

## OTIMIZAÇÃO DE PROCESSOS FLUIDODINÂMICOS: INTEGRAÇÃO DO COMPUTATIONAL FLUID DYNAMICS COM MACHINE LEARNING E META-HEURÍSTICA

Matheus Costa Pereira<sup>a</sup>, Tiago Martins de Azevedo<sup>a</sup>, Matheus Brendon Francisco<sup>a</sup>,  
Anderson Paulo de Paiva<sup>a</sup>

<sup>a</sup>Universidade Federal de Itajubá

Av. BPS, 1303, Pinheirinho, Itajubá, Minas Gerais, Brasil  
matheusc\_pereira@hotmail.com, tiago.deazevedo@yahoo.com.br,  
matheus\_brendon@unifei.edu.br, andersonppaiva@unifei.edu.br

### RESUMO

O *Computational Fluid Dynamics* (CFD) é uma ferramenta essencial para análise computacional de fluidos e suas interações com superfícies sólidas. Apesar de oferecer vantagens como a redução de custos de fabricação, flexibilidade e integração tecnológica, enfrenta desafios, como a necessidade de profissionais experientes e longos tempos de simulação. A integração com *Machine Learning* (ML) e meta-heurísticas (MH) oferece soluções avançadas para resolver esses desafios. O ML, ao compreender os problemas, gera modelos para previsão de resultados, enquanto as MH encontram valores ótimos de saída com a melhor configuração dos parâmetros de entrada. Essa integração, observada em diversos estudos, proporciona soluções eficazes e confiáveis. Alinhando-se aos princípios da Indústria 4.0, promove-se a transformação digital, automação e customização nos processos industriais. O método proposto, aplicado em um estudo de caso de um ventilador centrífugo industrial, apresenta resultados eficientes, promovendo uma abordagem inteligente e adaptável para lidar com desafios complexos na indústria.

**PALAVRAS CHAVE.** Aprendizado de Máquina. Meta-heurística. Fluidodinâmica Computacional.

**Tópicos. Metodologia.** Aplicação de algoritmos de Machine Learning. Otimização com meta-heurística Indústria. Validação dos resultados com o Computational Fluid Dynamics.

### ABSTRACT

Computational Fluid Dynamics (CFD) is an essential tool for the computational analysis of fluids and their interactions with solid surfaces. Despite offering advantages such as reduced manufacturing costs, flexibility, and technological integration, it faces challenges such as the need for experienced professionals and long simulation times. The integration with Machine Learning (ML) and meta-heuristics (MH) provides advanced solutions to address these challenges. ML, by understanding the problems, generates models for predicting results, while MH finds optimal output values with the best configuration of input parameters. This integration, observed in various studies, provides effective and reliable solutions. Aligning with the principles of Industry 4.0, it promotes digital transformation, automation, and customization in industrial processes. The proposed method, applied in a case study of an industrial centrifugal fan, presents efficient results, promoting an intelligent and adaptable approach to dealing with complex challenges in the industry.

**KEYWORDS.** Machine Learning. Meta-heuristic. Computational Fluid Dynamics.

**Paper topics.** Methodology Application of Machine Learning algorithms. Optimization with meta-heuristics. Industry 4.0. Validation of results with Computational Fluid Dynamics.

## 1. Introdução

O *Computational Fluid Dynamics* (CFD) é uma ferramenta crucial na análise numérica e computacional do comportamento de fluidos, como líquidos e gases, e suas interações com superfícies sólidas. Por meio de métodos matemáticos e computacionais, é possível simular o comportamento desses fluidos em uma variedade de situações e condições. O uso do CFD traz diversas vantagens, principalmente pela redução da necessidade de construir protótipos físicos, o que resulta em uma diminuição significativa no tempo e nos custos de fabricação [Gerold Fink et al. 2021].

No entanto, trabalhar com CFD também apresenta várias dificuldades práticas. A principal delas é a necessidade de profissionais experientes que possuam conhecimento tanto na teoria dos fluidos quanto na compreensão dos modelos numéricos [Khankari, 2021]. Além disso, o tempo de simulação representa uma limitação significativa [Gerold Fink et al. 2021; Nordvik et al, 2019] e, especialmente em projetos que exigem respostas rápidas, tornando difícil realizar múltiplas simulações em tempo hábil, ou em projetos com condições de contorno complexas (Shen et al. 2020). A disponibilidade de recursos computacionais, como licenças de software, e o alto custo computacional em relação às unidades centrais de processamento (CPU) e unidades de processamento gráfico (GPU), também podem representar desafios [Kochkov et al. 2021; Mahian et al. 2019]. A interpretação e análise dos resultados também demandam compreensão das tendências e dos dados obtidos.

Diante desses desafios, o uso de modelos de *Machine Learning* (ML) desempenha um papel importante. Esses algoritmos aprendem a reconhecer padrões e fazer previsões com base em dados, possibilitando uma compreensão mais profunda dos problemas enfrentados no CFD, como o tempo de simulação, a definição das variáveis de entrada e a previsão de resultados. Além disso, a aplicação de meta-heurísticas (MH), uma abordagem relacionada à otimização computacional, também é valiosa. As MH exploram soluções em um espaço de busca de forma iterativa, visando encontrar as condições ótimas de maneira eficiente. Esse método permite lidar com problemas complexos e de grande escala e evita cair em ótimos locais, o que permite encontrar resultados satisfatórios e resulta em soluções robustas.

A combinação do ML com CFD ou da MH com o CFD pode ser vista em múltiplos trabalhos, tais como Nabipour et al. [2020], que combinam o uso de ML com CFD para reduzir o tempo computacional no campo de nanofluidos para prever o fluxo e a distribuição térmica White et al. [2020] utilizam redes neurais artificiais (ANN) para avaliar problemas aerodinâmicos com o objetivo de aproximar modelos CFD com o uso de modelos de ML. Fukami et al. [2019] usam redes neurais convolucionais (CNN) e modelos híbridos de conexão com salto reduzido/multi-escala (DSC/MS) para realizar a análise em relação a dados de fluxo turbulento para reconstruir o campo de fluxo de alta resolução. Kochkov et al. [2021] utilizam aprendizagem profunda para auxiliar na aproximação no CFD em relação a modelagem de modelos com fluxos turbulentos. Zhu et al. [2019] trabalham com rede neural (AN) para avaliar modelos de ML para baixo número de Reynolds e alto número de Reynolds em relação a aerofólio para avaliação de fluxos. Ti et al. [2020] empregam a ANN para comparar resultados de simulações numéricas, dados de medição e dados previstos em relação à precisão de vórtices de turbinas eólicas. Cheng et al. [2022] realizam otimizações de turbinas eólicas com o uso de técnicas de ML e modelos de otimização com uso de MH e verificação da precisão dos resultados com o CFD. Mehrnia et al. [2020] verificam o desempenho de uma turbina de fluxo radial com o uso do acoplamento de MH no CFD. Rastgoo e Khajavi [2023] avaliam previsões utilizando algoritmos de ML e avaliam diversos MH buscando o que possua um resultado melhor em cada uma das métricas para otimização de projeto de aerofólios de aeronaves. Menéndez-Pérez et al. [2022] usam o ML para otimizar o comportamento termo-hidráulico de um trocador de calor, e sua otimização é realizada com algoritmos genéticos para melhorar a geometria, buscando aumentar a transferência de calor por convecção e avaliar a perda de pressão e o escoamento.

A combinação dessas técnicas (CFD, ML e MH) resulta em soluções eficazes para superar os desafios iniciais mencionados, proporcionando diversas vantagens para os engenheiros e profissionais envolvidos. Essa integração demonstra uma abordagem em sintonia com os

princípios da Indústria 4.0 e proporciona soluções eficazes para os desafios enfrentados na análise e otimização de sistemas complexos, impulsionando a adoção da transformação digital e da automação inteligente nos processos industriais.

Para aplicar o método proposto, utiliza-se um estudo de caso envolvendo um ventilador centrífugo industrial que opera em condições de alta temperatura. A experimentação com o CFD foi realizada utilizando o *software* Ansys Fluent, que desempenha um papel essencial no processo de design e análise digital de resultados, interagindo com os aspectos da produção. Além de ter a capacidade de realizar uma personalização flexível e otimizar processos fabris [Silvestri 2021].

Após a realização de diversos experimentos e a obtenção dos resultados, são empregados algoritmos de ML para compreender o modelo e avaliar sua capacidade de previsão, visando reduzir simulações futuras e compreender melhor o comportamento do modelo. Após a realização de diversos experimentos e a obtenção dos resultados, empregam-se algoritmos de ML para compreender o modelo e avaliar sua capacidade preditiva. Isso visa reduzir o número de simulações futuras e proporcionar uma melhor compreensão do comportamento do modelo. A função objetivo do problema a ser resolvido é constituída pelo modelo O ML é responsável por compreender problemas e prever resultados, sendo fundamental para a customização e personalização dos processos de produção, a fim de atender às expectativas dos clientes ou automatizar configurações para a fabricação de produtos.

Por fim, utilizam-se algoritmos de MH para otimizar os parâmetros de entrada, com o objetivo de maximizar o desempenho do ventilador centrífugo industrial em estudo. Esse processo está diretamente relacionado à automação, visando aumentar a eficiência e a produtividade por meio de uma abordagem automatizada nos processos industriais

## 2. Metodologia

Inicialmente, é importante ter as variáveis de entrada e de saída bem definidas para que a os parâmetros de entrada não sejam utilizados de forma aleatória para cada um dos experimentos, o que geraria uma confusão tanto no modelo quanto na análise e na otimização. Neste artigo, foram utilizados diversos *softwares* da Ansys. O Workbench foi utilizado para a configuração e escopo do projeto, o SpaceClaim foi usado para a construção e definição da geometria, o Fluent para a malha, o *setup* e a solução, o Discovery para uma análise rápida e prévia dos resultados, e o CFD-Post para a plotagem de gráficos e análise dos resultados.

Após a etapa inicial, são realizadas inúmeras simulações no Ansys, em que o modelo geométrico é construído, configurado e analisado e armazenando os resultados obtidos com o uso do CFD. Recomenda-se que para explorar o espaço de possíveis configurações que seja utilizado um planejamento de experimentos (DOE) para que as configurações não sejam projetadas sem base alguma, e isso permite a realização dos experimentos de forma sistemática.

O passo seguinte trata da preparação dos dados e treinamento de modelos, em que se utilizam três modelos de ML para treinar os dados em relação a cada uma das funções-objetivo. Nesta etapa, um percentual da amostra é separado para teste.

Em seguida, é realizada a avaliação dos modelos, em que são avaliadas as métricas de cada um deles para verificar sua precisão em realizar previsões e avaliar o que é explicado do modelo, verificando se há ajuste e também as diferenças dos resultados previstos pelo modelo em relação aos valores reais. Com isso, torna-se importante realizar a verificação das variáveis que possuem significância em relação ao modelo. Se alguma variável não tiver importância em relação ao modelo, esta, por sua vez, pode ser retirada.

Posteriormente, realiza-se o *Ensemble Learning* (EL), que combina inúmeros modelos de previsão com o intuito de produzir um novo que possua um melhor desempenho e que seja mais robusto do que modelos individuais, o que gera uma melhor precisão e generalização para a realização de previsões. Também é realizada a otimização de hiperparâmetros, que busca maximizar o desempenho do modelo e evitar *overfitting* ou *underfitting*, encontrando uma configuração mais adequada do que a inicial para aumentar a performance do modelo. A integração de otimização e ML destaca a capacidade de processar e analisar grandes volumes de dados para melhorias contínuas, representando um dos pilares da Indústria 4.0.

Na sequência são realizadas as previsões com esse algoritmo e comparam-se os resultados encontrados com os métodos individuais e com eles combinados, a fim de verificar a forma mais adequada para a função objetivo em questão. Com isso, realiza-se a otimização com MH de cada uma das funções com o intuito de encontrar o melhor parâmetro de entrada, ou seja, o parâmetro ótimo em relação ao modelo encontrado.

Por fim, é realizada a verificação do resultado obtido com o ML seguido do MH. As configurações para a geometria encontrada são reproduzidas no software Ansys e os resultados são coletados a fim de verificar e confirmar a eficiência da metodologia utilizada.

Essa metodologia demonstrou melhorias significativas no desempenho de sistemas de engenharia complexos. Ao empregar essas tecnologias avançadas, o projeto exemplifica a transformação digital e a automação inteligente promovidas pela Indústria 4.0, proporcionando uma abordagem adaptável para diversas aplicações industriais e fomentando uma produção mais eficiente e inovadora.

### 3. Exemplificação do método: Estudo de caso de um ventilador centrífugo industrial

O estudo de caso deste projeto trata da otimização do desempenho de um ventilador com o uso da abordagem integrada que envolve simulação computacional, modelagem preditiva com ML e técnicas de otimização MH, alinhando-se com princípios a Indústria 4.0. Essa integração proporciona uma análise digital detalhada e precisa.

Para explorar e exemplificar os benefícios do método aplicado, foi realizado um estudo de caso de um ventilador centrífugo responsável pela recirculação de ar em ambientes de altas temperaturas. Alguns parâmetros permanecem fixos, tal como espessura que é de 0,80 mm e a largura das pás que é de 44,60 mm seguindo previamente um padrão empresarial. A velocidade angular (rotação) do ventilador é de 5500 rpm. Ele é construído com AISI 430, cujas propriedades incluem uma densidade de  $7,80 \cdot 10^{-3} \text{ g/mm}^3$ , módulo de elasticidade de  $2,00 \cdot 10^{11} \text{ Pa}$ , módulo de cisalhamento de  $7,70 \cdot 10^9 \text{ Pa}$ , coeficiente de Poisson de 0,27 e calor específico de  $0,46 \text{ J/kg}^\circ\text{C}$ . O experimento é conduzido considerando diferentes configurações de pás, sendo as variáveis de controle a quantidade ( $x_1$ ), ângulo de entrada ( $x_2$ ), ângulo de saída ( $x_3$ ) e comprimento ( $x_4$ ). As variáveis independentes analisadas e otimizadas são a vazão mássica ( $Y_1$ ) e o torque ( $Y_2$ ). As iterações são conduzidas até que a convergência seja atingida, levando em conta critérios como velocidade em três eixos, equação de continuidade,  $k$  e  $\omega$ , além de critérios de qualidade da malha, como uma qualidade ortogonal das malhas acima de 0,15 e uma distorção abaixo de 0,95. Foram testadas diversas configurações diferentes, respeitando o espaço experimental definido por um *Central Composite Design* (CCD) com pontos fatoriais, axiais e centrais.

As variáveis de respostas são dadas por:

- Vazão mássica na saída (MFR): explicada pela taxa de fluxo de massa do fluido que passa pela seção transversal em um período de tempo unitário, ou seja, o ar movido pelo ventilador. Ela é medida em kg/s e pode ser calculada como:

$$\text{MFR} = \int \rho \mathbf{v} \cdot d\mathbf{A} = \sum_{i=1}^n \rho_i \mathbf{v}_i \mathbf{A}_i \quad (1)$$

Onde:  $\rho$  é a densidade do fluido,  $\mathbf{v}$  é a velocidade do fluido e  $d\mathbf{A}$  é o elemento de área.

- Torque requerido: é dada pela quantidade de força rotacional necessária para que as pás do ventilador girem. Expressa em Nm e calculada como:

$$\mathbf{T} = \mathbf{r}_{AB} \mathbf{F}_P + \mathbf{r}_{AB} \mathbf{F}_V \quad (2)$$

Onde:  $\mathbf{A}$  é o centro de momento específico,  $\mathbf{B}$  é a origem da força,  $\mathbf{r}_{AB}$  é o vetor de torque,  $\mathbf{F}_P$  é o vetor de força de pressão e  $\mathbf{F}_V$  é o vetor de força viscosa.

Ressalta-se que as variáveis possuem uma correlação forte e positiva de 0,88. No entanto, os objetivos de otimização dessas variáveis são opostos, pois busca-se maximizar a vazão enquanto se minimiza o torque.

### 3.1. Dados experimentais

Com base na explicação das variáveis dada anteriormente, a Tabela 1 descreve as variáveis em relação aos seus níveis experimentais, unidades de medida, abreviações e níveis experimentais, com o objetivo de mostrar tanto as variáveis codificadas quanto as decodificadas. A variável  $x_1$  é um número inteiro, enquanto  $x_2$ ,  $x_3$  e  $x_4$  são variáveis que serão tratadas com duas casas decimais.

Tabela 1: Variáveis de controle

| $x_n$ | Variável                 | Unidade    | -2    | -1    | 0     | +1    | +2     |
|-------|--------------------------|------------|-------|-------|-------|-------|--------|
| $x_1$ | Número de pás            | Quantidade | -     | 6     | 10    | 14    | 18     |
| $x_2$ | Ângulo da entrada da pá  | Graus      | -15,0 | 0,00  | 15,00 | 30,00 | 45,00  |
| $x_3$ | Ângulo de abertura da pá | Graus      | -45,0 | 0,00  | 45,00 | 90,00 | 135,00 |
| $x_4$ | Comprimento da pá        | Milímetros | 19,0  | 26,00 | 33,00 | 40,00 | 47,00  |

Os gráficos de contorno mostram como a resposta varia em relação às variáveis de entrada. Eles nos permitem visualizar o comportamento da variável em relação a diferentes combinações dessas variáveis, o que auxilia na interpretação dos possíveis resultados. Na Figura 1, é possível ver esse gráfico, que pode ser plotado após algumas simulações para examinar o comportamento da MFR e do T.




Figura 1: Gráfico de contorno em relação a vazão e torque

A Figura 2 apresenta um modelo do ventilador representado pelo ponto central, onde os parâmetros são codificados:  $x_1$  até  $x_4$  representam 0, indicando um ventilador com 10 pás, um ângulo de entrada de 15°, um ângulo de abertura de 45° e pás medindo 33 mm. Essa representação visual nos permite ter uma visão clara da configuração do ventilador em seu ponto central.




Figura 2: Geometria do ventilador do experimento 10

Esse modelo específico ilustrado na Figura 2 possui uma MFR de 0,270 kg/s e um T de 3,358 Nm. Essas medidas estão naturalmente correlacionadas, o que significa que não é possível aumentar a MFR sem afetar o T, e vice-versa. Isso evidencia a necessidade de um equilíbrio entre essas variáveis, conhecido como *trade-off*, onde decisões sobre uma afetam diretamente a outra.

### 3.2. Resultados com o Computational Fluid Dynamics

Para continuar a análise do modelo mencionado, considera-se o ponto central discutido na 3.1 como exemplo. As trajetórias do fluido, conhecidas como *pathlines*, são apresentadas em relação a um plano central definido na área de atuação do ventilador. Isso permite observar como o fluido se desloca dentro do domínio. Além disso, é ilustrado um gráfico de contorno em relação a variação da magnitude da velocidade do fluido em toda a região do domínio, expressa em metros por segundo (m/s). Por fim, é exibido um gráfico de contorno relacionado com a distribuição da pressão total, que corresponde à soma da pressão estática e da pressão dinâmica, também representada no domínio do fluido em pascal (Pa). Tanto a velocidade quanto a pressão têm implicações nos resultados discutidos neste artigo, refletindo o comportamento do fluxo de fluido no sistema em estudo. Tais representações estão expressas na Figura 3.




Figura 3: Linhas de trajetória e gráficos de contorno do experimento 10

Observar os contornos e as trajetórias das linhas contribui para identificar zonas de recirculação e padrões de fluxo. Por meio de uma avaliação visual, torna-se possível analisar os resultados de cada modelo e comparar as diferenças entre as diferentes configurações de geometria. Essa análise visual facilita a tomada de decisão, permitindo compreender como as mudanças na geometria do sistema afetam o comportamento do fluxo de fluido.

### 3.3. Aplicação de algoritmos de Machine Learning

Após a obtenção de uma variedade de resultados experimentais, é aplicada a etapa de implementação de algoritmos de ML, os quais têm como objetivo abordar duas funções-objetivo: a MFR e o T. Inicialmente, procede-se à divisão do conjunto de dados em conjuntos de teste e treinamento, onde 80% dos dados são aleatoriamente distribuídos para treinamento, garantindo a replicabilidade dos resultados, enquanto os restantes 20% são reservados para teste.

Na sequência, ocorre o treinamento dos diferentes modelos, onde é estabelecida uma grade de hiperparâmetros com diversos estimadores e uma profundidade máxima padrão. Utiliza-se então o *GridSearch*, uma técnica que otimiza os hiperparâmetros de um modelo, treinando todas as combinações possíveis e avaliando o desempenho em relação a uma métrica, o que contribui para a otimização dos resultados.

Os três algoritmos utilizados são: *Decision Tree* (DT), que divide o espaço de entrada em regiões retangulares e atribui uma saída a cada uma delas de forma recursiva; Regressão Polinomial (RP), que modela a variável dependente em relação ao grau do polinômio; e *Random Forest* (RF), um conjunto de DT treinados em diferentes subconjuntos, onde as previsões são combinadas para alcançar um resultado final.

Cada algoritmo apresenta suas vantagens e desvantagens. Nesse contexto, emprega-se o Ensemble Learning (EL), que combina múltiplos modelos para obter uma previsão mais precisa e

robusta. Vale destacar que o RF é um exemplo de EL, e a combinação de modelos resulta em previsões mais precisas.

Posteriormente, realiza-se o cálculo da importância das variáveis, identificando aquelas significativas para a MFR e o T. As variáveis com importância menor que 5,00% são descartadas do modelo de previsão. Na avaliação da MFR, o número de pás se destaca com 73,49% de importância, enquanto o comprimento de pás possui apenas 6,08%. Para o T, as mesmas variáveis também apresentam resultados semelhantes, com o número de pás representando 67,49% de importância e o comprimento de pás, 2,85%.

Para avaliar a precisão das previsões, são utilizadas várias métricas, incluindo o R-quadrado ( $R^2$ ), o *Mean Squared Error* (MSE), o *Root Mean Squared Error* (RMSE) e o *Mean Absolute Error* (MAE). A formulação de cada uma dessas métricas é dada da Eq. (3) até a Eq. (6).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

Onde:  $y_i$  são os valores observados,  $\hat{y}_i$  são os valores preditos pelo modelo,  $\bar{y}_i$  é a média dos valores observados e  $n$  representa o número de observações.

Cada métrica fornece uma medida diferente da qualidade do modelo de previsão. Os valores correspondentes para cada algoritmo em relação às duas funções-objetivo, MFR (Y1) é apresentado na Tabela 2 e T (Y2) na Tabela 3.

Tabela 2: Métricas do modelo para a vazão

|       | DT     | RP     | RF     | EL     |
|-------|--------|--------|--------|--------|
| $R^2$ | 0,9179 | 0,8656 | 0,9567 | 0,9483 |
| MSE   | 0,0002 | 0,0030 | 0,0001 | 0,0001 |
| RMSE  | 0,0150 | 0,0546 | 0,0109 | 0,0119 |
| MAE   | 0,0113 | 0,0263 | 0,0070 | 0,0084 |

Tabela 3: Métricas dos modelos para o torque

|       | DT     | RP     | RF     | EL     |
|-------|--------|--------|--------|--------|
| $R^2$ | 0,7935 | 0,8294 | 0,8459 | 0,9057 |
| MSE   | 0,3238 | 0,9165 | 0,2417 | 0,1479 |
| RMSE  | 0,5690 | 0,9574 | 0,4916 | 0,3846 |
| MAE   | 0,4424 | 0,4704 | 0,3869 | 0,2864 |

Na primeira variável independente, observa-se que o modelo RF apresentou o melhor desempenho, enquanto na segunda função, o EL se destacou como o mais eficaz. Levando isso em consideração, esses modelos serão priorizados nas etapas subsequentes. Após essa seleção, os modelos treinados são utilizados para prever os valores de teste, e os resultados obtidos são verificados.

Essa série de treinamentos se concentra na previsão do desempenho do ventilador, abrangendo desde a limpeza dos dados até o ajuste de hiperparâmetros e a avaliação dos modelos por meio de métricas apropriadas. Esse uso avançado de ML reflete a adoção de tecnologias

emergentes para desenvolver sistemas inteligentes e autônomos, caracterizando-se como uma das principais características da Indústria 4.0.

A Figura 4 representa a comparação entre os valores reais e previstos da MFR usando o modelo RF, enquanto a Figura 5 realiza uma análise semelhante para o T, utilizando o EL. No eixo y há a exibição dos valores previstos, enquanto no eixo x, estão os valores reais. Quanto mais próximos os pontos estiverem da linha de referência, melhor será a precisão dos resultados.




Figura 4: Comparação entre valores reais e previstos da vazão com o *Random Forest*




Figura 5: Comparação entre valores reais e previstos do torque com o Ensemble Learning

Na Figura 4 e 5, o eixo y representa os valores previstos pelo modelo, enquanto o eixo x mostra os valores reais. Quanto mais próximos os pontos estiverem da linha de referência, melhor é a precisão das previsões. As métricas previamente avaliadas, como o  $R^2$ , desempenham um papel

crucial na interpretação desse gráfico. Um alto valor de  $R^2$ , como observado em ambos os casos, superior a 90,00%, indica que os modelos têm uma boa capacidade de fazer previsões precisas. Isso significa que, quanto melhor os dados se ajustam ao modelo, mais próximos os pontos estarão da linha de referência.

### 3.4. Otimização com meta-heurística

O Particle Swarm Optimization (PSO) é uma técnica eficaz de meta-heurística que busca soluções aproximadas em espaços de busca complexos. Baseado no movimento de partículas em um espaço multidimensional, o PSO permite explorar eficientemente o espaço de solução em busca do melhor valor em relação ao objetivo. Cada partícula representa uma possível solução para o problema em questão, e, ao longo das iterações, movem-se em direção às regiões que apresentam melhores resultados. O PSO busca encontrar valores ótimos das variáveis de entrada para maximizar o desempenho do ventilador.

Na etapa de otimização, é empregado o PSO para encontrar os melhores valores em relação aos objetivos do modelo. Para a variável de MFR, é utilizada a função do algoritmo RF com o objetivo de maximização. Já para a variável T, opta-se pela combinação de algoritmos fornecida pelo Ensemble Learning EL, visando à minimização. O tamanho do enxame é definido como 200 e estabelece-se um número máximo de iterações também em 200, garantindo uma busca eficiente pelo melhor conjunto de parâmetros.

Os valores previstos resultantes da aplicação do PSO foram 0,4040 kg/s para a MFR e 1.2796 Nm para T. Esses valores representam as melhores soluções encontradas para cada variável de entrada, destacando-se como resultados otimizados para o modelo em questão em que o vetor solução para a vazão é dada por  $\mathbf{x}_{\text{MFR}}^{\text{T}*} = [18 \quad 13,4 \quad 135 \quad 38,3]$  e para o torque é representada por  $\mathbf{x}_T^{\text{T}*} = [4 \quad -15 \quad -45 \quad 19]$ .

### 3.5. Validação dos resultados com o Computational Fluid Dynamics

Após todo o processo de construção dos modelos de ML e a otimização dos resultados utilizando MH, chega-se ao momento de realizar novas configurações de geometria para verificar a precisão dos resultados obtidos anteriormente. Com isso, uma nova simulação CFD é realizada para comparar os resultados ótimos de cada modelo.

Na primeira simulação, a previsão do modelo indicava que a MFR deveria ser de 0,4039 kg/s, mas o resultado obtido com o CFD foi de 0,3685 kg/s, representando uma diferença mínima de 8,76%. Na segunda simulação, a previsão para T era de 1,2796 Nm, enquanto o resultado do CFD foi de 1,1865 Nm, com uma diferença ainda menor, de 7,28%.

Esses resultados destacam a eficácia do modelo criado, mesmo com um número reduzido de simulações realizadas com o CFD utilizando o Ansys Fluent. Se um número maior de simulações fosse realizado para compor o banco de dados, os resultados poderiam ser ainda mais precisos, embora isso exigisse um tempo maior de simulação computacional.

A Figura 6 ilustra os resultados encontrados, comparando os modelos. A primeira parte se refere ao MFR, utilizando o modelo RF, e a segunda ao T, utilizando o modelo EL. A primeira parte apresenta um gráfico de superfície, mostrando a relação entre as variáveis de entrada mais significativas e a variável de saída, onde valores mais próximos do vermelho indicam proximidade do ótimo. Em seguida, as linhas de trajetória das partículas são exibidas em relação à quantidade de partículas no domínio. Por fim, são apresentados os contornos: o primeiro gráfico de contorno mostra a magnitude da velocidade em m/s, enquanto o segundo mostra a pressão total em Pa. Nos gráficos de partículas e de contorno, quanto mais próximo do vermelho, mais alto é o valor da escala; quanto mais próximo do azul, mais baixo é o valor.




Figura 6: Resultados obtidos com o Ansys Fluent com o uso da otimização meta-heurística para vazão e torque

Foi mantida a mesma escala para as figuras, permitindo a percepção clara do comportamento de cada uma das variáveis com base na escala de cores. A uniformidade na escala de cores facilita a comparação visual dos resultados entre as diferentes configurações de geometria e simulações. Observa-se que o comportamento dos fluxos é bastante distinto, refletindo a natureza conflitante dos objetivos de otimização.

### 3.6. Indústria 4.0

O emprego de técnicas como CFD, ML e MH exemplifica a integração dos princípios da Indústria 4.0. Esta última é fundamentada em quatro pilares principais: digitalização, integração, automação e customização.

O uso do CFD permite a digitalização do processo de *design* e análise do ventilador, fornecendo uma representação visual precisa do comportamento do fluxo de ar e de outros resultados que afetam diretamente seu desempenho em diferentes condições operacionais. Isso facilita a integração de dados e informações relacionadas ao produto, permitindo uma tomada de decisão mais informada em todas as etapas do processo.

Por sua vez, o ML oferece a capacidade de extrair percepções valiosas dos dados gerados pelo CFD, possibilitando a automação de tarefas complexas, como previsão de desempenho, custo e outras variáveis significativas com base em diferentes configurações e condições de trabalho. Além disso, permite a personalização do processo com a adaptação do *design* do ventilador às necessidades específicas de cada aplicação ou cliente.

A MH desempenha um papel crucial na automação da otimização da configuração do ventilador, explorando de forma eficiente o espaço de solução em relação às possíveis respostas. Com a aplicação de algoritmos de otimização, torna-se possível encontrar soluções ótimas em um tempo mais curto, auxiliando na tomada de decisões.

Dessa forma, a aplicação integrada dessas técnicas reflete o compromisso com os princípios da Indústria 4.0, promovendo a digitalização, integração, automação e customização dos processos industriais, com o propósito de atender às demandas de um mercado cada vez mais dinâmico e competitivo.

#### 4. Conclusão

O tempo é um recurso de suma importância, com isso, economizá-lo ou utilizá-lo de forma mais eficiente representa um grande ganho industrial. O método proposto visa mesclar várias técnicas para trazer vantagens desde a concepção do problema até sua otimização, visando alcançar resultados eficazes com um custo computacional reduzido, alinhando-se aos princípios da Indústria 4.0.

Para superar os desafios impostos pela *Computational Fluid Dynamics* (CFD), o uso de *Machine Learning* (ML) e meta-heurísticas (MH) oferece técnicas avançadas para resolver problemas complexos de forma eficiente. Essas técnicas avançadas não apenas geram modelos com ajustes precisos, como também possibilitam a otimização das variáveis independentes em busca da confecção do melhor *design*. Além de gerar modelos com ajustes adequados e R-quadrado superiores a 90%, a otimização das variáveis independentes busca encontrar o melhor *design*. Esse *design* é então reproduzido novamente no CFD para comprovação dos resultados, apresentando um erro inferior a 9% e garantindo a confiabilidade dos resultados.

Os resultados obtidos demonstram a capacidade do método em realizar previsões e otimizações de forma eficiente, com menor tempo computacional e resultados próximos aos que seriam obtidos com o CFD, mas com uma base estatística sólida e sem a necessidade de testes por tentativa e erro. Essa integração de tecnologias avançadas que inclui princípios da digitalização, integração, automação e customização dos processos, não só reduz o tempo computacional, mas também promove uma abordagem mais inteligente e adaptável para lidar com problemas industriais complexos, permitindo uma resposta mais ágil e eficaz.

Destaca-se que foi realizada uma otimização para cada variável. Em trabalhos futuros, serão realizadas otimizações multiobjetivo, analisando variáveis conflitantes e utilizando outros métodos de solução, como o *Multiobjective Particle Swarm Optimization* (MOPSO) e a *Normal Boundary Intersection* (NBI). O objetivo é encontrar um conjunto de soluções Pareto-ótimas e avaliar os resultados através de *trade-off* entre as variáveis.

#### Referências

- CHENG, B.; DU, J.; YAO, Y. Machine learning methods to assist structure design and optimization of Dual Darrieus Wind Turbines. *Energy*, v. 244, p. 122643, 1 abr. 2022.
- FUKAMI, K.; FUKAGATA, K.; TAIRA, K. Super-resolution reconstruction of turbulent flows with machine learning. *Journal of Fluid Mechanics*, v. 870, p. 106–120, 10 jul. 2019.
- GEROLD FINK *et al.* Accurate and Efficient Simulation of Microfluidic Networks. *Proceedings of the Asia and South Pacific Design Automation Conference, ASP-DAC*, p. 85–90, 18 jan. 2021.
- KHANKARI, K. Analysis of spread of airborne contaminants and risk of infection. *Volume 63, Issue 7, Pages 14 - 20*, v. 63, n. 7, p. 14–20, 1 jul. 2021.
- KOCHKOV, D. *et al.* Machine learning–accelerated computational fluid dynamics. *Proceedings of the National Academy of Sciences of the United States of America*, v. 118, n. 21, p. e2101784118, 25 maio 2021.
- MAHIAN, O. *et al.* Recent advances in modeling and simulation of nanofluid flows-Part I: Fundamentals and theory. *Physics Reports*, v. 790, p. 1–48, 3 fev. 2019.
- MEHRNIA, S. *et al.* Radial turbine optimization under unsteady flow using nature-inspired algorithms. *Aerospace Science and Technology*, v. 103, p. 105903, 1 ago. 2020.
- MENÉNDEZ-PÉREZ, A. *et al.* Metaheuristics applied to the optimization of a compact heat exchanger with enhanced heat transfer surface. *Applied Thermal Engineering*, v. 214, p. 118887, 1 set. 2022.

NABIPOUR, N. *et al.* Prediction of Nanofluid Temperature Inside the Cavity by Integration of Grid Partition Clustering Categorization of a Learning Structure with the Fuzzy System. *ACS Omega*, v. 5, n. 7, p. 3571–3578, 25 fev. 2020.

NORDVIK, A. *et al.* Numerical prediction of hill charts of Francis turbines. *Journal of Physics: Conference Series*, v. 1266, n. 1, p. 012011, 2 ago. 2019.

RASTGOO, A.; KHAJAVI, H. A novel study on forecasting the airfoil self-noise, using a hybrid model based on the combination of CatBoost and Arithmetic Optimization Algorithm. *Expert Systems with Applications*, v. 229, p. 120576, 1 nov. 2023.

SHEN, R. *et al.* Recent application of Computational Fluid Dynamics (CFD) in process safety and loss prevention: A review. *Journal of Loss Prevention in the Process Industries*, v. 67, p. 104252, 1 set. 2020.

SILVESTRI, L. CFD modeling in Industry 4.0: New perspectives for smart factories. *Procedia Computer Science*, v. 180, p. 381–387, 1 jan. 2021.

TI, Z.; DENG, X. W.; YANG, H. Wake modeling of wind turbines using machine learning. *Applied Energy*, v. 257, p. 114025, 1 jan. 2020.

WHITE, C.; USHIZIMA, D.; FARHAT, C. Fast neural network predictions from constrained aerodynamics datasets. *AIAA Scitech 2020 Forum*, v. 1, p. 1–10, 1 jan. 2020.

ZHU, L. *et al.* Machine learning methods for turbulence modeling in subsonic flows around airfoils. *Physics of Fluids*, v. 31, n. 1, p. 015105, 1 jan. 2019.