



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENERGIA NUCLEAR
CURSO DE GRADUAÇÃO EM ENGENHARIA DE ENERGIA

MARIA FERNANDA NUNES SILVA

***PHYSICS-INFORMED NEURAL NETWORKS APLICADAS À MODELAGEM
DINÂMICA DE VENTO***

Recife

2024

MARIA FERNANDA NUNES SILVA

Documento assinado digitalmente
 MARIA FERNANDA NUNES SILVA
Data: 30/10/2024 11:01:03-0300
Verifique em <https://validar.iti.gov.br>

**PHYSICS-INFORMED NEURAL NETWORKS APLICADAS À MODELAGEM
DINÂMICA DE VENTO**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Energia da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Engenheira de
Energia.

Orientador: Prof. Dr. Alexandre Carlos Araújo da Costa
Universidade Federal de Pernambuco

Documento assinado digitalmente
 ALEXANDRE CARLOS ARAUJO DA COSTA
Data: 31/10/2024 16:01:56-0300
Verifique em <https://validar.iti.gov.br>

Coorientador: Prof. Dr. José Ângelo Peixoto da Costa
Instituto Federal de Pernambuco

Documento assinado digitalmente
 JOSE ANGELO PEIXOTO DA COSTA
Data: 30/10/2024 14:11:43-0300
Verifique em <https://validar.iti.gov.br>

Recife

2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Silva, Maria Fernanda Nunes.

Physics-informed Neural Networks aplicadas à modelagem dinâmica de vento
/ Maria Fernanda Nunes Silva. - Recife, 2024.

44 p. : il., tab.

Orientador(a): Alexandre Carlos Araújo da Costa

Coorientador(a): José Ângelo Peixoto da Costa

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia de Energia -
Bacharelado, 2024.

Inclui referências.

1. PINN. 2. Simulação. 3. escoamento. 4. Energia eólica. I. Costa, Alexandre
Carlos Araújo da. (Orientação). II. Costa, José Ângelo Peixoto da. (Coorientação).
IV. Título.

620 CDD (22.ed.)

MARIA FERNANDA NUNES SILVA

**PHYSICS-INFORMED NEURAL NETWORKS APLICADAS À MODELAGEM
DINÂMICA DE VENTO**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Energia da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Engenheira de Energia.

Aprovado em 18/10/2024

BANCA EXAMINADORA

Documento assinado digitalmente
 **RAMIRO BRITO WILLMERSDORF**
Data: 07/11/2024 10:25:41-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Ramiro Brito Willmersdorf
Universidade Federal de Pernambuco

Documento assinado digitalmente
 **FREDERICO DUARTE DE MENEZES**
Data: 07/11/2024 10:52:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Frederico Duarte de Menezes
Instituto Federal de Pernambuco

Dedico este trabalho

Ao meu irmão, Álysson Fernando.

[Querido, desculpe a ausência nos primeiros anos desse curso. Se eu for o motivo de algo na sua vida, que seja para que não desista do que realmente quer.]

À tia Nina (*in memoriam*).

AGRADECIMENTOS

A todos que, de alguma forma, fizeram esses anos parecerem um instante.

[Eu tive quem sempre olhou por mim.]

Ao apoio financeiro, durante a realização da graduação, das empresas do grupo CPFL Energia, sob supervisão da ANEEL - Agência Nacional de Energia Elétrica, número do projeto P&D PD-00063-3090.

*“O vento se levanta!... é preciso tentar viver!”¹.
(Paul Valéry, Le Cimetière marin, 1920, tradução nossa).*

¹ Le vent se lève!... il faut tenter de vivre!

RESUMO

A energia eólica desempenha um papel fundamental na mitigação das alterações climáticas, sendo de particular importância para a redução das emissões de gases poluentes no setor de energia. Um de seus desafios centrais é a compreensão detalhada da dinâmica do fluxo atmosférico na camada limite, onde os aerogeradores operam, essencial para otimizar sua eficiência. Este trabalho investiga o uso de *Physics-informed Neural Networks* (PINNs) em simulações de escoamento, com foco específico no efeito esteira gerado pelos aerogeradores. Para alcançar esse objetivo, foi implementada uma PINN capaz de resolver as equações de escoamento ao mesmo tempo que atende às condições de contorno estabelecidas, direcionando-se para simulações de pequena escala. A metodologia incluiu a validação dos resultados obtidos, além de uma análise das discrepâncias entre os dados gerados pela PINN e as simulações de Dinâmica de Fluidos Computacional (CFD) convencionais. Os resultados revelaram sutis diferenças entre as duas abordagens, refletindo as particularidades de cada metodologia. As redes neurais apresentaram vantagens notáveis, como uma execução mais rápida e custos computacionais reduzidos, sugerindo que as PINNs são uma alternativa viável e promissora para otimizar simulações no campo da energia eólica.

Palavras-chave: PINN; simulação; escoamento; energia eólica.

ABSTRACT

Wind energy plays a key role for mitigating Climate Change, and is of particular importance for reducing emissions of polluting gases in the energy sector. One of its central challenges is a detailed understanding of the atmospheric flow dynamics within the boundary layer, where turbines perform, which is essential for optimizing their efficiency. This work investigates the use of Physics-informed Neural Networks (PINNs) in flow simulations, with a particular emphasis on the wake effect generated by wind turbines. To achieve this goal, a PINN capable of solving the flow equations while meeting the established boundary conditions was implemented, aiming small-scale simulations. The methodology included validating the results obtained, besides analyzing the discrepancies between the data generated by PINN and conventional Computational Fluid Dynamics (CFD) simulations. The results showed subtle differences between the two approaches, reflecting the particularities of each method. Neural Networks showed notable advantages, such as faster execution and reduced computational costs, suggesting that PINNs are a viable and promising alternative for simulations in the field of wind energy.

Keywords: PINN; simulation; fluid flow; wind energy.

LISTA DE FIGURAS

Figura 1 –	Esquema de uma rede PINN.	18
Figura 2 –	Escoamento viscoso incompressível entre placas paralelas.	23
Figura 3 –	Diagrama simplificado do funcionamento da rede PINN implementada.	29
Figura 4 –	Implementação das equações e dos tensores de tensão na função de perda.	29
Figura 5 –	Representação do problema simulado.	31
Figura 6 –	Malha da simulação de CFD	32
Figura 7 –	Comportamento da velocidade horizontal obtido por simulação de CFD.	32
Figura 8 –	Comportamento da velocidade vertical obtido por simulação de CFD.	33
Figura 9 –	Fluxo de velocidade total obtido por simulação de CFD.	33
Figura 10 –	Distribuição de pressão estática obtida por simulação de CFD.	33
Figura 11 –	Grade computacional da rede PINN.	35
Figura 12 –	Comportamento da velocidade horizontal obtido pela PINN.	35
Figura 13 –	Comportamento da velocidade vertical obtido pela PINN.	35
Figura 14 –	Fluxo de velocidade total obtido pela rede PINN.	36
Figura 15 –	Distribuição de pressão estática obtida pela rede PINN	36
Figura 16 –	Linhas de fluxo do perfil de velocidade total.	36
Figura 17 –	Gráfico de perda em função do número de iterações dos otimizadores.	37
Figura 18 –	Resultados da rede PINN (a) e da simulação de CFD (b).	39

LISTA DE TABELAS

Tabela 1 – Saídas da PINN e da simulação de CFD para as mesmas coordenadas.	38
Tabela 2 – Resultados da rede PINN para diferentes geometrias.	40

LISTA DE ABREVIATURAS E SIGLAS

AD	<i>Automatic Differentiation/Diferenciação Automática</i>
CFD	<i>Computational Fluid Dynamics/Dinâmica de Fluidos Computacional</i>
DNN	<i>Deep Neural Network/Rede Neural Profunda</i>
EDP	Equação Diferencial Parcial
GEE	Gases de Efeito Estufa
LBFSGS	Limited-memory Broyden-Fletcher-Goldfarb-Shanno
LHS	<i>Latin Hypercube Sampling/Amostragem por Hipercubo Latino</i>
MLP	<i>Multilayer Perceptron/Perceptron Multicamadas</i>
MSE	<i>Mean Squared Error/Erro Quadrático Médio</i>
PINN	<i>Physics-informed Neural Network</i>
RMSE	<i>Root Mean Square Error/Raiz Quadrada do Erro Médio</i>

LISTA DE SÍMBOLOS

Re	Número de Reynolds
ρ	Densidade do fluido
V	Velocidade do fluido
L	Comprimento da placa
μ	Viscosidade dinâmica do fluido
$\nabla \cdot$	Operador de divergência
t	Tempo
g	Aceleração da gravidade
∇^2	Operador laplaciano
p	Pressão
u	Componente horizontal da velocidade
U_{\max}	Máxima velocidade de entrada
v	Componente vertical da velocidade
y_i	Previsão da rede PINN
\hat{y}_i	Previsão da simulação de CFD
H	Altura da placa

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Motivação	14
1.2	Objetivos	16
1.2.1	<i>Objetivos gerais</i>	16
1.2.1	<i>Objetivos específicos</i>	16
1.2	Estrutura	16
2	CONCEITOS PRELIMINARES	17
2.1	Redes neurais	17
2.2	Physics-informed Neural Networks	18
2.3	Efeito esteira	19
3	ESTADO DA ARTE	20
4	METODOLOGIA	22
4.1	Propriedades do fluido e do escoamento	22
4.1.1	<i>Escoamento laminar e perfil de velocidade</i>	22
4.1.2	<i>Escoamento ao redor de corpos imersos em fluido</i>	23
4.2	Equações governantes	24
4.3	Condições de contorno	25
4.4	Arquitetura computacional	26
4.4.1	<i>Treinamento da rede</i>	27
4.4.2	<i>Definição da função de perda</i>	28
4.5	Comparação com simulações de CFD	30
5	ANÁLISE E DISCUSSÃO DOS RESULTADOS	31
6	CONCLUSÕES	41
	REFERÊNCIAS	42

1 INTRODUÇÃO

1.1 Motivação

As mudanças climáticas são um dos desafios mais urgentes enfrentados atualmente. Elas referem-se às alterações de longo prazo nos padrões climáticos da Terra, resultantes, principalmente, do aumento das concentrações de gases de efeito estufa (GEE) na atmosfera, e têm causado impactos significativos a nível global. A geração de energia interfere consideravelmente nessas mudanças, pois muitas fontes de energia convencionais, como a queima de combustíveis fósseis, liberam grandes quantidades de dióxido de carbono na atmosfera. A Agência Internacional de Energia estima que, hoje, o setor de energia seja responsável por mais de 70% das emissões globais de GEE (IEA, 2023).

A energia eólica é essencial na transição para um sistema energético mais sustentável, contribuindo para a redução dessas emissões e para a mitigação das mudanças climáticas (IPCC, 2023). No ano de 2023, a indústria eólica somou 1 TW de capacidade instalada, levando aproximadamente quatro décadas para atingir esse marco. No entanto, é na projeção futura que vislumbramos seu verdadeiro potencial: a adição de outro TW até 2030, isto é, em um tempo cerca de 5 vezes menor. Um aumento dessa magnitude na demanda requer uma otimização nos processos: “A indústria eólica agora precisa das condições certas para atingir o nível exigido para cumprir integralmente sua promessa de energia mais limpa e barata para todos”² (GWEC, 2023, p. 16, tradução nossa).

Veers *et al.* (2019) identificaram três grandes desafios para esse avanço, dentre eles, a necessidade premente de um entendimento mais profundo da dinâmica do fluxo atmosférico na camada limite, onde os aerogeradores operam. A precisão na compreensão dos padrões de vento é fundamental não apenas para o desenvolvimento inicial, mas também para a operação contínua e a otimização dos parques eólicos (Archer; Jacobson, 2007).

Sendo assim, a Dinâmica de Fluidos Computacional (CFD, do acrônimo de *Computational Fluid Dynamics*) se destaca, uma vez que permite simular o

² The wind industry now needs the right conditions to step up to the level that is required of it to fully deliver on its promise of cleaner and cheaper energy for all.

comportamento do vento em diferentes condições atmosféricas e terrenos (Dhunny; Lollchund; Rughooputh, 2017); possibilitando, dessa forma, a identificação de locais ideais para instalação de aerogeradores, além de otimizar o design das próprias turbinas para maximizar a eficiência energética (Dhert; Ashuri; Martins, 2017), por exemplo.

Todavia, o uso extensivo da CFD na modelagem atmosférica enfrenta alguns desafios. Apesar de eficaz, apresenta limitações quando se trata de questões estruturais, pois sua ênfase em grandezas médias no tempo não fornece informações adequadas sobre valores instantâneos, como picos de vento. Ademais, o alto custo computacional restringe sua aplicação em análises práticas em larga escala (Shao *et al.*, 2023). As simulações de CFD exigem recursos substanciais devido à complexidade dos modelos e à necessidade de resolver as equações fundamentais que descrevem o escoamento dos fluidos. Isto pode resultar em tempos de simulação prolongados e custos operacionais elevados, limitando a capacidade de realizar estudos detalhados em larga escala ou de explorar uma ampla gama de cenários.

Shao *et al.* (2023) também explicam que essas limitações ressaltam a necessidade de desenvolvimento contínuo e abordagens complementares para garantir precisão e eficácia em diversas aplicações. Uma abordagem promissora para mitigar esses desafios é a implementação de redes neurais do tipo *Physics-informed Neural Networks* (PINNs). Estas redes combinam a capacidade das redes neurais de aprender padrões complexos nos dados com a física subjacente do problema (Raissi; Perdikaris; Karniadakis, 2019), reduzindo o tempo de simulação e oferecendo uma alternativa viável e econômica à CFD tradicional. Além de reduzir o custo computacional, as PINNs também têm o potencial de lidar com dados incompletos ou ruidosos, o que é comum em estudos atmosféricos devido à natureza complexa e variável do vento (Jin *et al.*, 2021), podendo gerar estimativas precisas mesmo em condições em que os outros métodos apresentam dificuldades.

1.2 Objetivos

1.2.1 Objetivos gerais

Aplicar e validar o uso de uma PINN na solução de problemas de escoamento, com foco na sua aplicação para simulações de pequena escala, isto é, a fenômenos que ocorrem em áreas limitadas e que podem ser estudados em um contexto local.

1.2.2 Objetivos específicos

- i. Simulação de CFD que represente adequadamente o escoamento ao redor de um anteparo;
- ii. Implementação de uma rede neural (do tipo PINN) para resolução numérica das equações que descrevem o escoamento ao redor do mesmo anteparo;
- iii. Validação dos resultados e avaliação das discrepâncias entre os resultados de ambas as abordagens.

1.3 Estrutura

Após esta introdução, é apresentada uma fundamentação teórica, abordando os conceitos essenciais necessários para a compreensão deste trabalho, e se segue para uma breve revisão bibliográfica, na qual se realiza uma análise sucinta de trabalhos e teorias relevantes ao tema em questão. Posteriormente, é dedicado um capítulo à metodologia empregada e, logo após, são apresentados os resultados obtidos, acompanhados de uma análise e discussão dos mesmos. Por fim, uma conclusão sintetizando os principais achados da pesquisa, destacando suas contribuições para o avanço do conhecimento na área e sugerindo possíveis direções para pesquisas futuras.

2 CONCEITOS PRELIMINARES

2.1 Redes neurais

No livro "Deep Learning", Goodfellow, Bengio e Courville (2016) descrevem as redes neurais como modelos computacionais que se inspiram no funcionamento do sistema nervoso biológico. Essas redes são compostas por unidades básicas conhecidas como neurônios, organizados em camadas. Cada neurônio em uma camada está interligado a neurônios em camadas subsequentes através de conexões denominadas sinapses, que possuem pesos ajustáveis. O aprendizado em redes neurais ocorre por meio da modificação desses pesos com base nas entradas recebidas e nas saídas desejadas, permitindo a rede mapear entradas para saídas com precisão.

Durante a fase de treinamento, um conjunto de dados é introduzido na rede, e as saídas geradas são comparadas com as saídas esperadas para calcular o erro. Esse erro é retropropagado através da rede, ajustando os pesos das conexões para reduzir a discrepância entre as saídas previstas e as esperadas. O ajuste contínuo dos pesos é realizado por algoritmos de otimização e é fulcral para a capacidade da rede de aprender e generalizar a partir dos dados.

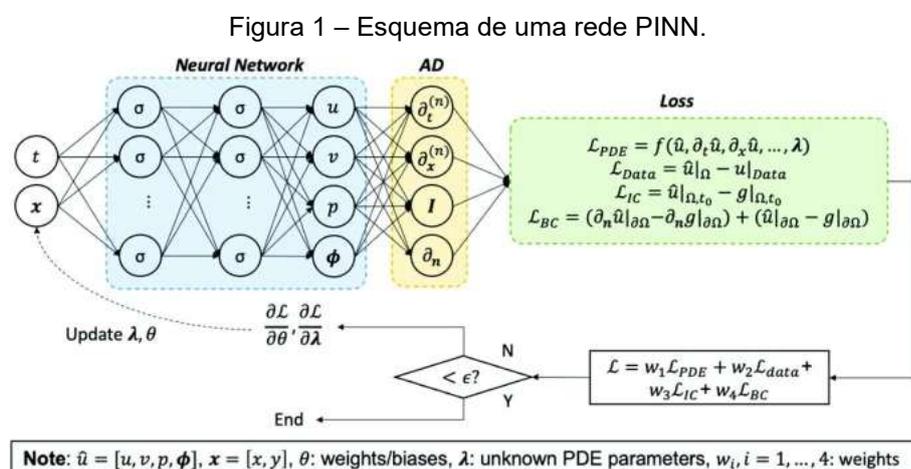
Além das estruturas básicas, as redes neurais podem ser classificadas em diferentes tipos conforme sua arquitetura e aplicação. As Redes Neurais Profundas (DNN, do acrônimo de *Deep Neural Networks*) são uma evolução das tradicionais, caracterizando-se por possuírem múltiplas camadas ocultas, o que permite aprender representações hierárquicas e complexas dos dados. A Perceptron de Múltiplas Camadas (*Multilayer Perceptron*, MLP) adota uma arquitetura *feedforward*, processando dados em uma única direção, da camada de entrada para a camada de saída. Com várias camadas de neurônios, incluindo camadas ocultas, as MLPs aumentam a capacidade da rede de resolver problemas sofisticados, utilizando funções de ativação nas camadas ocultas para aprender representações abstratas dos dados.

2.2 Physics-informed Neural Networks

A introdução da física no *machine learning*, através das *Physics-informed Neural Networks* (PINNs), representa uma evolução significativa das redes neurais convencionais, sendo especialmente desenvolvidas para resolver problemas que envolvem Equações Diferenciais Parciais (EDPs) e leis físicas subjacentes. O conceito central dessas redes é a integração de conhecimento físico diretamente na sua estrutura durante o treinamento. Isso é alcançado adicionando uma camada física à arquitetura da rede, que codifica as leis físicas que governam o sistema modelado pelas equações (Raissi; Perdikaris; Karniadakis, 2019).

A inclusão dessa camada física assegura que as soluções geradas respeitem rigorosamente as leis físicas, aumentando a robustez e a precisão dos resultados. Durante o treinamento, a rede neural ajusta seus parâmetros não apenas para minimizar o erro entre as saídas previstas e os dados de entrada, mas também para garantir conformidade com as restrições físicas incorporadas. Esse método permite a modelagem eficiente de sistemas complexos governados por EDPs e oferece uma abordagem computacionalmente viável para problemas onde a física é primordial para a precisão dos resultados (Zhang; Zhao, 2021).

Um esquema de uma PINN é representado na Figura 1, ilustrando um problema de múltiplas físicas, no qual as soluções incluem a velocidade, a pressão e um campo escalar, os quais estão interligados em um sistema de equações representado por f . Os elementos chave são a rede neural, o cálculo das derivadas parciais, abordado por meio da diferenciação automática (AD), e a função de perda (Cai et al., 2021).



Fonte: Cai et al. (2021, p. 1729).

2.3 Efeito esteira

O chamado efeito esteira é um fenômeno que surge da interação entre as pás dos aerogeradores em movimento e o ar circundante. Quando as pás giram, elas exercem uma força sobre o ar, deslocando-o de seu caminho original. Esse deslocamento provoca a formação de uma região de baixa pressão na parte traseira do aerogerador e uma região de alta pressão na parte dianteira (Porté-Agel; Bastankhah; Shamsoddin, 2020). Como resultado, ocorre um movimento do ar, sendo puxado para dentro da área de baixa pressão atrás das pás.

A consequência mais evidente desse fenômeno é a criação de um vento mais intenso e turbulento na esteira do aerogerador, especialmente na direção predominante do vento. Tal perturbação do fluxo de ar pode impactar significativamente a eficiência dos aerogeradores subsequentes em um parque eólico (Jiménez; Crespo; Migoya, 2010).

Ademais, o efeito esteira também pode ter implicações climáticas locais, influenciando padrões de vento e temperatura na área circundante aos aerogeradores. Portanto, sua compreensão é fundamental para o planejamento adequado e a otimização da disposição dos aerogeradores em parques eólicos, visando minimizar impactos na eficiência energética e no ambiente local. Estudos detalhados e modelagem computacional são comumente empregados para a análise e mitigação desse fenômeno.

3 ESTADO DA ARTE

A necessidade de incorporar informações físicas em métodos de aprendizado de máquina para resolver problemas complexos foi enfatizada por Sirignano e Spiliopoulos (2018), já que soluções consistentes com as leis da física tendem a ser mais confiáveis (Cai *et al.*, 2021). As PINNs representam uma solução inovadora para a modelagem de sistemas complexos, permitindo a otimização eficiente dos parâmetros do modelo, o que as torna uma ferramenta valiosa para resolver problemas em várias disciplinas.

Métodos de inteligência computacional têm mostrado eficácia na reconstrução de campos eólicos de alta dimensão com dados limitados. A transição de abordagens baseadas exclusivamente em dados para modelos híbridos, que combinam dados com princípios físicos, tem sido sugerida como uma forma de alcançar maior precisão e melhor capacidade de generalização (Zehtabiyani-Rezaie; Iosifidis; Abkar, 2022). Essa combinação melhora a precisão das previsões, tornando os modelos mais robustos e aplicáveis a uma maior variedade de cenários. Shao *et al.* (2023) demonstraram que a integração de equações físicas com redes neurais permite previsões com uma velocidade de execução entre 1 e 2 ordens de magnitude mais rápida que os métodos tradicionais de CFD, sem comprometer a precisão, embora o processo exija muita memória de vídeo durante o treinamento.

Em um estudo recente, Cobelli *et al.* (2023) utilizaram PINNs para modelar campos de vento em parques eólicos com dados de velocidade simulados numericamente. Os resultados mostraram alta precisão na reconstrução do campo de vento, com erros médios quadráticos de 0,32 m/s e 0,22 m/s para as velocidades nas direções longitudinal e transversal, respectivamente. O treinamento foi concluído em menos de três horas, significativamente mais rápido que as simulações numéricas tradicionais.

O que torna essas redes únicas é a capacidade de formular soluções para equações diferenciais parciais (Rao; Chenping; Sun, 2021). Além disso, uma das principais vantagens das PINNs é sua robustez ao lidar com dados incompletos ou ruidosos, proporcionando aproximações contínuas para as soluções (Jin *et al.*, 2021). Isso é especialmente relevante em aplicações práticas, onde os dados experimentais frequentemente contêm erros ou incertezas, como em medições atmosféricas, dadas as falhas nos sistemas de aquisição de dados que operam sob condições adversas e

a complexidade e variabilidade do vento. Quando os dados são escassos, redes neurais tradicionais tendem a falhar em produzir resultados precisos (Shao *et al.*, 2023), e gerar dados substitutos através de simulações de CFD é altamente custoso.

Sun *et al.* (2020) aplicaram as PINNs em escoamento de fluidos sem dados, recorrendo apenas a condições iniciais e de contorno. Em outro estudo, Wang *et al.* (2021) treinaram redes com os próprios dados resultantes de CFD e conseguiram prever o campo de fluxo em diferentes instantes de tempo, reconstruindo campos de temperatura e fluxo em convecção natural com geometrias complexas, utilizando uma rede neural baseada em princípios físicos.

Rao, Sun e Liu (2020) apresentaram resultados de alta precisão ao simular o fluxo laminar incompressível ao redor de um cilindro, aprimorando a previsão do tensor de tensão de Cauchy e eliminando a necessidade de diferenciação automática para calcular a segunda derivada. Zhu *et al.* (2019) mostraram que seu modelo gerava previsões e a incerteza associada sem a necessidade de dados rotulados, incorporando as equações governantes como funções de verossimilhança no termo de perda.

As PINNs também têm se mostrado eficazes na modelagem de campos de vento, oferecendo previsões precisas dos campos de velocidade e sendo eficientes no processamento computacional, resolvendo problemas diretos e inversos de alta dimensão em uma única execução). Cobelli *et al.* (2023) sugeriram que estudos explorem a utilização das PINNs para reconstruir o comportamento da velocidade na esteira, o que pode ampliar ainda mais seu campo de aplicação.

4 METODOLOGIA

O problema consiste na simulação de um problema de fluidodinâmica envolvendo a modelagem do escoamento bidimensional do ar na microescala em um canal e em torno de um anteparo intransponível, representando a seção reta de um cilindro (relativa ao corte perpendicular a seu eixo principal), sobre uma superfície plana ao nível do mar. A simulação busca entender a interação do ar com a estrutura e observar os padrões de velocidade e pressão do fluido em sua esteira, no caso de um fluxo laminar incompressível. Ressalta-se que o anteparo mencionado é, aqui, adotado como aproximação inicial ao problema relativo à simulação da interação do escoamento do ar com um aerogerador, tendo tal aproximação o propósito único de permitir a instrução com respeito ao uso e o entendimento do exemplo que acompanha a estrutura escolhida para a realização deste trabalho.

4.1 Propriedades do fluido e do escoamento

A viscosidade, medida da resistência ao escoamento, é a propriedade física mais importante na descrição do comportamento mecânico de um fluido específico (White, 2011). O número de Reynolds é o parâmetro que caracteriza a relação entre forças inerciais e viscosas, determinado através da Equação 1.

$$Re = \frac{\rho VL}{\mu} \quad (1)$$

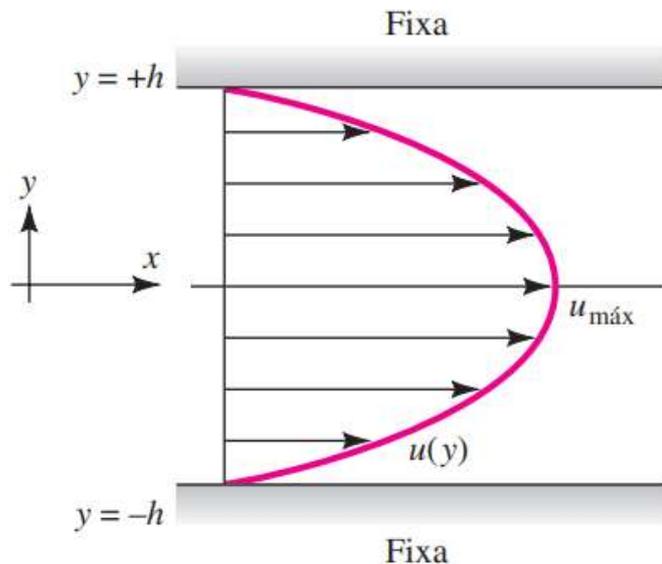
Neste trabalho, considerar-se-á o ar seco a temperatura ambiente como fluido, a uma temperatura de 25 °C e pressão atmosférica padrão de 101,3 kPa, o que confere uma densidade de 1 kg/m³ e viscosidade dinâmica de 0,02 kg/m².s.

4.1.1 Escoamento laminar e perfil de velocidade

No escoamento laminar, eventuais perturbações naturais são rapidamente dissipadas. O fluxo é ordenado e suave, e se move em camadas paralelas com mínima turbulência. Este tipo de escoamento incompressível, quando entre placas

paralelas fixas, apresenta um perfil parabólico de velocidade, o que significa que a velocidade é máxima no centro e diminui gradualmente até se anular nas paredes, vide Figura 2, obedecendo à condição de não escorregamento característica dos fluidos viscosos.

Figura 2 – escoamento viscoso incompressível entre placas paralelas.



Fonte: Adaptado de White, 2011.

4.1.2 Escoamento ao redor de corpos imersos em fluido

Ainda de acordo com White (2011), em escoamentos ao redor de corpos rombudos imersos em uma corrente de fluido, ocorre separação do fluxo tanto nas bordas de ataque (a parte que primeiro entra em contato com o fluido) quanto nas bordas de fuga (extremidade oposta, onde o fluido se separa da superfície do corpo). Em superfícies mais aerodinâmicas, como um cilindro circular, o escoamento se mantém próximo ao contorno do corpo.

A separação do escoamento resulta em uma região de esteira atrás do cilindro, cujo comportamento é fortemente influenciado pelo número de Reynolds. Em números de Reynolds baixos, a separação gera pequenas regiões de recirculação logo após as bordas, criando bolsões de vórtices de formação suave e estável. Nesses casos, o fluido segue um padrão de recirculação laminar, sem grandes flutuações ou instabilidades na sua esteira. Estudos experimentais, como os realizados por Sohankar, Norberg e Davidson (1997), indicam que o despreendimento de vórtices ao

redor de cilindros circulares ocorre a um número de Reynolds crítico de cerca de 49, com uma incerteza de mais ou menos 2, considerando a largura da seção transversal do cilindro como referência de comprimento para o cálculo.

4.2 Equações governantes

A equação da conservação da massa, ou equação da continuidade, descreve a conservação da massa em um volume de controle, como o próprio nome sugere. É expressa tal como apresentada na Equação 2.

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

Outra equação governante é a equação de Navier-Stokes, que descreve a relação entre as forças atuantes em um fluido e sua aceleração resultante.

É comum que se considere um sistema fechado, onde as propriedades do fluido, como densidade, viscosidade dinâmica e condutividade térmica, permanecem constantes ao longo do tempo e do espaço, caracterizando as condições ideais para uma análise fluidodinâmica. Para um escoamento incompressível, considerando esses fatores, a equação de Navier-Stokes dada na Equação 3 descreve como a velocidade do fluido varia no tempo e no espaço sob a influência de forças como pressão, viscosidade e forças externas.

$$\rho \frac{d\mathbf{V}}{dt} = \rho \mathbf{g} - \nabla p + \mu \nabla^2 \mathbf{V} \quad (3)$$

Além do mais, sabendo que ρ é constante, as variáveis se reduzem a apenas p e \mathbf{V} , e as equações podem ser resolvidas inteiramente separadas para a pressão e a velocidade, com condições de contorno como: $\mathbf{V} = \mathbf{V}_{\text{parede}}$ para uma superfície sólida; \mathbf{V} e p conhecidas na entrada ou na saída (White, 2011). O gradiente de pressão da Equação 3 acaba sendo constante porque, segundo a teoria da separação de variáveis, se duas grandezas são iguais e variam de maneira independente, elas devem ser iguais a uma constante comum; e menor que 0, uma vez que a pressão diminui na direção do escoamento para superar a resistência gerada pela tensão de cisalhamento nas paredes. A aceleração da gravidade pode ser desconsiderada em

escoamentos onde os efeitos inerciais ou viscosos predominam, como em escalas curtas de tempo ou espaço, especialmente em tubos ou canais com orientação horizontal e confinamento.

4.3 Condições de contorno

As condições de contorno determinam o comportamento do fluido em diferentes regiões do sistema. Quando ambas as placas são fixas e apresentam velocidade nula, a equação da continuidade leva a um escoamento que depende apenas da posição y , apresentando uma distribuição parabólica característica de um escoamento laminar, seguindo o perfil de Poiseuille. Destarte, para este trabalho, foram adotadas as Equações 4 e 5 como condições de contorno da velocidade na entrada do sistema.

Na saída, a pressão é definida como zero, Equação 6, pois o fluido, em teoria, se expande para a atmosfera livre. Quanto à superfície do anteparo, as velocidades horizontal e vertical são fixadas em zero, Equação 7, refletindo a condição de não deslizamento. Isso significa que, na interface entre o fluido e o anteparo, não ocorre movimento relativo e o fluido se adere à superfície.

Na entrada:

$$\mathbf{u} = \frac{4 y U_{\max} (H - y)}{H^2} \quad (4)$$

$$\mathbf{v} = 0 \quad (5)$$

Na saída:

$$p = 0 \quad (6)$$

Nas paredes e na superfície do anteparo:

$$\mathbf{u} = \mathbf{v} = 0 \quad (7)$$

4.4 Arquitetura computacional

Uma vez estabelecidas as equações governantes, o domínio de simulação é discretizado em uma grade computacional, que permite a transformação das equações diferenciais parciais que regem o escoamento em uma representação numérica adequada para solução via métodos computacionais.

A preparação dos dados envolve a criação de vários conjuntos de pontos, que correspondem às diferentes condições de contorno, como entrada e saída de fluxo, bem como as superfícies da parede do domínio e do obstáculo. Esses pontos são estrategicamente posicionados para cobrir todo o domínio de interesse de maneira uniforme, e são gerados com o método do Hipercubo Latino (LHS), que garante uma distribuição eficiente no espaço, buscando capturar de forma precisa o comportamento das soluções das equações diferenciais parciais. Por ser um método sem malha, elimina a necessidade de uma grade estruturada e oferece maior flexibilidade para lidar com geometrias complexas.

Adicionalmente, uma área de refinamento é estabelecida ao redor do obstáculo. O refinamento permite uma maior densidade de pontos em regiões críticas, como áreas de separação de escoamento e zonas de recirculação. Dentro dessa área, os pontos adicionais também são distribuídos uniformemente, excluindo-se aqueles localizados dentro do obstáculo, para evitar cálculos desnecessários em regiões onde o fluxo não ocorre.

No contexto de implementação, várias bibliotecas de aprendizado de máquina oferecem suporte para a construção e treinamento de uma rede informada pela física, como TensorFlow, Keras, PyTorch e NVIDIA Modulus. No entanto, PyTorch tem se destacado por oferecer uma variedade de módulos e funcionalidades que facilitam a criação e treinamento de redes neurais, incluindo camadas pré-definidas, otimizadores, funções de ativação e ferramentas para cálculos de gradientes automáticos. Esta última, por sua vez, é fundamental para o treinamento eficiente de PINNs, pois simplifica o processo de retropropagação para ajustar os parâmetros da rede neural.

4.4.1 Treinamento da rede

A rede neural empregada é uma DNN projetada para resolver problemas de fluxo e dinâmica de fluidos, especificamente as equações de Navier-Stokes. A profundidade da rede é definida por um número específico de camadas ocultas, enquanto a largura é determinada pelo número de nós em cada camada.

Ela aceita entradas que representam coordenadas espaciais e produz saídas que incluem componentes de velocidade, pressão e componentes do tensor de tensões. Essa segmentação das saídas em variáveis específicas simplifica o processo de cálculo das perdas, permitindo um acesso direto às componentes relevantes para as funções de perda. Um diagrama simplificado do funcionamento da rede em questão é apresentado na Figura 3.

O treinamento da rede é realizado em duas fases: na fase inicial, o otimizador Adam atualiza os pesos, permitindo que a rede aprenda padrões básicos. Em seguida, o LBFGS (Limited-memory Broyden-Fletcher-Goldfarb-Shanno) é utilizado para um ajuste mais preciso, concentrando-se em uma otimização mais refinada com base nas informações do gradiente, recorrendo à direção de descida obtida pelo primeiro otimizador. Essa abordagem combina a eficiência do Adam com a precisão do LBFGS e, com isso, alcança uma melhor performance geral da rede.

Adam é um otimizador que combina a média móvel dos gradientes e dos quadrados dos gradientes. Durante o treinamento, ele suaviza a atualização dos pesos usando um fator de decaimento, o que ajuda a controlar a influência de gradientes antigos. Além disso, ajusta a taxa de aprendizado em cada dimensão, evitando atualizações excessivas quando os gradientes são grandes. Uma característica importante do Adam é a correção de viés, que compensa a inicialização em zero das médias móveis, garantindo atualizações mais confiáveis. Assim, os pesos são atualizados com base nessas médias móveis e um hiperparâmetro que controla a taxa de aprendizado.

Por outro lado, o LBFGS é um método de otimização de segunda ordem que utiliza informações da Hessiana, a matriz de segundas derivadas, para encontrar mínimos de forma eficiente, especialmente em casos em que as avaliações da função de perda são custosas. Ele constrói uma aproximação da Hessiana com base em iterações anteriores, permitindo atualizações de pesos sem calcular a matriz

completa, o que seria computacionalmente caro. As atualizações são feitas na direção que minimiza a função de perda, considerando a direção oposta ao gradiente e um fator que leva em conta o passo de aprendizado e a curvatura da função.

O método de fechamento é responsável por integrar todos esses elementos. Ele limpa os gradientes acumulados antes de calcular as perdas, garantindo que os passos de otimização sejam baseados nas informações mais recentes. Ao passo que calcula as perdas, realiza a retropropagação e ajusta os pesos da rede com base no erro calculado. O armazenamento das perdas ao longo das iterações é importante para monitorar seu desempenho e identificar se a convergência está adequada. Ao finalizar o treinamento, os pesos são salvos para uso futuro.

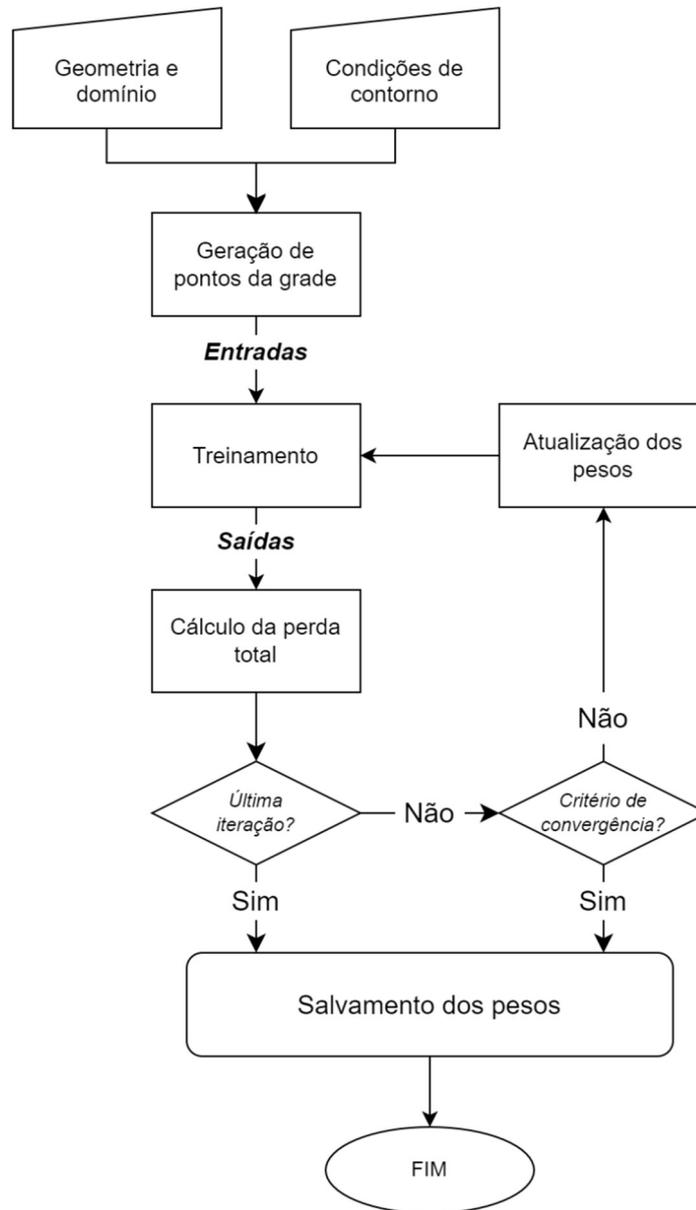
Além do número de iterações, o critério de parada da rede neural inclui a convergência, onde o treinamento é interrompido se a perda total não apresentar melhorias significativas por um número específico de iterações consecutivas, indicando que se pode ter alcançado um mínimo local ou estar estagnada. Outro aspecto é a tolerância do gradiente; se o gradiente das perdas ficar abaixo de um determinado limiar, isso pode indicar que a rede não está mais aprendendo e o treinamento pode ser encerrado.

Adicionalmente, a validação de performance em um conjunto separado de dados pode ser aplicada. Se a performance começar a se deteriorar nesse conjunto, isso pode sinalizar *overfitting*, que ocorre quando o modelo se ajusta excessivamente aos dados de treino, capturando ruídos em vez de padrões gerais.

4.4.2 Definição da função de perda

A perda total é calculada por meio da soma de três componentes distintas: a perda das condições de contorno, a perda da saída e a perda das EDPs. Respectivamente, os termos em questão mensuram o erro quadrático médio (MSE) entre as previsões da rede e os valores de referência nas fronteiras do domínio; dos valores de pressão na saída do domínio; e das discrepâncias entre as previsões da rede e as soluções das equações de Navier-Stokes e da equação da continuidade, incluindo as equações associadas ao tensor de tensões de Cauchy, cuja implementação é exibida na Figura 4. O valor da perda total apresentado a cada iteração é a média dos erros quadráticos em relação a todos os pontos de amostra considerados para cada conjunto associado.

Figura 3 – Diagrama simplificado do funcionamento da rede PINN implementada.



Fonte: A autora (2024).

Figura 4 – Implementação das equações e dos tensores de tensão na função de perda.

```

f0 = u_x + v_y
f1 = self.rho*(u*u_x + v*u_y) - sig_xx_x - sig_xy_y
f2 = self.rho*(u*v_x + v*v_y) - sig_xy_x - sig_yy_y
f3 = -p + 2*self.mu*u_x - sig_xx
f4 = -p + 2*self.mu*v_y - sig_yy
f5 = self.mu*(u_y + v_x) - sig_xy
  
```

Fonte: A autora (2024).

4.5 Comparação com simulações de CFD

Na indústria eólica, os resultados de uma modelagem só são satisfatórios se a solução é capaz de capturar a dinâmica essencial da esteira, incluindo a formação de vórtices e a distribuição de pressão e velocidade. Para uma aplicação prática, como o design e a otimização de parques eólicos, a capacidade de prever com precisão o efeito de esteira é essencial para maximizar a eficiência energética e minimizar os impactos negativos entre turbinas. Se os resultados das previsões são comparados com dados experimentais ou simulações mais convencionais (como as obtidas por métodos de CFD), a precisão e a confiabilidade do método podem ser avaliadas.

De forma breve, uma simulação de CFD começa com o pré-processamento, onde a malha é criada, subdividindo o domínio em pequenos elementos para facilitar os cálculos. Em seguida, o solucionador discretiza as equações de Navier-Stokes por meio de métodos numéricos, aplica as condições de contorno e resolve as equações de forma iterativa, utilizando técnicas de controle de convergência para alcançar uma solução estável do comportamento do fluido. Com a solução, o pós-processamento permite visualizar e interpretar os resultados, analisando o desempenho do sistema.

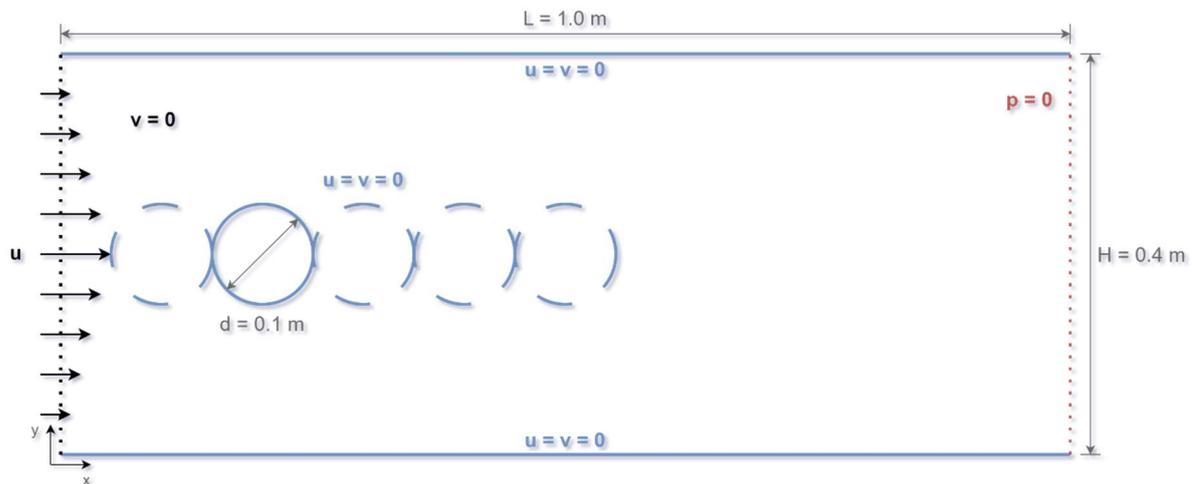
A simulação inicial será realizada no ANSYS Fluent, software amplamente empregado para simulações computacionais em fluidodinâmica, assegurando que a PINN e a ferramenta tenham as mesmas condições de contorno e configurações do domínio. A seguir, comparam-se os resultados obtidos em ambas as abordagens, empregando a raiz quadrada do erro médio (RMSE). Para isso, serão extraídos os valores dos resultados em regiões específicas da simulação, especialmente aquelas consideradas mais relevantes para a análise, como áreas de interesse crítico ou zonas de alta variabilidade, onde cada variável converge para seus valores mínimos e máximos. O RMSE é uma métrica amplamente utilizada que avalia a diferença entre valores previstos e observados, permitindo uma avaliação objetiva da performance do modelo, calculado como na Equação 8.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

5 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo, são apresentados os resultados obtidos no trabalho. A partir da modelagem computacional, buscou-se uma representação acurada do escoamento para resolver o problema de dinâmica de fluidos ilustrado na Figura 5. A posição do cilindro pode variar livremente ao longo do eixo das abscissas, e na simulação inicial foi considerado um valor fixo de 0,2. As condições de contorno foram estabelecidas de acordo com as características do escoamento em presença de um único obstáculo imerso, *vide* Seção 4.3, incluindo os parâmetros de velocidade e viscosidade do fluido definidos na Seção 4.1.

Figura 5 – Representação do problema simulado.



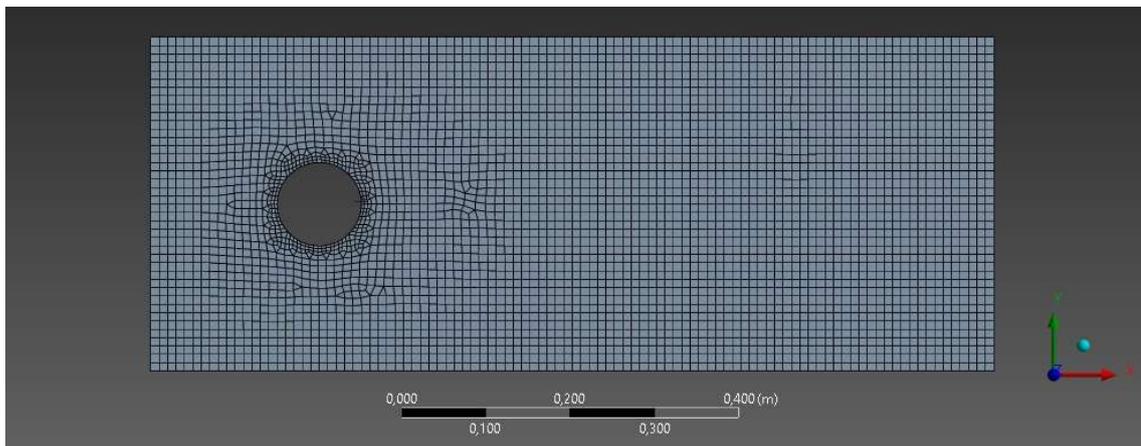
Fonte: A autora (2024).

O diâmetro do cilindro foi mantido como 0,1 m e a velocidade máxima de entrada estava normalizada em 1 m/s, o que resulta em $Re = 5$, garantindo o escoamento laminar. A relação entre a altura do canal e o comprimento do anteparo foi estabelecida em 4, otimizando o controle do fluxo e resultando em uma queda de pressão mais acentuada para esse tipo de escoamento; valores superiores a 6 começam a comprometer a eficácia do confinamento (Nikhil; Varakhedkar; Kumar, 2022). A posição simétrica do anteparo em relação ao eixo das ordenadas foi escolhida de forma a simplificar as condições de contorno e para reduzir o tempo de cálculo, uma vez que o comportamento do fluxo em uma região pode ser refletido na outra. Essa centralização do objeto no domínio também facilita a análise das interações entre o fluido e o objeto, tornando as forças e os padrões de escoamento

mais evidentes, e pode aumentar a precisão nas medições das variáveis, já que a simetria favorece uma distribuição mais equilibrada das forças sobre o objeto.

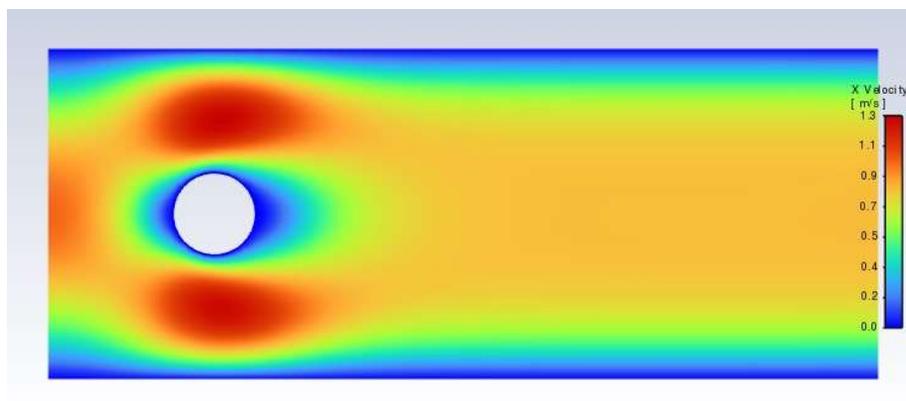
Esse processo foi fundamentado na saída de um modelo de CFD desenvolvido no ANSYS Fluent, cuja malha discretizada é apresentada da Figura 6. As Figuras 7, 8 e 9 apresentam as componentes horizontal, vertical e a magnitude total da velocidade, enquanto a Figura 10 ilustra a distribuição da pressão estática resultante. A geração de malha em CFD pode ser demorada, pois exige uma discretização cuidadosa do domínio, dependendo diretamente da densidade requerida e das configurações de refinamento. As simulações foram executadas em uma máquina com processador i7-7500U 2,7 GHz e 16 GB de memória RAM.

Figura 6 – Malha da simulação de CFD.



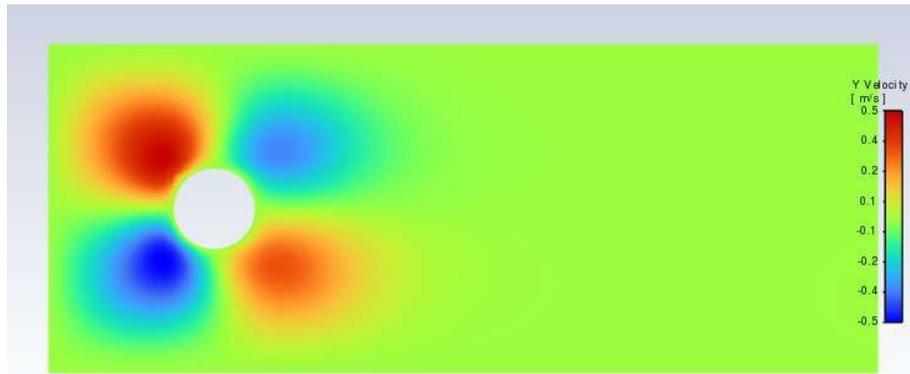
Fonte: A autora (2024).

Figura 7 – Comportamento da velocidade horizontal obtido por simulação de CFD.



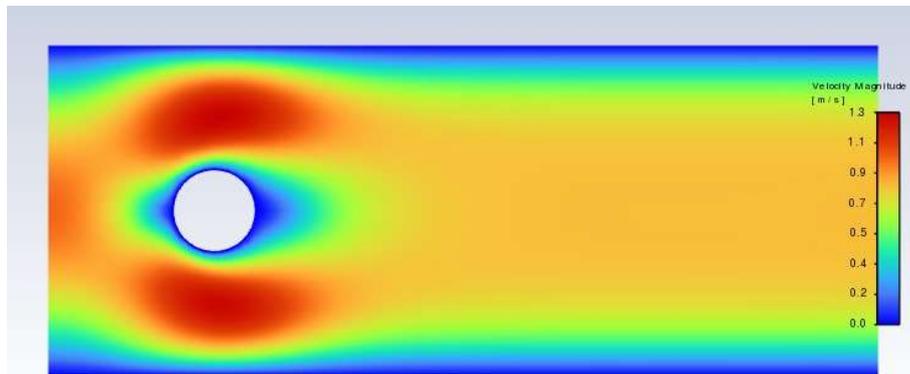
Fonte: A autora (2024).

Figura 8 – Comportamento da velocidade vertical obtido por simulação de CFD.



Fonte: A autora (2024).

Figura 9 – Comportamento da velocidade total obtido por simulação de CFD.



Fonte: A autora (2024).

Figura 10 – Distribuição de pressão estática obtida por simulação de CFD.



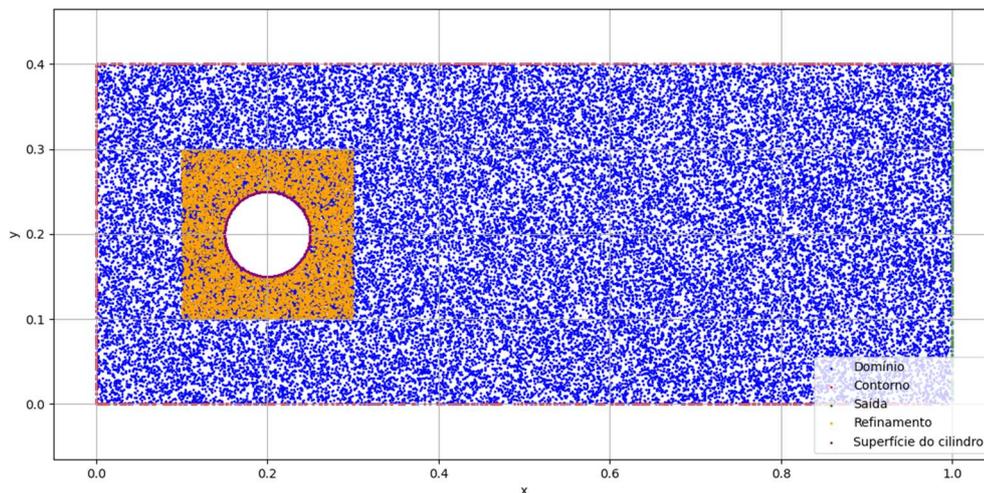
Fonte: A autora (2024).

A geometria de treinamento da PINN é idêntica à ilustrada na Figura 5, com um adendo na mudança do centro horizontal do cilindro, que pode assumir os valores 0,1;

0,2; 0,4; 0,6; e 0,8, mas mantendo a posição de simetria vertical. O treinamento foi realizado no ambiente T4-GPU do Google Colab.

Ao longo do processo de configuração da rede, inferiu-se que cerca de 40.000 pontos eram necessários para capturar adequadamente as nuances do fenômeno, com 10.000 pontos adicionais para criar a região de refinamento. Os pontos correspondentes às paredes, à superfície do cilindro e à saída foram, respectivamente, cerca de 400, 200 e 200. Testes mostraram que uma grade menos densa compromete a precisão, especialmente em torno do obstáculo, onde ocorrem mudanças rápidas de pressão. Aumentar o número de pontos não resultou em melhorias significativas. A grade computacional final aparece na Figura 11.

Figura 11 – Grade computacional da rede PINN.



Fonte: A autora (2024).

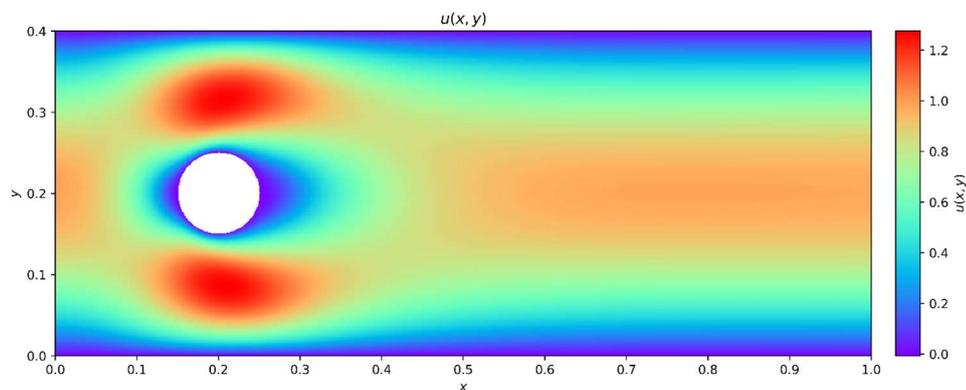
Em relação à profundidade e a largura da rede, inicialmente, optou-se pelo uso de 4 camadas ocultas, cada uma contendo 40 neurônios, aplicando transformações lineares seguidas pela função de ativação *Tanh* (tangente hiperbólica), que conseguiu retratar bem um cenário individual. Porém, tendo em vista a variação na geometria, foram necessárias 10 camadas ocultas com 40 neurônios cada para representar fielmente o escoamento em todas as posições do cilindro.

Quanto ao número de iterações, foram fixadas 10.000 iterações do otimizador Adam e foram necessárias mais 25.000 iterações do LBFGS. A partir de 20.000 iterações conjuntas, o padrão dos resultados ficou delineado, permitindo uma análise preliminar da performance do modelo; porém, essa quantidade não foi suficiente para aprender a dinâmica do escoamento, o que levou a uma subestimação das

velocidades em regiões críticas, como na região de separação em torno do obstáculo. A acurácia aumentou significativamente com as 35.000 iterações.

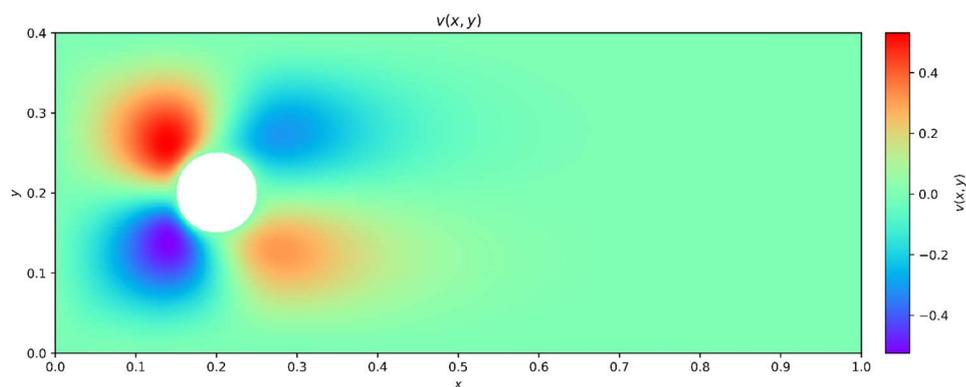
Depois do treinamento único que incorporou as cinco geometrias, foi possível obter soluções para qualquer ponto posicionado ao longo do eixo definido, respeitando as fronteiras do domínio. Para a mesma geometria simulada no ANSYS Fluent, os resultados da PINN são apresentados a seguir. Nas Figuras 12, 13 e 14, são exibidas as componentes horizontal e vertical da velocidade, seguidas do fluxo total. Na Figura 15, estão os dados da pressão estática, e na Figura 16, as linhas de fluxo da velocidade.

Figura 12 – Comportamento da velocidade horizontal obtido pela PINN.



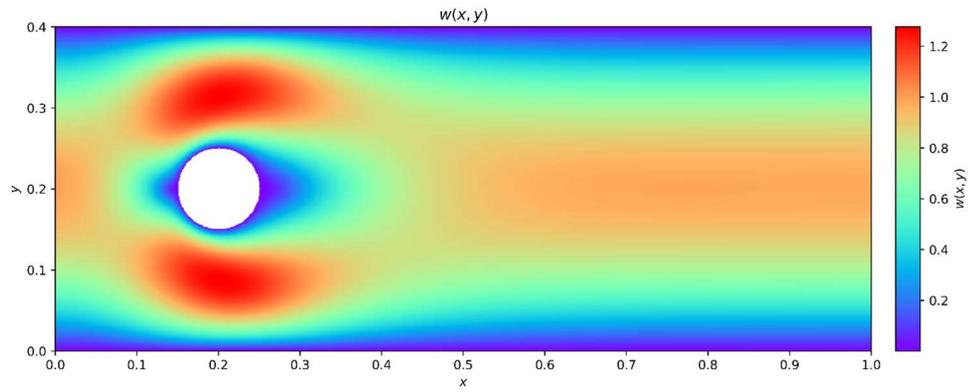
Fonte: A autora (2024).

Figura 13 – Comportamento da velocidade vertical obtido pela rede PINN.



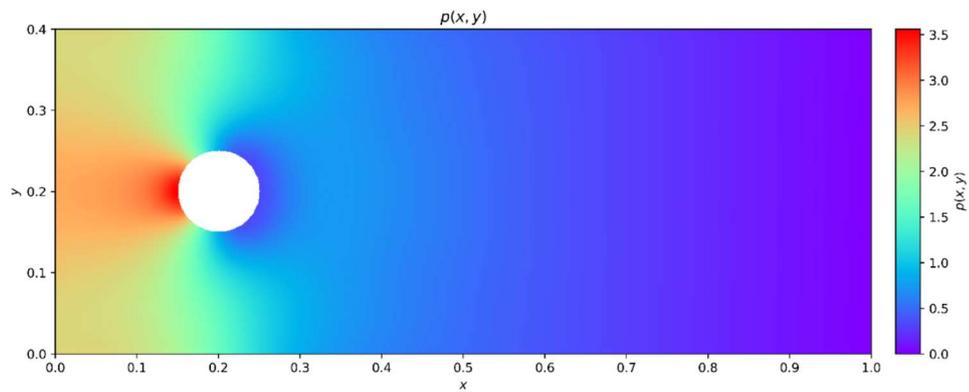
Fonte: A autora (2024).

Figura 14 – Comportamento da velocidade total obtido pela rede PINN.



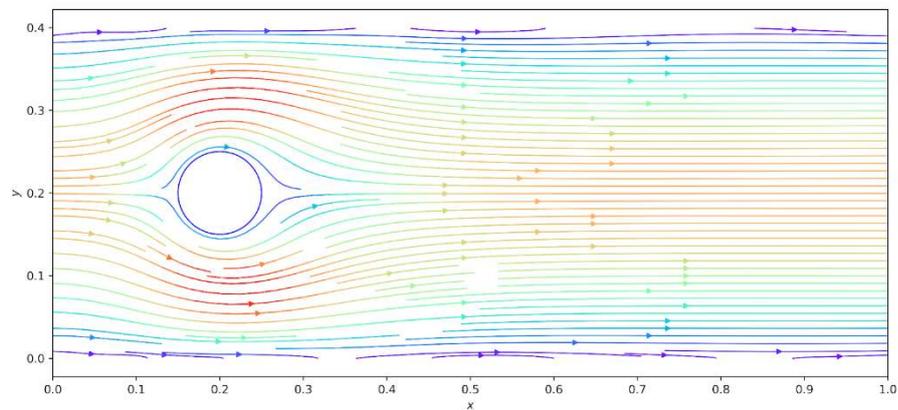
Fonte: A autora (2024).

Figura 15 – Distribuição de pressão estática obtida pela rede PINN.



Fonte: A autora (2024).

Figura 16 – Linhas de fluxo do perfil de velocidade total.

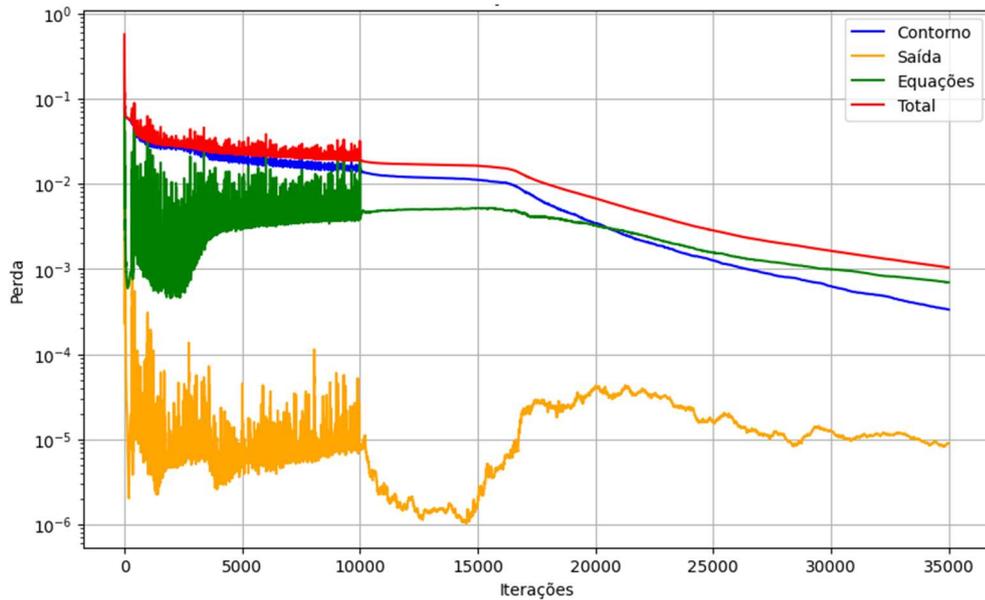


Fonte: A autora (2024).

A evolução das perdas em função do número de iterações está registrada no gráfico da Figura 17. Para as condições de contorno da velocidade, a perda final foi

de $3,330e-4$; para a saída, $9,020e-6$; e para as equações diferenciais, $6,954e-4$, totalizando uma perda de $1,03745e-3$.

Figura 17 – Gráfico de perda em função do número de iterações dos otimizadores.



Fonte: A autora (2024).

As saídas resultantes da PINN corresponderam, sim, ao fenômeno esperado fisicamente e foram equivalentes ao resultado da simulação de CFD, conseguindo representar bem a região da esteira. Para uma comparação robusta, foram selecionados pontos específicos dentro das simulações, considerando regiões críticas onde as interações do fluxo com o anteparo são mais relevantes. As áreas selecionadas incluem a zona de estagnação, localizada na parte frontal do cilindro, onde o fluxo desacelera e forma uma área de baixa velocidade; a região de separação, próxima à lateral do cilindro, onde a velocidade atingida é máxima; e a área de recirculação, situada imediatamente atrás do cilindro, onde o fluxo apresenta a maior redução na velocidade.

Com esse objetivo, foram identificados os pontos onde cada uma das saídas da rede atingiu seus valores máximos e mínimos. As respectivas coordenadas foram, então, utilizadas para extrair os valores correspondentes dos resultados da simulação no ANSYS Fluent. Esses valores são apresentados na Tabela 1.

Tabela 1 – Saídas da PINN e da simulação de CFD para as mesmas coordenadas.

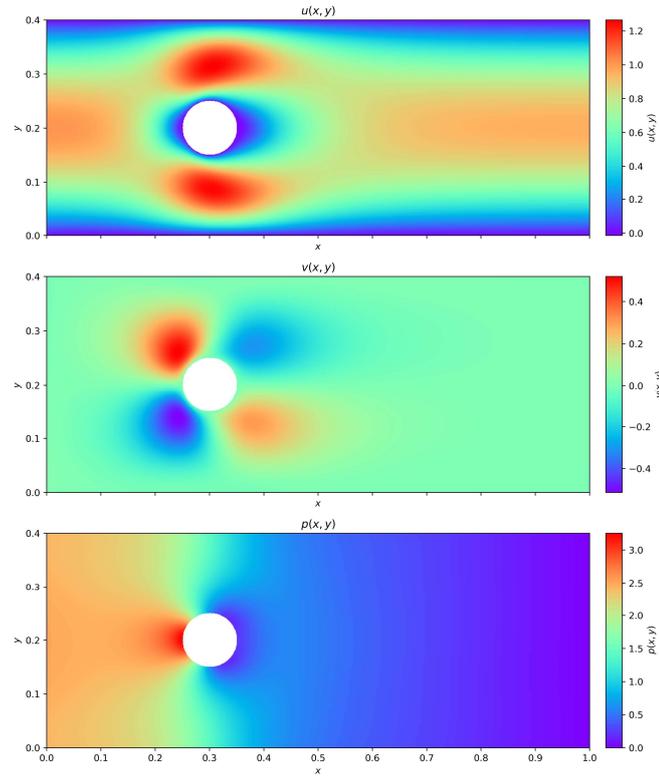
Componente		PINN	Coordenada	CFD
u	mín.	-0,01480	0,186; 0,152	0,00912
	máx.	1,26371	0,205; 0,313	1,26675
v	mín.	-0,56763	0,141; 0,139	-0,49181
	máx.	0,56301	0,141; 0,260	0,50426
p	mín.	-0,00127	0,999; 0,148	0,00136
	máx.	3,62663	0,149; 0,202	3,64806

Fonte: A autora (2024).

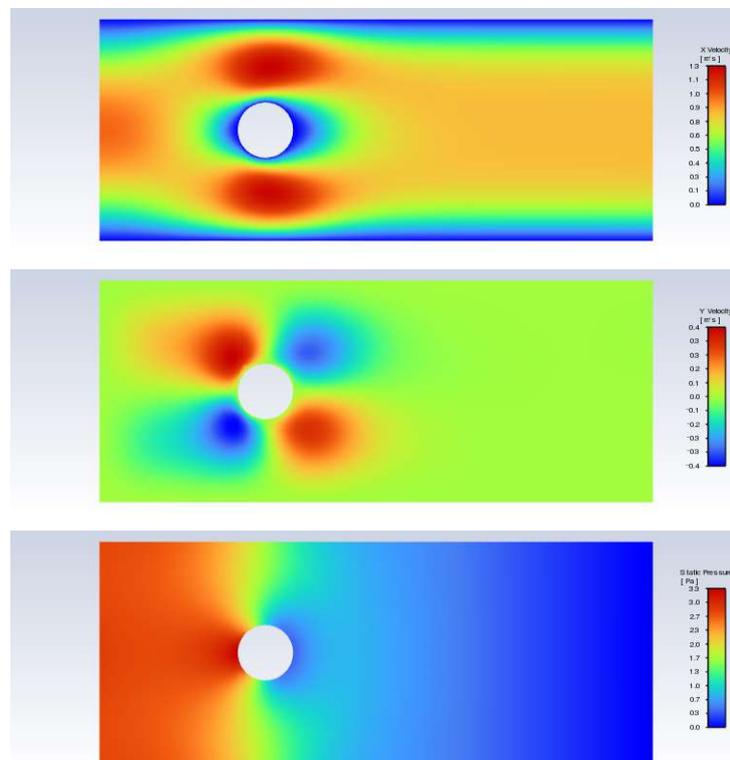
O RMSE resultou em 0,04133, demonstrando uma boa concordância entre os resultados. As variações podem ser atribuídas principalmente às diferenças inerentes às metodologias, especialmente no que diz respeito ao uso de malhas na CFD.

A rede foi treinada por 2 horas e 30 minutos, permitindo que as soluções fossem obtidas em apenas 6 segundos por condição operacional pós treinamento. Em contraste, o método tradicional de CFD levou em média 269 segundos para apresentar resultados com uma mudança de geometria, devido à necessidade de redesenho da superfície e geração de nova malha, apresentando resultados muito próximos, mas com um tempo chegando a ser 43 vezes maior. A Figura 18 traz mais uma comparação entre os resultados das duas metodologias, dessa vez, de uma posição não inserida no treinamento da rede; e a Tabela 2 exibe os resultados da PINN para algumas outras variações na geometria.

Figura 18 – Resultados da rede PINN (a) e da simulação de CFD (b).



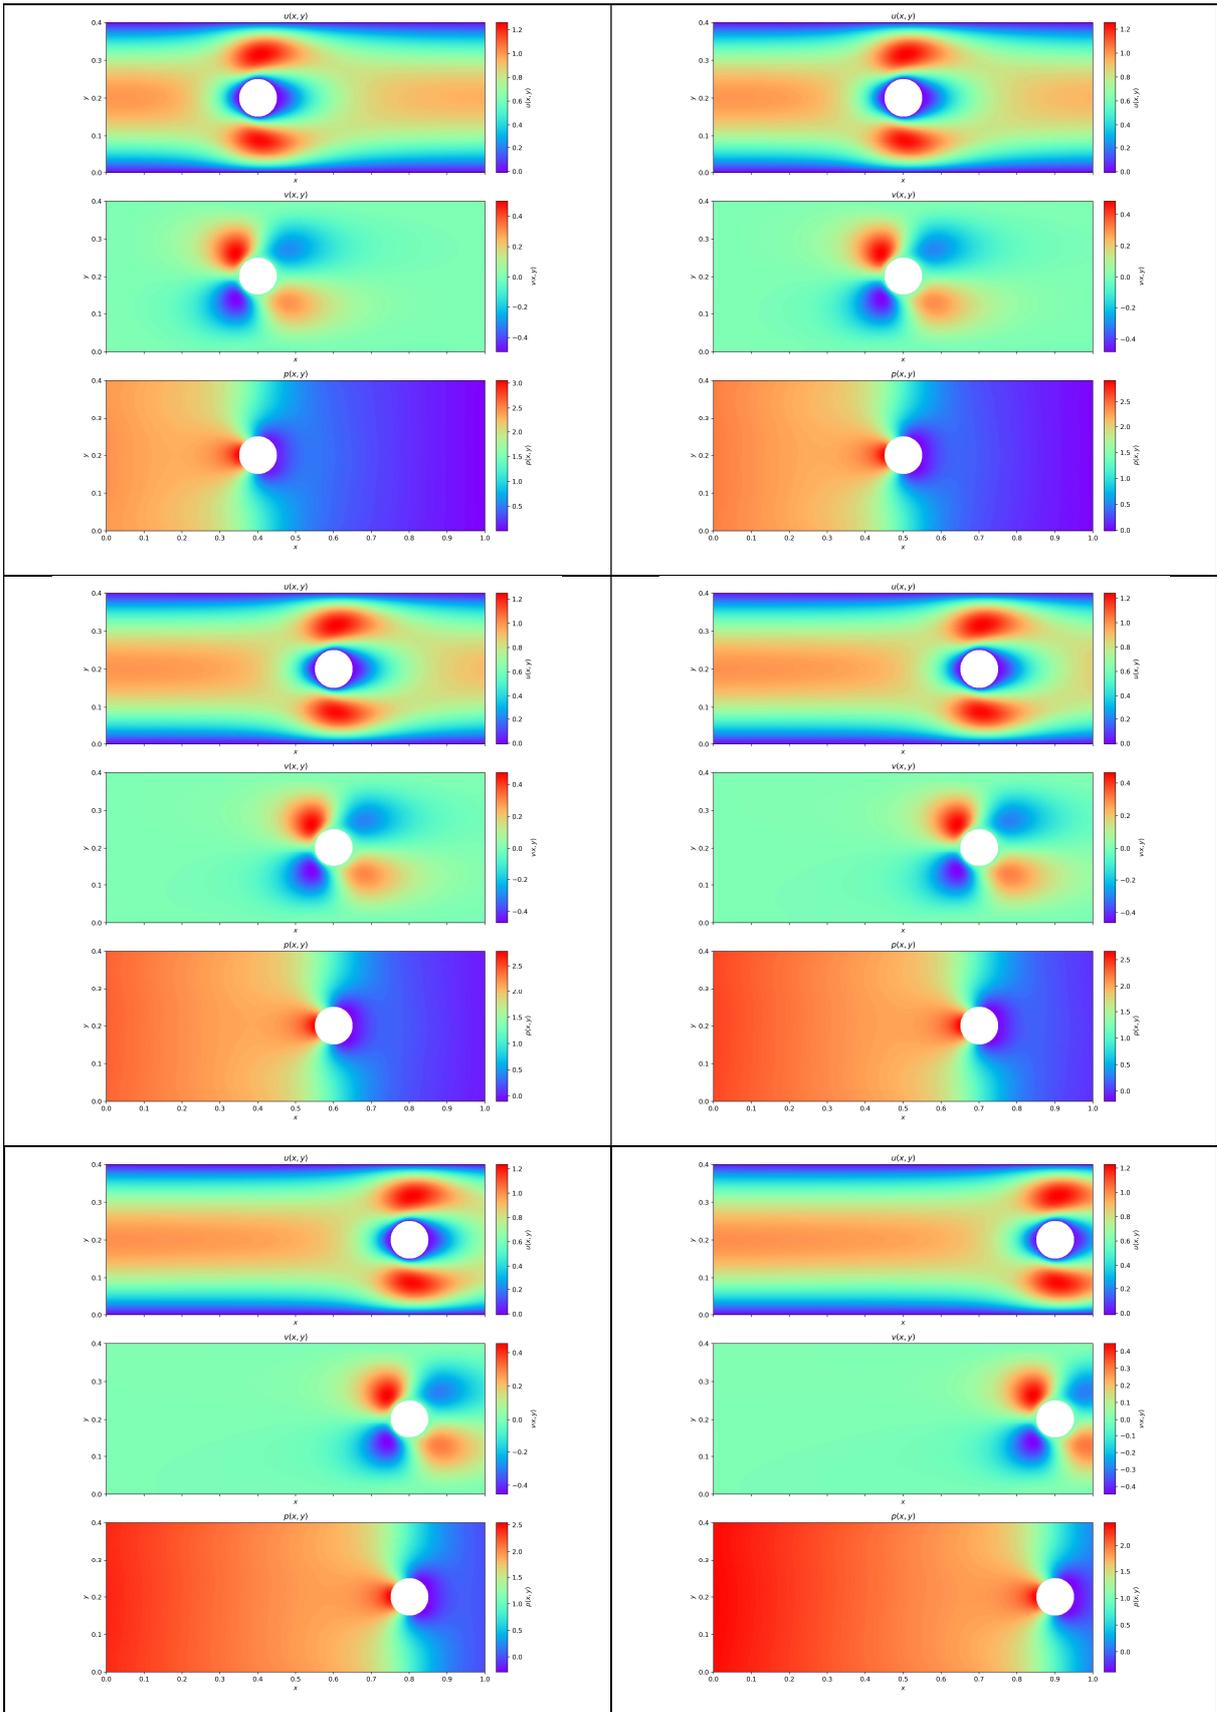
(a)



(b)

Fonte: A autora (2024).

Tabela 2 – Resultados da rede PINN para diferentes geometrias.



Fonte: A autora (2024).

6 CONCLUSÕES

Este trabalho consistiu na simulação do escoamento bidimensional do ar ao redor de um anteparo intransponível, utilizando uma rede neural do tipo *Physics-informed Neural Network*, analisando a interação do ar com a estrutura e os padrões de velocidade e pressão resultantes formados na esteira de um fluxo laminar incompressível. Os resultados obtidos mostraram-se satisfatórios, refletindo comportamentos consistentes com os esperados fisicamente.

A abordagem das PINNs evidencia uma série de vantagens significativas associadas ao seu uso. Mesmo que o treinamento seja um processo demorado, um dos seus principais diferenciais acaba sendo a eficiência em lidar com novas condições uma vez que o modelo esteja estabelecido — partindo de poucas configurações treinadas, é capaz de prever dezenas de situações diferentes sem a necessidade de redesenho, geração de malhas ou reanálises. A rapidez na obtenção dos resultados favorece sua adoção na aplicação proposta.

Para trabalhos futuros, sugere-se explorar a modelagem de geometrias mais complexas para obtenção de uma representação mais precisa de um rotor aerodinâmico de um aerogerador, juntamente com a investigação da dinâmica de fluxos turbulentos. Isso permitirá analisar como um anteparo posicionado à montante captura mais energia cinética do vento, culminando em uma geração de energia elétrica mais eficiente, enquanto um anteparo à sotavento enfrenta um fluxo menos eficiente devido à dissipação de energia e à formação de vórtices gerados pela interação com o primeiro. A inclusão de dados reais como entrada no modelo e testes com outras bibliotecas de otimizadores de hiperparâmetros, como Optuna e Ray Tune, podem aprimorar ainda mais as simulações. Por fim, a aplicação das simulações em diferentes cenários de vento também representa uma evolução interessante para a pesquisa.

REFERÊNCIAS

- ARCHER, Cristina L.; JACOBSON, Mark Z. Supplying baseload power and reducing transmission requirements by interconnecting wind farms. **Journal of applied meteorology and climatology**, v. 46, n. 11, p. 1701-1717, 2007.
- CAI, Shengze et al. Physics-informed neural networks (PINNs) for fluid mechanics: A review. **Acta Mechanica Sinica**, v. 37, n. 12, p. 1727-1738, 2021.
- COBELLI, P. et al. Physics informed neural networks for wind field modeling in wind farms. **Journal of Physics: Conference Series**, v. 2505, p. 012051, 2023. Apresentado na Wake Conference 2023.
- COUNCIL–GWEC, Global Wind Energy. Global wind report 2023. **GWEC**, Brussels, 2023.
- DHERT, Tristan; ASHURI, Turaj; MARTINS, Joaquim RRA. Aerodynamic shape optimization of wind turbine blades using a Reynolds-averaged Navier–Stokes model and an adjoint method. **Wind Energy**, v. 20, n. 5, p. 909-926, 2017.
- DHUNNY, A. Z.; LOLLCHUND, M. R.; RUGHOOPUTH, S. D. D. V. Wind energy evaluation for a highly complex terrain using Computational Fluid Dynamics (CFD). **Renewable Energy**, v. 101, p. 1-9, 2017.
- GOODFELLOW, I. Deep Learning. I. Goodfellow, Y. Bengio, A. Courville. 2016.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. Summary for Policymakers. In: Climate Change 2023: Synthesis Report. Core Writing Team: H. Lee and J. Romero (eds.). **IPCC**, Geneva, Switzerland, 2023. p. 1-34. Disponível em: <https://www.ipcc.ch/report/ar6/syr/downloads/report/IPCC_AR6_SYR_SPM.pdf>. Acesso em: set. 2024.
- INTERNATIONAL ENERGY AGENCY. World Energy Outlook 2023. **IEA** [S.l.: s.n.], 2023. Disponível em: <<https://iea.blob.core.windows.net/assets/86ede39e-4436-42d7-ba2a-edf61467e070/WorldEnergyOutlook2023.pdf>>. Acesso em: set. 2024.
- JIMÉNEZ, Ángel; CRESPO, Antonio; MIGOYA, Emilio. Application of a LES technique to characterize the wake deflection of a wind turbine in yaw. **Wind energy**, v. 13, n. 6, p. 559-572, 2010.
- JIN, Xiaowei et al. NSFnets (Navier-Stokes flow nets): Physics-informed neural networks for the incompressible Navier-Stokes equations. **Journal of Computational Physics**, v. 426, p. 109951, 2021.
- NIKHIL, T. S.; VARAKHEDKAR, Amit; KUMAR, Rajendran Senthil. Flow confinement effect and heat transfer around square cylinder with downstream control cylinders. **Journal of Thermal Analysis and Calorimetry**, v. 147, n. 2, p. 1699-1709, 2022.

PORTÉ-AGEL, Fernando; BASTANKHAH, Majid; SHAMSODDIN, Sina. Wind-turbine and wind-farm flows: a review. **Boundary-layer meteorology**, v. 174, n. 1, p. 1-59, 2020.

RAISSI, Maziar; PERDIKARIS, Paris; KARNIADAKIS, George E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. **Journal of Computational physics**, v. 378, p. 686-707, 2019.

RAO, Chengping; SUN, Hao; LIU, Yang. Physics-informed deep learning for incompressible laminar flows. **Theoretical and Applied Mechanics Letters**, v. 10, n. 3, p. 207-212, 2020.

RAO, Chengping; SUN, Hao; LIU, Yang. Physics-informed deep learning for computational elastodynamics without labeled data. **Journal of Engineering Mechanics**, v. 147, n. 8, p. 04021043, 2021.

SHAO, Xuqiang et al. PIGNN-CFD: A physics-informed graph neural network for rapid predicting urban wind field defined on unstructured mesh. **Building and Environment**, v. 232, p. 110056, 2023.

SIRIGNANO, Justin; SPILIOPOULOS, Konstantinos. DGM: A deep learning algorithm for solving partial differential equations. **Journal of computational physics**, v. 375, p. 1339-1364, 2018.

SOHANKAR, Ahmad; NORBERGB, C.; DAVIDSON, Lars. Numerical simulation of unsteady low-Reynolds number flow around rectangular cylinders at incidence. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 69, p. 189-201, 1997.

SUN, Luning et al. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data. **Computer Methods in Applied Mechanics and Engineering**, v. 361, p. 112732, 2020.

VALÉRY, Paul. **Le cimetière marin**. 1920.

VEERS, Paul et al. Grand challenges in the science of wind energy. **Science**, v. 366, n. 6464, p. eaau2027, 2019.

WANG, Tongsheng et al. Reconstruction of natural convection within an enclosure using deep neural network. **International Journal of Heat and Mass Transfer**, v. 164, p. 120626, 2021.

WHITE, F. M. *Fluid Mechanics*. [S.l.]: McGraw-Hill Education, 2011.

ZEHTABIYAN-REZAIE, Navid; IOSIFIDIS, Alexandros; ABKAR, Mahdi. Data-driven fluid mechanics of wind farms: A review. **Journal of Renewable and Sustainable Energy**, v. 14, n. 3, 2022.

ZHANG, Jincheng; ZHAO, Xiaowei. Three-dimensional spatiotemporal wind field reconstruction based on physics-informed deep learning. **Applied Energy**, v. 300, p. 117390, 2021.

ZHU, Yinhao et al. Physics-constrained deep learning for high-dimensional surrogate modeling and uncertainty quantification without labeled data. **Journal of Computational Physics**, v. 394, p. 56-81, 2019.