

CLASSIFICAÇÃO DE VAZÃO A PARTIR DE SÉRIES TEMPORAIS DE PRESSÃO ATRAVÉS DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

SOFIA PAGLIARINI¹; ALLAN MALDANER RODRIGUES²; RAFAELA ARAUJO RAUBER³; JOÃO GABRIEL PIRAINÉ BANDEIRA⁴; JOÃO INÁCIO MOREIRA BEZERRA⁵; MARLON HERNANDEZ-CELY⁶

¹; ²; ³; ⁴ Engenharia de Controle e Automação, Centro de Engenharias CEng –
sofiapagliarini@gmail.com; maldaner.allan@gmail.com; raffah84@gmail.com;
joaogabrielpbandeira@gmail.com

⁵ Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico CD Tec –
jimbezerra@inf.ufpel.edu.br

⁶ Engenharia de Controle e Automação, Centro de Engenharias CEng – marlon.cely@ufpel.edu.br

1. INTRODUÇÃO

Diante dos avanços tecnológicos e científicos observados ao longo das Revoluções Industriais, diversas inovações foram implementadas com o objetivo de aprimorar sistemas e processos industriais. Assim, o uso de sensoriamento, máquinas programáveis, protocolos de comunicação, entre outros recursos, tornou-se cada vez mais presente e necessário para a execução de tarefas, promovendo a automação de processos e a otimização de recursos.

A vazão é a terceira variável de processo mais medida na indústria, devido à sua relevância em diferentes aplicações (FRAYNE et al., 1994; LIU et al., 2022), que vão desde o uso residencial até processos industriais complexos. Atualmente, o mercado oferece uma ampla variedade de sensores de vazão, cada um voltado a necessidades específicas, como precisão, tipo de fluido (gás, líquido, combustível), condutividade elétrica, condições termodinâmicas, espaço físico disponível para instalação, custo, entre outros fatores (VIVACE INSTRUMENTS, 2024).

Com os avanços da Quarta Revolução Industrial, diversas técnicas têm sido disseminadas para facilitar processos e otimizar o tempo de execução. Nesse contexto, este estudo explora o potencial de uma das vertentes da Indústria 4.0: a Inteligência Artificial (IA), mais especificamente os modelos de Aprendizado de Máquina (*Machine Learning* — ML). Esses modelos utilizam bases de dados para treinamento, visando à realização de tarefas específicas na etapa de teste; no presente caso, o problema abordado é a classificação (MONTINI, 2019). Embora a literatura apresenta diversos modelos de ML para tarefas de classificação, este trabalho foca na implementação de algoritmos baseados em árvores de decisão, tais como *Random Forest* e *XGBoost* (ALHASHEM, 2020). Essas arquiteturas utilizam o treinamento de múltiplas árvores de decisão independentes. O *Random Forest* aplica a técnica de *bagging*, enquanto o *XGBoost* utiliza *boosting*, cuja principal diferença está no fato de o *XGBoost* combinar suas árvores de forma sequencial para corrigir erros anteriores, tornando o modelo mais robusto (CHAUDHARY et al., 2016; WANG et al., 2024).

Considerando a diversidade de sensores de vazão e as dificuldades frequentemente associadas à sua instalação e aplicação correta, este trabalho tem como objetivo classificar diferentes tipos de vazão a partir da análise de dados obtidos por sensores transmissores de pressão (TRAN et al., 2017). Esses sensores apresentam vantagens, como facilidade de instalação e manutenção em tubulações, maior adaptabilidade e menor sensibilidade a mudanças externas (KAMALI, 2025). Dessa forma, propõe-se um estudo experimental que utilize dados de sensores de pressão para a classificação de diferentes tipos de vazão, com o suporte de arquiteturas baseadas em Inteligência Artificial.

2. METODOLOGIA

Considerando que, para a implementação deste estudo e o alcance dos objetivos estabelecidos, foi proposto um esquema de passos, apresentado na Figura 1. Em seguida, procedeu-se à etapa de aplicação desses passos com os respectivos materiais.

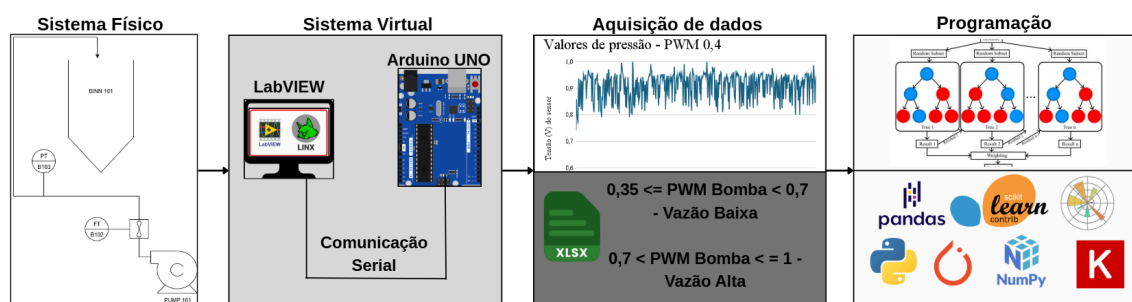


Figura 1 - Esquema de passos a serem seguidos no estudo. Autoria própria.

No experimento do projeto, desenvolveu-se um sistema hidráulico monofásico, com fluido líquido de água, composto por uma bomba centrífuga responsável por gerar a vazão no sistema, dois sensores, um para medir a vazão (em L/min) e outro para medir a pressão (em Bares) do fluxo no duto e um tanque para armazenar o fluido. Para possibilitar a leitura e o armazenamento dos sinais provenientes dos sensores do circuito físico, utilizou-se comunicação serial por meio de um *Arduino UNO*®, permitindo a programação em blocos no sistema supervisor baseado em *LabVIEW*® e o registro das informações desejadas.

Com o intuito de produzir uma base de dados de séries temporais de pressão, foram coletadas aproximadamente 500 amostras para cada variação de tensão aplicada à bomba, possibilitando, ao final, a divisão dos valores de vazão em dois grupos principais: alta vazão e baixa vazão. A partir desse banco de dados, contendo valores de pressão e suas respectivas classificações, passou-se à etapa de programação das técnicas de Aprendizado de Máquina.

Para a implementação dos classificadores de ML, optou-se pela linguagem *Python*, devido à sua facilidade de programação por meio de bibliotecas específicas para Inteligência Artificial, além de sua ampla disseminação no meio científico. Neste estudo, as bibliotecas utilizadas concentram-se principalmente no

scikit-learn e no *NumPy*, empregadas para o processamento e normalização dos dados. As técnicas de ML escolhidas para a classificação foram o *Random Forest* e o *XGBoost*, ambas baseadas no processamento das informações por meio de “árvores” para tomada de decisão. A escolha dessas técnicas deve-se ao seu baixo custo computacional e elevada eficiência na classificação binária.

3. RESULTADOS E DISCUSSÃO

Finalizadas as compilações de treinamento, validação e teste dos modelos de classificação, os resultados do estudo foram demonstrados por meio das Matrizes de Confusão, apresentadas na Figura 2. Como observado, a classificação binária entre vazão alta e baixa alcançou resultados satisfatórios. Como esta base foi desenvolvida no estudo, sabe-se que está balanceada para os dois casos: alta vazão e baixa vazão. Com isso, foi possível analisar, juntamente com as matrizes, a acurácia da classificação, que é calculada pela divisão do número de previsões corretas pelo total de previsões realizadas. Assim, a média da acurácia dos classificadores *Random Forest* e *XGBoost* é aproximadamente 94%, atingindo o objetivo de uma boa classificação.




Figura 2 - Matrizes de Confusão dos resultados dos classificadores de vazão. Autoria própria.

4. CONCLUSÕES

O sistema inteligente desenvolvido neste trabalho demonstrou alta eficácia na classificação de séries temporais de vazão a partir de um sensor de pressão. Os modelos atingiram bons resultados, com acurácia máxima de 94%, cumprindo assim os objetivos propostos pela pesquisa. O bom desempenho foi corroborado pela análise das Matrizes de Confusão, que indicaram uma performance consistente para ambas as técnicas de Inteligência Artificial empregadas.

Este trabalho, portanto, demonstra uma tendência no setor industrial: a integração de tecnologias, desde a instrumentação industrial para medir e coletar dados até a aplicação da Inteligência Artificial.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ALHASHEM, M. Machine learning classification model for multiphase flow regimes in horizontal pipes. In: INTERNATIONAL PETROLEUM TECHNOLOGY CONFERENCE, IPTC, 2020. p.D023S042R001.

ARTEAGA-ARTEAGA, H.B. et al. Machine learning applications to predict two-phase flow patterns. PeerJ Computer Science, Amsterdam, v.7, p.e798, 2021.

CHAUHDARY, A.; KOLHE, S.; KAMAL, R. An improved random forest classifier for multi-class classification. Information Processing in Agriculture, Amsterdam, v.3, n.4, p.215–222, 2016.

FRAYNE, R. et al. Turbine flow sensor for volume-flow rate verification in MR. Magnetic Resonance in Medicine, Hoboken, v.32, n.3, p.410–417, 1994.

KAMALI, H.A. Impact of liquid injector pressure on gas flow characteristics and evaporation rates: A combined Eulerian-Lagrangian approach and PSO-optimized XGBoost model. International Communications in Heat and Mass Transfer, Amsterdam, v.164, p.108822, 2025.

LIU, X. et al. Dynamic performance analysis of turbine flow sensor based on CFD simulations. Flow Measurement and Instrumentation, Amsterdam, v.87, p.102205, 2022.

MONTINI, A. Machine e deep learning: fortes tendências para o Brasil em 2019. Zero Hora Digital, Porto Alegre, 2019. Online. Disponível em: <https://febrabantech.febraban.org.br/especialista/alessandra-montini/machine-e-deep-learning-fortes-tendencias-para-o-brasil-em-2019>

TRAN, A.V.; ZHANG, X.; ZHU, B. The development of a new piezoresistive pressure sensor for low pressures. IEEE Transactions on Industrial Electronics, New York, v.65, n.8, p.6487–6496, 2017.

VIVACE INSTRUMENTS. A medição de vazão. 2024. Online. Disponível em: <https://www.vivaceinstruments.com.br/pt/artigo/a-medicao-de-vazao>

WANG, D. et al. Prediction of Oil–Water Two-Phase Flow Patterns Based on Bayesian Optimisation of the XGBoost Algorithm. Processes, Basel, v.12, n.8, p.1660, 2024.