) quantifica a diferença entre as previsões da rede e os valores CFD, de forma que a minimização desta diferença indica correlação forte entre os dados previstos e os reais (CFD). Contudo, é extremamente importante verificar o comportamento do treinamento para identificar possíveis *overfitting* (sobreajuste) dos dados. Isso acontece quando o modelo se adequa excessivamente aos dados de treinamento, produzindo previsões inadequadas para novos dados (Géron, 2019). A **Figura 5** apresenta o desempenho do modelo empregado durante o processo de treinamento.

**Figura 5.** Processo de treinamento da rede neural: Modelo para predição da vazão volumétrica (a); Modelo de predição da pressão (b)



Nos gráficos apresentados, a linha verde representa a variação da função custo para cada época durante o processo de treinamento, onde os respectivos dados foram utilizados para ajuste dos pesos da rede. Em geral, o valor começa elevado devido à natureza heurística dos pesos e conforme estes são atualizados, o valor de MSE reduz. Na **Figura 5 (a)**, é possível observar que, a partir da época 10, o modelo apresenta leves oscilações, sem alteração significativa nos valores, atingindo um nível de convergência. Já na **Figura**

**5 (b)**, nota-se que as oscilações são mais bruscas, e o decréscimo da função erro é mais nítido. Comparando-se os dois casos, nota-se que o modelo de vazão volumétrica obteve um MSE de aproximadamente 0,0125 no treinamento, enquanto que o modelo de pressão ficou na proximidade de 0,02.

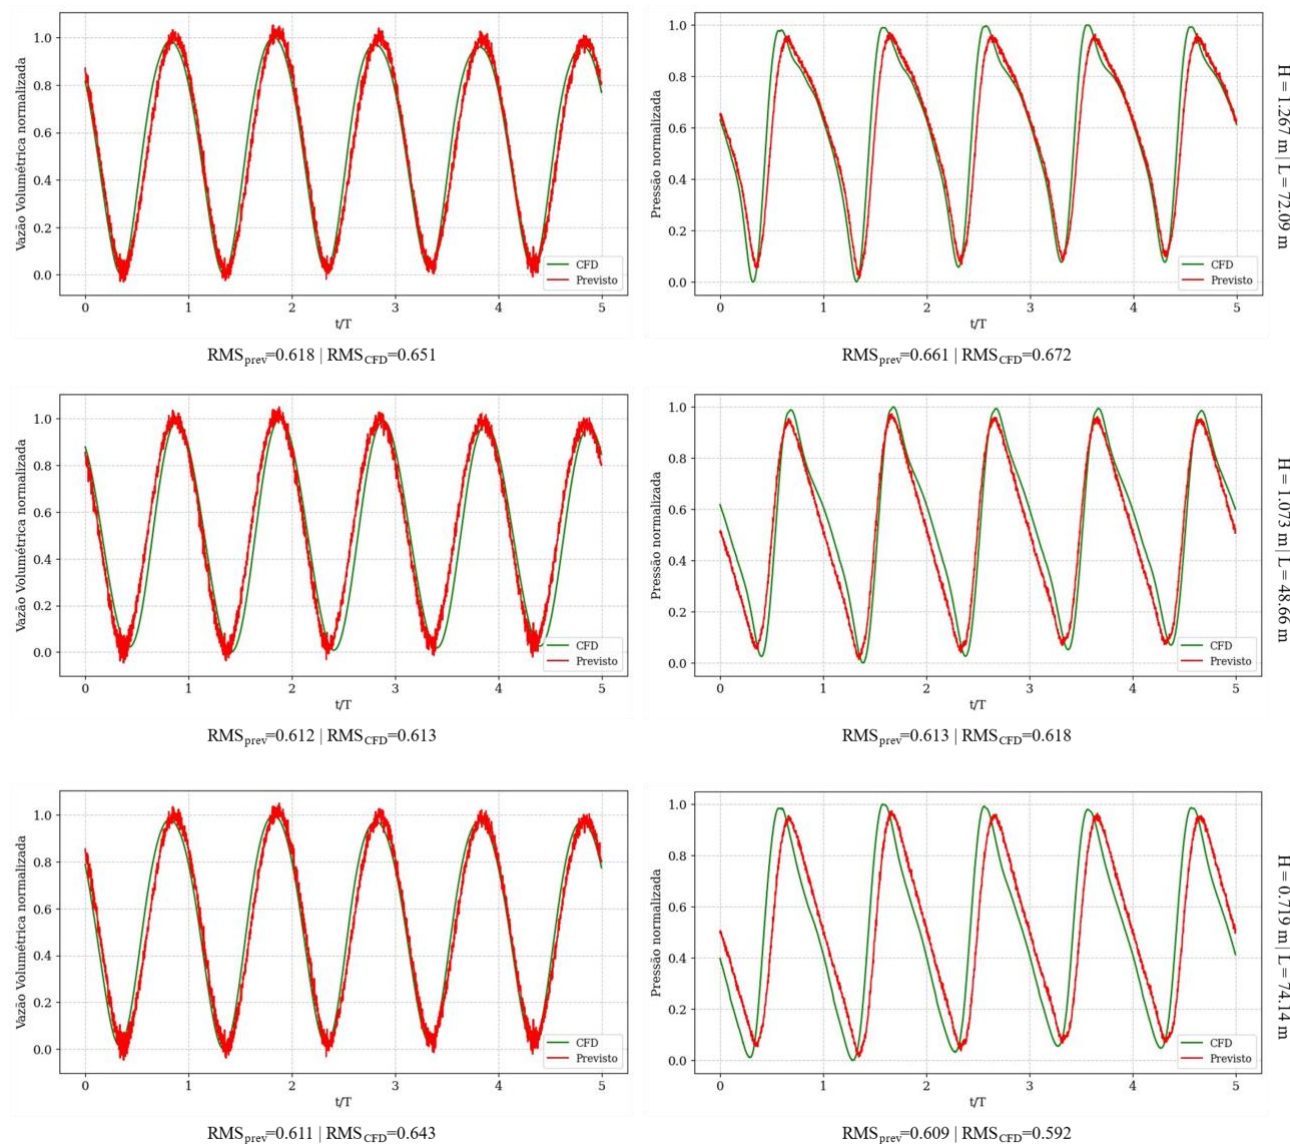
A linha vermelha representa a variação da função custo utilizando os dados de teste, onde, neste caso, o modelo treinado é avaliado utilizando os dados de teste, ou seja, dados não observados pelo modelo. O comportamento da curva mostra uma tendência similar a curva de treinamento, sendo um aspecto favorável. Além disso, as métricas também retornaram valores similares aos de treinamento, indicando que o modelo consegue se adaptar a novos dados sem resultar em *overfitting*. Visto que os modelos apresentaram performance adequada durante o processo de treinamento, segue-se para a verificação das previsões em si. A **Figura 6** apresenta comparações das previsões para vazão volumétrica e pressão em diferentes situações de onda.

Observando a **Figura 6**, nota-se que o modelo produz resultados coerentes, mas ainda com certas discrepâncias. Em uma análise visual, é notável que as curvas não estão perfeitamente alinhadas, especialmente com relação ao comprimento de onda nas previsões de vazão volumétrica e na amplitude das previsões de pressão. Nota-se que o comportamento da vazão volumétrica possui cristas e vales mais ordenados, o que facilita a correlação dos dados de entrada com a saída pela rede, bem como o aprendizado, resultado em métricas mais baixas, como observado na **Figura 5**. Já o comportamento da pressão é mais imprevisível, tornando o aprendizado mais sensível. Novamente, isso é observado na **Figura 5**, onde as métricas foram maiores, bem como as oscilações.

Em termos quantitativos, novamente opta-se pelo uso da métrica RMS, previamente utilizada na validação da geração de ondas, para análise da **Figura 6**. Nota-se que os valores de RMS são mais próximos para os resultados de pressão, do que para os de vazão volumétrica, onde é possível identificar uma diferença máxima de 5%. Isso acontece pois, no caso das previsões de pressão, as diferenças de amplitude são compensadas pelas diferenças no comprimento de onda, enquanto, para as previsões de vazão volumétrica, não ocorre esta compensação, uma vez que as amplitudes são similares, mas o comprimento de onda não. Observa-se que essa diferença é ligeiramente maior na crista das ondas, onde os maiores valores se concentram, resultando em um RMS mais baixo para a previsão.

Outro importante conceito a ser enfatizado por este trabalho é a capacidade de pós-processamento de dados gerados por um modelo de aprendizado de máquina. Isso é, ao invés de prever diretamente um único valor, opta-se por reproduzir dados generalizados, para que possam ser processados em variadas aplicações. Na aplicação estudada, conforme visto, os dados gerados podem ser pós-processados para o cálculo do RMS, parâmetro corriqueiramente utilizado no tratamento de sequências de dados, que no caso de dados oscilantes, como ondas, representa a energia capturada em um determinado período e/ou comprimento (Goswami; Sinha, 2022).

**Figura 6.** Comparação dos dados CFD com as previsões do modelo para vazão volumétrica e pressão em diferentes configurações de onda incidente



Além disso, o conceito proposto no estudo é a geração de sequências de dados para pressão e vazão volumétrica. Logo, com as informações geradas para ambas as variáveis, é possível estimar, por exemplo, a potência disponível no conversor do tipo CAO, através da seguinte equação (Sheng *et al.* 2013):


$$P = p \cdot Q \quad (12)$$

Onde:  $P$  representa a potência (W) disponível,  $p$  é a pressão (Pa),  $Q$  é a vazão volumétrica ( $\text{m}^3/\text{s}$ ). É importante salientar que, para calcular a potência estimada, deve-se aplicar a equação de normalização (Equação 11) nos dados gerados antes de calcular a potência para retornar à escala original. Com isso, após retornar os dados previstos de pressão e vazão volumétrica a escala real, o comportamento da potência pode ser

observado conforme mostra **Figura 7**.

Observando a figura, nota-se que a distribuição da potência tem grande variabilidade, mostrando vários picos ao longo da operação. Dentre estes picos, observa-se as maiores amplitudes ocorrem em momentos em que os picos de vazão e pressão (**Figura 6**) se encontram, ou seja, quando a diferença de pressão entre a câmara do dispositivo CAO e a saída do orifício (atmosfera), é maior e, conseqüentemente, a vazão volumétrica também; os demais picos ocorrem em momentos de variação intermediária das variáveis, resultando em menor geração de potência. Um ponto importante a ser salientado é que no presente estudo, a unidade de geração de potência (turbina) não foi considerada, gerando uma perda de carga inferior, conseqüentemente, menor pressão.

**Figura 7.** Comportamento da potência estimada para diferentes configurações de onda incidente



A potência de um CAO é uma das maneiras de avaliar a performance do dispositivo. Segundo Garcia-Teruel *et al.* (2021), existem outras maneiras de otimizar um CAO, cujas informações podem ser extraídas de gráficos como os apresentados nas **Figuras 6 e 7**. Portanto, o principal conceito do presente estudo é a possibilidade de previsão de uma sequência de dados das variáveis de operação de um dispositivo CAO, baseada na informação da onda incidente, pode-se estimar diferentes condições de operação, possibilitando a identificação de picos de vazão/pressão que possam identificar as condições de funcionamento, algo que não é possível determinar com a previsão de apenas um valor médio.

## CONCLUSÕES

O presente trabalho estuda a aplicação de modelos de aprendizado de máquina na análise de colunas de água oscilante (CAO) para previsão da vazão volumétrica e a pressão de ar no orifício da turbina, em um determinado período. Dois modelos, um para cada variável de resposta, foram desenvolvidos através de uma arquitetura de rede neural artificial, totalmente conectada, que recebe a informação da elevação da altura de onda e retorna as previsões. O banco de dados utilizado no treinamento dos modelos foi criado via *Design of Experiments* (DOE), que gerou amostras para diferentes combinações de altura e comprimento de ondas. As amostras foram inicialmente simuladas via CFD, gerando as



informações necessárias para o processo de treinamento e a avaliação do modelo. A modelagem numérica foi avaliada comparando-se a geração de ondas com o modelo teórico de Stokes de segunda ordem, retornando resultados satisfatórios. O processo de treinamento dos modelos foi avaliado através da função custo *Mean Squared Error* (MSE), que trouxe a métrica entre os valores previstos pelo modelo e os valores CFD.

Os resultados do estudo mostraram que a arquitetura adotada nos modelos conseguiu generalizar o problema, gerando resultados coerentes, sem a presença de *overfitting* (sobreajuste). Isso também é enfatizado pelos valores de MSE, onde valores de até 0,02 foram encontrados, sendo uma excelente marca para a metodologia empregada. A boa performance no treinamento resultou em previsões que capturam o problema estudado, gerando dados que trazem informações importantes sobre o comportamento da vazão de massa e pressão de ar para uma determinada condição de onda. Além disso, os dados gerados são pós-processáveis, de modo que parâmetros como *Root Mean Square* (RMS) possam ser determinados para estimar, por exemplo, a potência disponível no dispositivo CAO.

Contudo, é importante salientar que alguns resultados gerados ainda possuem discrepâncias, gerando estimativas com certa margem de erro. Foram encontradas diferenças de até 5% no RMS entre as previsões e os dados CFD. Já para o comportamento geral, nota-se diferenças significativas na amplitude e no comprimento de onda dos dados gerados, mostrando que o modelo não está com uma boa precisão. Isso faz com que alternativas na modelagem sejam implementadas para melhoria do modelo. Uma delas é a ampliação da base de dados, para que mais situações sejam abordadas no modelo, aumentando a capacidade de generalização. Isso pode fazer com que seja possível reduzir ainda mais as métricas de treinamento. Outras propostas de melhoria envolvem a alteração nos hiperparâmetros, como o número de camadas ocultas, número de neurônios, taxa de aprendizado do otimizador, ou ainda, uma completa reformulação da arquitetura, empregando-se outros modelos de redes neurais artificiais.

Em um contexto geral, os resultados aqui encontrados são satisfatórios, pois além de atingirem o esperado no escopo do trabalho, também forneceram informações importantes sobre a atual capacidade do método empregado. A partir da análise de resultados foram observadas possíveis condições de melhoria, bem como identificadas oportunidades de aplicação em outros cenários. Como sugestões de cenários a serem estudados, deve-se enfatizar a modelagem do sistema de conversão de energia, isto é, a influência da própria turbina na conversão de energia, já que, no cenário atual, apenas um orifício aberto foi considerado. Além disso, cita-se a variação dos parâmetros de onda combinados com variações geométricas do dispositivo CAO, para desenvolver um modelo capaz de generalizar ainda mais o problema. Quanto à geração de ondas, a implementação de ondas irregulares e estados de mar realísticos também são oportunidades de estudo, bem como estudos tridimensionais. São várias possibilidades que, combinadas com a versatilidade dos modelos de aprendizado de máquina, podem trazer grandes avanços na modelagem de sistemas de energia das ondas, bem como em outras áreas da engenharia.

## REFERÊNCIAS

ABADI, M. *et al.* 2015. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems**. Software available from tensorflow.org.

AHMAD, I.; M'ZOUGH, F.; ABOUTALEBI, P.; GARRIDO, I.; GARRIDO, A.J. A regressive machine-learning approach to the non-linear complex FAST model for hybrid floating offshore wind turbines with integrated oscillating water columns. **Scientific Reports**, v. 13, 2023. DOI: <https://doi.org/10.1038/s41598-023-28703-z>

ANSYS® Fluent, Release 2023 R2, Help System, Ansys Fluent Theory Guide, ANSYS, Inc. CHOLLET, F. *et al.* 2015. **Keras**. Available at: <https://github.com/fchollet/keras>.

DING, J.; PANG, S.; CHEN, Z. Optimization of the chamber of OWC to improve hydrodynamic performance. **Ocean Engineering**, v. 287, 2023. DOI: <https://doi.org/10.1016/j.oceaneng.2023.115782>

GARCIA-TERUEL, A.; FOREHAND, D.I.M. A review of geometry optimisation of wave energy converters. **Renewable and Sustainable Energy Reviews**, v. 139, 2021. DOI: <https://doi.org/10.1016/j.rser.2020.110593>

GEORGE, A.; CHO, I.H.; KIM, M.H. Optimal Design of a U-Shaped Oscillating Water Column Device Using an Artificial Neural Network Model. **Processes**, v. 9, 2021. DOI: <https://doi.org/10.3390/pr9081338>

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow**. O'Reilly Media, v. 2, 2019.

GOSWAMI, T.; SINHA, G.R. **Statistical Modeling in Machine Learning**. Academic Press, v. 1, 2022.

HIRT, C.W.; NICHOLS, B.D. Volume of fluid (VOF) method for the dynamics of free boundaries. **Journal of Computational Physics**, v. 39, pp. 201-225, 1981. DOI: [https://doi.org/10.1016/0021-9991\(81\)90145-5](https://doi.org/10.1016/0021-9991(81)90145-5)

KHALEGHI, S.; LIE, T.T.; BAGULEY, C. An Overview of the Oscillating Water Column (OWC) Technologies: Issues and Challenges. **Journal of Basic & Applied Sciences**, pp. 98-118, 2022. DOI: <https://doi.org/10.29169/1927-5129.2022.18.11>

LETZOW, M.; LORENZINI, G.; BARBOSA, D. V. E.; HÜBNER, R. G.; ROCHA, L. A. O.; GOMES, M. N. *et al.* Numerical Analysis of the Influence of Geometry on a Large Scale Onshore Oscillating Water Column Device with Associated Seabed Ramp. **International Journal of Design & Nature and Ecodynamics**, v. 15, pp. 873-884, 2020. DOI: <https://doi.org/10.18280/ijdne.150613>

LIMA, Y. T. B.; ISOLDI, L. A.; SANTOS, E. D.; MACHADO, B. N.; GOMES, M. N.; BISERNI, C. *et al.* Study of the Geometry of an Oscillating Water Column Device with Five Chambers Coupled under Regular Waves through the Constructal Design Method. **Fluids**, v. 9, 2024. DOI: <https://doi.org/10.3390/fluids9040086>

LIMA, Y.T.B.; GOMES, M.N.; CARDOZO, C.F.; ISOLDI, L.A.; SANTOS, E.D.; ROCHA, L.A.O. Analysis of Geometric Variation of Three Degrees of Freedom through the Constructal Design Method for a Oscillating Water Column Device with Double Hidropneumatic Chamber. **Defect and Diffusion Forum**, v. 396, pp. 22-31, 2019. DOI: <https://doi.org/10.4028/www.scientific.net/DDF.396.22>

- LISBOA, R.C.; TEIXEIRA, P.R.F.; DIDIER, E. Regular and Irregular Wave Propagation Analysis in a Flume with Numerical Beach Using a Navier-Stokes Based Model. **Defect and Diffusion Forum**, v. 372, pp. 81-90, 2017. DOI: <https://doi.org/10.4028/www.scientific.net/DDF.372.81>
- LÓPEZ, I.; IGLESIAS, G. Efficiency of OWC wave energy converters: A virtual laboratory. **Applied Ocean Research**, v. 44, pp. 63-70, 2014. DOI: <http://dx.doi.org/10.1016/j.apor.2013.11.001>
- MAHDY, A.; HASANIEN, H.M.; ABDEL ALEEM, S.H.E.; AL-DHAIFALLAH, M.; ZOBAA, A.F.; ALI, Z.M. State-of-the-Art of the most commonly adopted wave energy conversion systems. **Ain Shams Engineering Journal**, v. 15, 2024. DOI: <https://doi.org/10.1016/j.asej.2023.102322>
- MAHMOUD, M.; ADBELKAREEM, M.A.; OLABI, A.G. Wave energy extraction Technologies. **Renewable Energy – Volume 2: Wave, Geothermal, and Bioenergy**. 2021. Cap. 1-3, pp. 37-51.
- MAVRIPPLIS, D.J. Unstructured Grid Techniques. **Annual Reviews of Fluid Mechanics**, v. 29, pp. 473-514, 1997. DOI: <https://doi.org/10.1146/annurev.fluid.29.1.473>
- MISIULIA, D.; ELSAYED, K.; ANDERSSON, A. G. Geometry optimization of a deswirler for cyclone separator in terms of pressure drop using CFD and artificial neural network. **Separation and Purification Technology**, v. 185, pp. 10-23, 2017. DOI: <https://doi.org/10.1016/j.seppur.2017.05.025>
- MONTGOMERY, D.C. **Design and Analysis of Experiments**. John Wiley & Sons, v. 8, 2012.
- PATANKAR, S. V. **Numerical Heat Transfer and Fluid Flow**. McGraw-Hill, New York, 1980.
- REHMAN, S.; ALHEMS, L.M.; ALAM, M.M.; WANG, L.; TOOR, Z. A review of energy extraction from wind and ocean: Technologies, merits, efficiencies, and cost. **Ocean Engineering**, v. 267, 2023. DOI: <https://doi.org/10.1016/j.oceaneng.2022.113192>
- SEO, D.; HUH, T.; KIM, M.; HWANG, J.; JUNG, D. Prediction of Air Pressure Change Inside the Chamber of an Oscillating Water Column–Wave Energy Converter Using Machine-Learning in Big Data Platform. **Energies**, v. 14, 2021. DOI: <https://doi.org/10.3390/en14112982>
- SHADMANI, A.; NIKOO, M.R.; GANDOMI, A.H.; WANG, R.Q.; GOLPALVAR, B. A review of machine learning and deep learning applications in wave energy forecasting and WEC optimization. **Energy Strategy Reviews**, v. 49, 2023. DOI: <https://doi.org/10.1016/j.esr.2023.101180>
- SHENG, W.; ALCORN, R.; LEWIS, A. On thermodynamics in the primary power conversion of oscillating water column wave energy converters. **Journal of Renewable and Sustainable Energy**, v. 5, 2013. DOI: <http://dx.doi.org/10.1063/1.4794750>
- SILVA, J.M.; VIEIRA, S.M.; VALÉRIO, D.; HENRIQUES, J.C.C.; SCLAVOUNOS, P.D. Air pressure forecasting for the Mutriku oscillating-water-column wave power plant: Review and case study. **IET Renewable Power Generation**, v.15, pp. 3485-3503, 2021. DOI: <https://doi.org/10.1049/rpg2.12289>
- STEIN, M. Large Sample Properties of Simulations Using Latin Hypercube Sampling. **Technometrics**, v. 29, n. 2, p. 143-151, 1987. DOI: <https://doi.org/10.2307/1269769>

TEIXEIRA, P.R.F.; DIDIER, E. Numerical analysis of the response of an onshore oscillating water column wave energy converter to random waves. **Energy**, v. 220, 2021. DOI: <https://doi.org/10.1016/j.energy.2020.119719>

YANG, J.; PALAZZOLO, A. Deep convolutional autoencoder augmented CFD thermal analysis of bearings with inter pad groove mixing. **International Journal of Heat and Mass Transfer**, v. 188, 2022. DOI: <https://doi.org/10.1016/j.ijheatmasstransfer.2022.122639>

ZINANI, F.S.F. Fluidodinâmica Computacional e otimização de conversores de energia das ondas do mar. **Revista 3S**, pp. 33-37, 2023.

Recebido em: 29/10/2024

Aprovado em: 12/12/2024