

CFD E APRENDIZADO DE MÁQUINAS PARA ESTIMATIVA DO FATOR DE PERFIL DE MEDIDORES ULTRASSÔNICOS DE VAZÃO EM CONDIÇÕES NÃO CONFORMES

Lucas Araujo de Almeida¹, lucas.almeida.45@edu.ufes.br

Ramon Silva Martins¹, ramon.martins@ufes.br

Luis Gustavo Giacon Villani¹, luis.villani@ufes.br

Guilherme Siqueira de Aquino², guilherme.siqueiradeaquino@imft.fr

¹ Universidade Federal do Espírito Santo (UFES), Campus Goiabeiras, Av. Fernando Ferrari 514, Vitória, ES, 29075-910

² Institut de Mécanique des Fluides de Toulouse (IMFT), Université de Toulouse, CNRS, 314000 Toulouse, France

Resumo. O conhecimento do fator de perfil - fator que converte a velocidade média no caminho acústico do medidor na velocidade média da seção transversal - em tempo real nos medidores de vazão ultrassônicos por tempo de trânsito é fundamental nos casos em que o medidor está próximo de um acidente de linha - qualquer característica ou elemento da tubulação que perturbe o escoamento - e, portanto, não apresenta perfil de velocidades completamente desenvolvido. O presente trabalho apresenta a análise do fator de perfil em uma curva sob a variação do número de Reynolds (Re), distância à curva e ângulo do medidor por CFD – sigla em inglês para Dinâmica dos Fluidos Computacional. Por fim, são gerados modelos de Aprendizado de Máquina (AM) para a estimativa do fator de perfil, que comprovaram elevada acurácia do Random Forest (RF), Regressão por Processos Gaussianos (RPG), Multilayer Perceptron (MLP) e Gradient Boosting Regressor (GBR), com erros abaixo de 5% para certas configurações do medidor. Dentre os modelos testados, o modelo RF se destacou por seu baixo tempo de treino e predição.

Palavras-chave: Medidor de vazão ultrassônico. Aprendizado de Máquinas. Dinâmica dos fluidos computacional.

1. INTRODUÇÃO

A medição de vazão é uma atividade fundamental no controle de processos industriais. Entre as opções de medidores de vazão, encontra-se o medidor de vazão por ultrassom por tempo de trânsito, que representa uma alternativa de elevada acurácia (L. LYNNWORTH; Y. LIU, 2006), com grande intervalo de operação com relação a vazão (HONEYWELL INTERNATIONAL, INC., 2012), possível autodiagnóstico (por comparação com a velocidade do som termodinâmica), ausência de partes móveis e baixa perda de carga (K. MYLVAGANAM, 1989).

As características do medidor ultrassônico são essenciais para a medição de vazão em unidades de flare (SICK – SENSOR INTELLIGENCE, 2012), em que há larga faixa de vazão e há o transporte de gases inflamáveis, o que não permite técnicas intrusivas. As unidades de flare apresentam, em geral, limitações de espaço para os ramos de tubulação, o que não permite fazer com que o medidor de vazão esteja próximo de acidentes de linha que produzem escoamentos em condições não conformes.

A medição de vazão ultrassônica por tempo de trânsito requer o conhecimento do perfil de velocidades para a determinação do fator de perfil, que representa a razão entre a velocidade média aferida pelo medidor e a velocidade média da seção transversal (W. MILLER, 1996). Em condições perturbadas, o perfil de velocidades pode ser aferido por técnicas experimentais ou numéricas.

Uma vez que os escoamentos industriais podem apresentar configurações variadas com respeito à vazão, geometria, posição do medidor, entre outros fatores, a integração do CFD com o Aprendizado de Máquinas (AM) representa uma alternativa promissora para a calibração e estimativa de erro em tempo real de medidores ultrassônicos, por meio de modelos de regressão (SIQUEIRA DE AQUINO et al., 2025). As técnicas de Random Forest e Redes Neurais demonstraram elevada acurácia na previsão de erros de medidores ultrassônicos em operação no trabalho de LI et al. (2023).

Diante deste contexto, objetiva-se analisar o comportamento do fator de perfil em uma curva de 90 graus, com base na teoria da mecânica dos fluidos e em simulações CFD. A partir da base de dados obtida, pretende-se treinar modelos de Aprendizado de Máquina capazes de prever o comportamento desse fator.

2. METODOLOGIA


A metodologia de análise consiste na obtenção de dados do fator de perfil por meio de CFD, com posterior tratamento por Machine Learning para regressão. As simulações são realizadas através do software Ansys Fluent, e o tratamento de dados, assim como as regressões do Machine Learning, são realizados através da linguagem de programação Python.

2.1. CFD

A análise dos medidores ultrassônicos por meio de CFD se dá pela avaliação do fator de perfil em regime permanente por simulações com a técnica RANS com a variação dos seguintes parâmetros: Número de Reynolds (Re), distância ao acidente de linha (x_c) e ângulo de medição (θ), em medidores ultrassônicos do tipo Z. O fluido em análise é o ar a 15°C ($\nu = 1,461 \text{ m}^2/\text{s}$), dessa forma, a alteração do Re se dá pela mudança da velocidade média de entrada.

São usadas como base as dimensões do circuito do NEMOG (MARTINS, 2021). Dessa forma, $D = 290 \text{ mm}$, $R = 1,5D$ e os ângulos do medidor consistem em 8 pontos igualmente espaçados (Figura 1). As demais variáveis são como mostradas na Figura 1. Para a análise CFD, a geometria apresenta comprimento total após a curva $L_c = 55D$. As condições de contorno são de entrada com perfil completamente desenvolvido (1), não deslizamento na parede (2) e gradiente de velocidade e pressão especificada iguais a zero na saída (3).

Figura 1 – Geometria do caso analisado



Fonte: Produção dos autores.

São utilizadas 5 malhas de referência e o teste de independência de malha é realizado com 3 malhas. A convergência é verificada pelo valor da distância adimensional a parede (y^+) e pela raiz do erro quadrático médio (RMSE).

Conforme Martins (2021), o modelo de turbulência escolhido é o RSM com tratamento de parede Scalable, e o método de discretização utilizado é o upwind de segunda ordem.


2.2. FATOR DE PERFIL

A velocidade média do medidor ultrassônico pode ser medida através dos tempos de trânsito e ângulo do medidor, conforme equação (1) - t_{AB} é o tempo de trânsito do ponto A ao B, D é o diâmetro da tubulação e α o ângulo entre os medidores no plano de medição, conforme esquemático na Figura 2. A velocidade média real é, então, obtida pelo fator de perfil.

$$\bar{u}_{UFM} = \frac{D}{\sin(2\alpha)} \left(\frac{t_{BA} - t_{AB}}{t_{AB}t_{BA}} \right) \quad (1)$$

A vazão na simulação é conhecida a partir do perfil de velocidades de entrada, e então o fator de perfil numérico é obtido a partir do perfil de velocidades no caminho acústico através da equação (2), em que u , v e w são as componentes de velocidade e θ o ângulo do plano de medição (Figura 2).

Figura 2 – Esquema do medidor ultrassônico



Fonte: Editado de Aquino (2025).

$$\bar{u}_{UFM} = \frac{1}{L} \left(\int_0^L u \, dL + \tan(\alpha) \cos(\theta) \int_0^L v \, dL + \tan(\alpha) \sin(\theta) \int_0^L w \, dL \right) \quad (2)$$

2.3. MACHINE LEARNING

Os dados são divididos em 80% para treino e 20% para teste, com exceção do modelo de RPG, em que são utilizados 40% para teste a fim de reduzir o custo computacional da geração do modelo. No caso do MLP, 30% dos dados de treino são separados para validação.

São testados os modelos de Regressão por Processos Gaussianos, Random Forest, Gradient Boosting Regressor e Redes Neurais para estimativa do fator de perfil. Todos os modelos são analisados inicialmente para otimização dos parâmetros de aprendizado. Uma vez que os parâmetros do modelo são ajustados, são avaliadas as estatísticas do RMSE e R^2 através da validação cruzada com 5 conjuntos de dados (com exceção do caso da RPG, em que é calculada pela estatística do próprio modelo) com os dados de teste. Por fim, o modelo mais rápido na predição é testado quanto ao seu erro relativo na estimativa do fator de perfil.

3. RESULTADOS E DISCUSSÕES

A Tabela 1 mostra os resultados obtidos pelos modelos de regressão, em que as variáveis T_{rel} representam o tempo relativo para determinada tarefa. Todos os modelos apresentaram boa acurácia na interpolação do fator de perfil, no entanto, o modelo MLP e RPG apresentaram elevado tempo para predição, o que pode ser prejudicial para atualização de k em tempo real. Apesar do modelo RF apresentar baixo tempo de treino e predição, este depende de uma maior quantidade de dados que os demais, o que pode representar uma limitação em certos contextos e pode ser explorado em trabalhos futuros.


A Figura 3 mostra a distribuição dos erros relativos das predições feitas pelo modelo Random Forest. Observa-se que os erros se concentram abaixo de 5%, no entanto, a configuração do medidor deve ser escolhida corretamente a fim de evitar erros extremos (como o erro acima de 12,5%).

Tabela 1 – Resultados dos modelos de Machine Learning

Modelo	R^2	RMSE	$T_{rel,treino}$	$T_{rel,predição}$
RF	0,9914	0,0062	1,00	1,00
GBR	0,9951	0,0047	15,45	8,97
MLP	0,9739	0,0113	6859,6	99,83
RPG	0,9940	0,0051	63997,5	1559,8

Fonte: Produção dos autores.

Figura 3 – Distribuição dos erros relativos do modelo Random Forest



Fonte: Produção dos autores.

4. CONCLUSÕES

A partir dos resultados obtidos, é possível concluir que os modelos de Machine Learning foram capazes de prever o fator de perfil, de forma que a estimativa deste fator, em operação, pode ser utilizada para o aumento da acurácia na medição de vazão.

5. REFERÊNCIAS

- AQUINO, G. S. de et al. Statistical considerations on rans simulations of inhomogeneous pipe flows. Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 47, n. 2, jan. 2025.
- HONEYWELL INTERNATIONAL, INC., “NATURAL GAS ULTRASONIC FLOW METER USZ 08,” 2012. Disponível em: <http://www.mercuryinstruments.com/products/flowmeter/USM-USZ-08.php>.
- K. MYLVAGANAM, “High-Rangeability Ultrasonic Gas Flowmeter for Monitoring Flare Gas,” IEEE Transactions on Ultrasonics Ferroelectric and Frequency Control, vol. 36, no. 2, pp. 144– 149, 1989.
- LI, Mengna; LI, Zhen-Lin; LI, Chunhui. In-use measurement of ultrasonic flowmeter based on machine learning. Measurement: Journal of the International Measurement Confederation, v. 223, p. 113721, 2023. DOI: 10.1016/j.measurement.2023.113721.
- L. LYNNWORTH and Y. LIU, “Ultrasonic flowmeters: Half-century progress report, 1955 2005,” Ultrasonics, vol. 44, no. Supplement 1, pp. e1371– e1378, 2006. Proceedings of Ultrasonics International (UI’05) and World Congress on Ultrasonics (WCU).
- MARTINS, R. S. et al. Sensitivity analysis for numerical simulations of disturbed flows aiming ultrasonic flow measurement. Measurement, v. 185, p. 110015, 2021. ISSN 0263-2241.
- W. MILLER, R. Flow Measurement Engineering Handbook. McGraw–Hill, 3rd ed., 1996.
- SICK - SENSOR INTELLIGENCE, “FLOWSIC100 Flare Ultrasonic Mass Flow Meter- Gas Mass Flow Measurement for Flare Gas Applications,” 2012.
- SIQUEIRA DE AQUINO, G.; Silva Martins, R.; Ferreira Martins, M.; Ramos, R. An Overview of Computational Fluid Dynamics as a Tool to Support Ultrasonic Flow Measurements. Metrology 2025, 5, 11. <https://doi.org/10.3390/metrology5010011>.

6. AGRADECIMENTOS

Os autores agradecem ao PPGEM-UFES e ao LabTecMec-UFES por patrocinar o evento.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.